

## Implementasi *Deep Learning* untuk Pelabelan Lahan pada Citra Satelit Area Desa Leles

Alifia Nadiva Altafunnisia<sup>1\*</sup>, Jumadi<sup>2</sup>, Eva Nurlatifah<sup>3</sup>

Teknik Informatika, UIN Sunan Gunung Djati Bandung, Bandung, Indonesia

\*e-mail *Corresponding Author*: 1207050012@student.uinsgd.ac.id

### Abstract

*Efficient land management in rural areas is essential for environmental sustainability and community well-being. This study develops a deep learning model to classify land types in satellite imagery, focusing on two main categories: residential areas and vacant land. The dataset consists of 2,080 cropped images from Google Earth, divided into 790 images for training, 790 for validation, and 500 for testing. The model is trained using transfer learning with the ResNet50 architecture and optimized over 50 epochs. Training results show an accuracy of 99% for training and 98% for validation, while evaluation on the test dataset achieves an accuracy of 91.4%. The model successfully identifies most images correctly, although 43 out of 500 images were misclassified. These findings demonstrate the significant potential of deep learning in supporting more accurate land management based on satellite imagery, contributing to more efficient spatial planning.*

**Keywords:** *Google earth image; Deep learning; Satellite imagery.*

### Abstrak

Pengelolaan lahan yang efisien di daerah pedesaan penting untuk keberlanjutan lingkungan dan kesejahteraan masyarakat. Penelitian ini mengembangkan model *Deep Learning* untuk mengidentifikasi jenis lahan pada citra satelit, dengan kategori utama: pemukiman dan lahan kosong. *Dataset* terdiri dari 2.080 gambar hasil *cropping* citra *Google Earth*, yang dibagi menjadi 790 gambar untuk pelatihan, 790 untuk validasi, dan 500 untuk pengujian. Model dilatih menggunakan *transfer learning* dengan arsitektur *ResNet50*, yang dioptimalkan selama 50 *epoch*. Hasil pelatihan menunjukkan hasil training 99% dan validasi 98%, sementara evaluasi pada data pengujian mencapai 91,4%. Model berhasil mengidentifikasi sebagian besar gambar dengan benar, meskipun masih terdapat 43 dari 500 gambar yang tidak sesuai dengan label aslinya. Penelitian ini menunjukkan bahwa *Deep Learning* memiliki potensi besar dalam mendukung pengelolaan lahan berbasis citra satelit yang lebih akurat untuk mendukung perencanaan tata ruang yang lebih efisien.

**Kata kunci:** *Google earth image; Deep learning; Citra satelit.*

### 1. Pendahuluan

Penggunaan teknologi identifikasi citra satelit telah menjadi alat penting dalam berbagai bidang, termasuk pertanian, kehutanan, perencanaan tata ruang, serta mitigasi bencana [1]. Kemampuannya untuk memberikan gambaran visual area yang luas dalam berbagai resolusi dan spektrum warna menjadikannya sumber informasi yang sangat berharga dalam memahami kondisi geografis, ekologis, dan sosial [2]. Di era digital ini, kebutuhan akan metode yang lebih canggih dalam pengolahan citra satelit semakin meningkat guna menghasilkan informasi yang akurat, relevan, dan dapat diandalkan [3]. Tantangan global seperti perubahan iklim, urbanisasi, dan degradasi lingkungan semakin menuntut pendekatan berbasis data dalam mendukung pengambilan keputusan strategis [4]. Salah satu teknologi yang berkembang pesat dan memiliki potensi besar dalam analisis citra satelit adalah *deep learning* [5], yang telah membuka peluang baru dalam pemrosesan data skala besar dengan tingkat presisi yang tinggi [6].

Meskipun memiliki potensi agraris yang besar, Desa Leles di Kabupaten Garut menghadapi tantangan dalam memastikan pengelolaan lahan yang efektif [7]. Berdasarkan data statistik Kabupaten Garut, Desa Leles memiliki luas wilayah sebesar 6,41 kilometer persegi dan perekonomian warganya sangat bergantung pada sektor pertanian [8]. Namun,

pengelolaan lahan di daerah ini masih memiliki keterbatasan dalam pemetaan penggunaan lahan secara akurat, menghambat optimalisasi sumber daya yang tersedia. Proses identifikasi lahan sering kali memerlukan waktu lama serta sumber daya manusia yang signifikan, sehingga efisiensi menjadi kendala utama [9]. Dengan demikian, diperlukan strategi yang lebih efektif untuk mendukung pengelolaan lahan yang lebih optimal.

Untuk mengatasi tantangan tersebut, pendekatan berbasis *deep learning* dapat menjadi solusi yang efektif. *Deep learning* telah terbukti mampu memahami pola kompleks dalam data visual, termasuk dalam analisis citra satelit [10]. Model seperti *Convolutional Neural Networks* (CNN) telah menunjukkan keberhasilan dalam berbagai aplikasi seperti pengenalan wajah dan diagnosis medis berbasis citra [11]. Dalam konteks identifikasi citra satelit, CNN dapat dilatih untuk mengenali berbagai jenis penggunaan lahan, seperti lahan pertanian, hutan, area perkotaan, atau badan air, dengan tingkat akurasi yang tinggi [12]. *Google Earth*, sebagai penyedia citra satelit resolusi tinggi yang mudah diakses, menjadi sumber data yang sangat relevan untuk penelitian ini [13]. Dengan memanfaatkan teknologi ini, diharapkan dapat tercipta sistem otomatis yang mampu mengidentifikasi dan memetakan lahan dengan lebih efisien dibandingkan metode konvensional.

Penelitian ini difokuskan pada pengembangan model *deep learning* berbasis CNN guna mengidentifikasi jenis lahan di Desa Leles, khususnya lahan kosong dan pemukiman. Implementasi teknologi ini diharapkan dapat meningkatkan efisiensi dalam pemetaan lahan serta memberikan informasi yang akurat untuk mendukung perencanaan tata ruang yang lebih baik. Selain itu, hasil penelitian ini berpotensi menjadi langkah awal dalam transformasi digital pengelolaan sumber daya alam di tingkat lokal. Keberhasilan model yang dikembangkan juga diharapkan dapat diterapkan di wilayah lain dengan kebutuhan serupa, sehingga manfaatnya dapat dirasakan secara lebih luas.

## 2. Tinjauan Pustaka

Penelitian sebelumnya telah mengungkap berbagai metode dalam mengenali citra satelit dengan memanfaatkan teknologi kecerdasan buatan. Salah satu penelitian yang dilakukan oleh M. Andre Setiawan dkk [14], penerapan algoritma CNN dalam mengidentifikasi lahan untuk budidaya udang menunjukkan keberhasilan dengan capaian akurasi tertinggi sebesar 99% dan nilai loss 21%, menggunakan *batch size* 8 serta 30 *epoch*. Model ini menunjukkan performa yang baik dengan nilai akurasi sebesar 97,20%, *precision* 94,63%, dan *sensitivity* 95,81%. Model tersebut dinilai berkualitas karena tidak ditemukan indikasi *overfitting* maupun *underfitting* berdasarkan grafik *loss* dan akurasi.

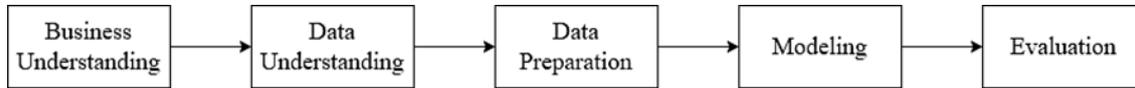
Selain itu, pada penelitian Dwi Wahyu dkk [15], model klasifikasi berbasis algoritma *Random Forest* (RF) dengan pendekatan piksel dikembangkan menggunakan data input dari citra satelit Landsat-8, Sentinel-1, dan Sentinel-2. Model ini kemudian diterapkan pada 10 kabupaten, dengan hasil terbaik diperoleh di Kabupaten Banyuwangi yang mencapai akurasi sebesar 0,89. Estimasi luas potensi lahan jagung bulanan di Banyuwangi berkisar antara 22.256,82 hingga 58.992,3 hektar. Hasil studi ini membuktikan bahwa pemanfaatan *cloud computing* mampu mempercepat proses komputasi, baik dalam tahap pembangunan model maupun prediksi pada seluruh kabupaten yang dikaji.

Pada penelitian Raditya Novidianto [16], penelitian ini membuktikan bahwa teknologi kecerdasan buatan, khususnya *Convolutional Neural Network* (CNN), memberikan hasil terbaik dengan nilai *sensitivity* 0,9807, *specificity* 0,9773, *accuracy* 0,9766, *MCC* 0,9682, dan *Cohen's Kappa* 0,9680, serta *G-mean* sebesar 0,9742. Model *rotfor multiclass OVO* juga menunjukkan kinerja yang cukup memadai dengan *sensitivity* 0,9106, *specificity* 0,9700, *accuracy* 0,9063, *MCC* 0,8760, dan *Cohen's Kappa* 0,9594, serta *G-mean* 0,9238. Sedangkan *rotfor multiclass OVA* menghasilkan *sensitivity* 0,9084, *specificity* 0,9699, *accuracy* 0,9063, *MCC* 0,8737, *Cohen's Kappa* 0,9595, dan *G-mean* 0,9229.

Pada penelitian sebelumnya menunjukkan bahwa pemanfaatan teknologi kecerdasan buatan, khususnya *Convolutional Neural Network* (CNN), telah terbukti efektif dalam mengidentifikasi dan mengenali citra satelit. Penelitian ini menggunakan arsitektur *ResNet50* yang sangat efektif dalam pengenalan citra. Berbeda dengan penelitian sebelumnya yang sering menggunakan model CNN standar, penelitian ini memanfaatkan keunggulan *ResNet50* yang memiliki kemampuan ekstraksi fitur yang lebih baik. Selain itu, pendekatan ini memungkinkan model untuk lebih adaptif dalam mengolah dan menginterpretasikan data citra satelit dengan tingkat akurasi yang lebih tinggi.

### 3. Metodologi

Metode yang diterapkan dalam penelitian ini adalah CRISP-DM (*Cross-Industry Standard Process for Data Mining*), yaitu suatu metodologi yang digunakan dalam proses perencanaan, pelaksanaan, dan evaluasi proyek *data mining* [17]. CRISP-DM merupakan model proses yang memberikan gambaran umum siklus hidup *data mining* [18].



Gambar 1. Metode CRISP-DM

#### 3.1 Business Understanding

Desa Leles merupakan wilayah dengan potensi agraris yang tinggi, sehingga pengelolaan lahan yang efisien menjadi kebutuhan penting untuk mendukung keberlanjutan lingkungan sekaligus meningkatkan kesejahteraan masyarakat setempat. Namun, proses ini cukup memakan waktu dan sumber daya, sehingga menjadi tantangan dalam menyediakan data yang cepat dan akurat untuk perencanaan tata ruang, pengelolaan sumber daya, dan identifikasi perubahan lingkungan. Dengan perkembangan teknologi kecerdasan buatan, khususnya *deep learning*, muncul peluang untuk mengotomatisasi proses identifikasi lahan. Penelitian ini bertujuan untuk meningkatkan efisiensi dalam identifikasi lahan pada area Desa Leles melalui penerapan teknologi *deep learning*. Keberhasilan penelitian ini dinilai berdasarkan akurasi model dalam mengidentifikasi jenis lahan, efisiensi waktu pemrosesan, serta manfaat yang dapat dirasakan langsung oleh pihak terkait, seperti pemerintah daerah dan masyarakat setempat. Dengan demikian, implementasi teknologi ini diharapkan dapat menjadi solusi inovatif dalam mendukung pengelolaan lahan yang lebih baik dan berkelanjutan.

#### 3.2 Data Understanding

*Dataset* yang digunakan pada penelitian ini diperoleh dengan melakukan *cropping* pada citra satelit dari *Google Earth* khusus untuk kawasan Desa Leles, menghasilkan sebanyak 2.080 gambar. *Dataset* ini mencakup dua kategori utama, yaitu lahan kosong dan pemukiman, yang dirancang untuk mendukung proses pelatihan, validasi, dan pengujian model *deep learning*. Pembagian *dataset* ini bertujuan untuk memastikan model dapat belajar mengenali pola secara efektif sekaligus dievaluasi secara akurat untuk mengukur performanya.

Tabel 1. Gambar *Dataset* Hasil *Cropping*

Kelas Gambar		
	Lahan Kosong	Pemukiman
<i>Data Training</i>		



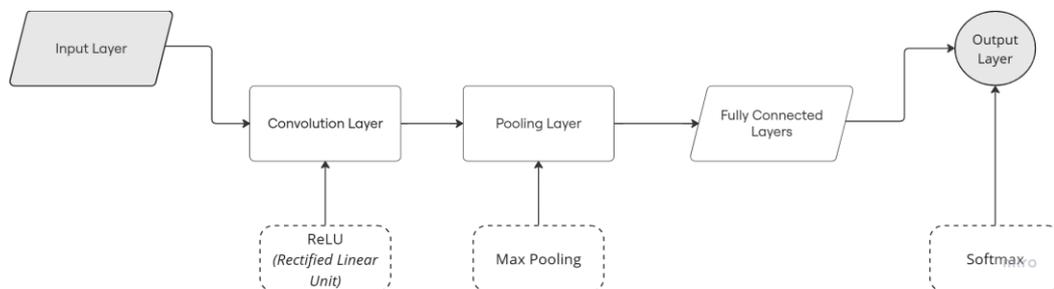
### 3.3 Data Preparation

Dataset yang terdiri dari 2.080 gambar diproses pada tahap *data preparation*, dengan alokasi 1.580 gambar untuk *training* dan *validation*, serta 500 gambar untuk *testing*, guna memastikan performa optimal dari model *deep learning*. Proses yang dilakukan meliputi *resizing* gambar ke dimensi standar agar konsisten dengan input model, normalisasi piksel untuk mengubah nilai piksel ke rentang tertentu sehingga mempercepat konvergensi model, augmentasi data yang meliputi *flipping*, *rotating*, *scaling*, dan *cropping*, serta pembagian dataset menjadi *training*, *validation*, dan *testing* untuk memastikan evaluasi model dilakukan secara objektif dan menyeluruh. Proses ini bertujuan untuk mempersiapkan dataset yang berkualitas dan siap digunakan dalam pelatihan model *deep learning*.

Tabel 2. Jumlah dan Pembagian Data

Data Kategori	Jumlah	Persentase
<i>Training</i>	790	38%
<i>Validation</i>	790	38%
<i>Testing</i>	500	24%

### 3.4 Modeling



Gambar 2. Struktur arsitektur *Convolutional Neural Network*

Arsitektur *Convolutional Neural Network* (CNN) yang disusun khusus untuk mengidentifikasi citra satelit digunakan pada tahap *modeling* dalam penelitian ini. Model ini dikembangkan menggunakan *library TensorFlow* dan diimplementasikan dalam bahasa pemrograman *Python*. Struktur CNN yang diterapkan dalam penelitian ini tersusun atas sejumlah komponen utama yang bekerja secara berurutan untuk memproses citra satelit dari tahap input hingga output. Proses dimulai dari *input layer*, yang menerima gambar dalam format RGB dengan resolusi tertentu sebagai data masukan. Setelah itu, gambar melewati beberapa *convolutional layers* yang berfungsi mengekstraksi fitur penting seperti tepi, tekstur, dan pola visual lainnya. Setiap lapisan konvolusi menggunakan fungsi aktivasi ReLU (*Rectified Linear Unit*) untuk menambahkan *non-linearitas*, yang memungkinkan model menangkap pola yang lebih kompleks dalam data citra.

Selanjutnya, model menerapkan *pooling layers*, seperti *MaxPooling*, yang berfungsi untuk mereduksi dimensi data tanpa menghilangkan informasi penting.

*Pooling* ini membantu mengurangi beban komputasi sekaligus meningkatkan efisiensi ekstraksi fitur. Dalam penelitian ini, digunakan arsitektur *ResNet50*, yang merupakan salah satu model CNN terdalam dan paling efektif dalam mengenali pola pada gambar. Pada arsitektur *ResNet50*, digunakan *residual connections* atau jalur pintas (*shortcut*) yang memungkinkan transfer informasi langsung dari lapisan sebelumnya ke lapisan berikutnya. Pendekatan ini membantu mengatasi permasalahan *vanishing gradient*, sehingga model dapat belajar lebih baik tanpa kehilangan informasi penting selama pelatihan.

Setelah fitur utama berhasil diekstraksi, data kemudian melewati *fully connected layers*, yang bertugas menggabungkan informasi dari berbagai fitur untuk menghasilkan representasi yang lebih komprehensif. Akhirnya, pada *output layer*, model menggunakan fungsi aktivasi *softmax*, yang mengubah hasil perhitungan menjadi probabilitas untuk masing-masing kelas, yaitu lahan kosong atau pemukiman. Model ini dilatih menggunakan dataset *training* dan dievaluasi menggunakan dataset *validation*. Proses optimasi dilakukan dengan menggunakan *Adam Optimizer*, yang bertujuan untuk meminimalkan fungsi *loss* dan memastikan model mencapai akurasi yang optimal. Dengan arsitektur ini, model diharapkan mampu mengidentifikasi jenis lahan dengan efisiensi dan akurasi tinggi.

### 3.5 Evaluation

Pada tahap evaluasi, model *Convolutional Neural Network* (CNN) diuji menggunakan 500 gambar testing untuk mengukur kemampuannya dalam melakukan identifikasi lahan secara tepat. Dalam penelitian ini, *confusion matrix* digunakan sebagai metode identifikasi untuk menganalisis distribusi prediksi model terhadap data aktual. Matriks ini memuat empat komponen utama, yaitu *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN), yang mendeskripsikan kondisi keberhasilan dan kesalahan prediksi model. Selanjutnya, metrik seperti *accuracy*, *precision*, *recall*, dan *F1-score* dihitung berdasarkan *confusion matrix* untuk menilai performa model secara menyeluruh. *Accuracy* untuk mengukur persentase prediksi model yang benar terhadap keseluruhan data.

*Accuracy* untuk mengukur persentase prediksi model yang benar terhadap keseluruhan data.

$$Accuracy = \frac{True\ Positive + True\ Negative}{True\ Positive + False\ Positive + False\ Negative + True\ Negative} \dots\dots (1)$$

*Precision* adalah persentase dari prediksi yang relevan dari hasil klasifikasi. *Recall*, di sisi lain, adalah persentase dari total hasil yang relevan yang berhasil diidentifikasi dengan benar.

$$Precision = \frac{True\ Positive}{True\ Positif + False\ Positif} \dots\dots (2)$$

*Recall* merepresentasikan tingkat keberhasilan model dalam mendeteksi sampel positif secara akurat, yakni perbandingan antara jumlah sampel positif yang teridentifikasi dengan benar dan jumlah keseluruhan sampel positif, sesuai dengan rumus yang digunakan.

$$Recall = \frac{True\ Positive}{True\ Positif + False\ Negatif} \dots\dots (3)$$

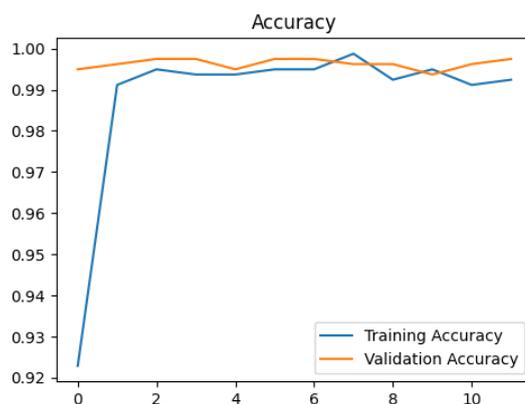
*F1-Score* adalah rata-rata harmonik antara *precision* dan *recall*.

$$F1-Score = \frac{2 \times (Precision \times Recall)}{Precision + Recall} \dots\dots (4)$$

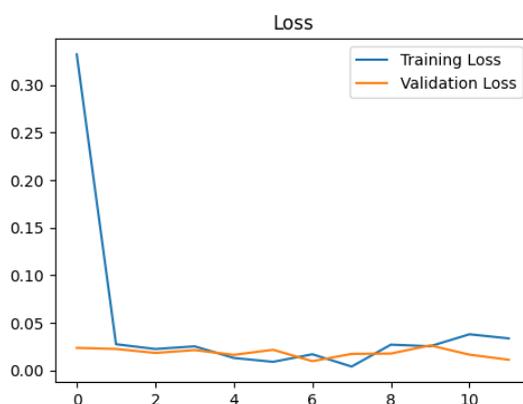
## 4. Hasil dan Pembahasan

### 4.1 Hasil

Dataset yang digunakan dalam penelitian ini terdiri dari 2.080 gambar yang diambil melalui proses *cropping* pada citra *Google Earth*. Gambar ini terdiri dari dua kelas, yaitu pemukiman dan lahan kosong. Pembagian dataset dibagi ke dalam tiga kelompok, yakni 790 gambar digunakan sebagai *data training*, 790 gambar sebagai *data validation*, dan 500 gambar sebagai *data testing*. Model dilatih menggunakan arsitektur ResNet50 selama 50 *epoch*, dan hasil pelatihan divisualisasikan melalui grafik *accuracy* dan *loss*. Pada grafik akurasi (Gambar 3), terlihat bahwa *accuracy training* meningkat dengan cepat di awal pelatihan dan stabil mendekati 100%. *Accuracy validation* juga meningkat, tetapi tidak sehalus *accuracy training* dan mengalami sedikit fluktuasi, terutama di akhir pelatihan. Pada grafik *loss* (Gambar 4), nilai *loss training* menurun tajam di awal pelatihan, lalu melandai dan mendekati nol pada akhir pelatihan. Sementara itu, *loss validation* juga menurun di awal pelatihan, tetapi dengan pola yang tidak semulus x.



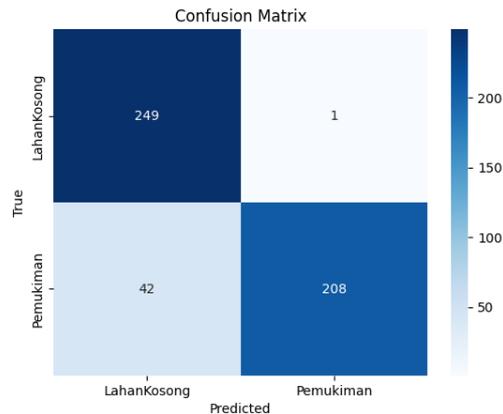
Gambar 3. Grafik *Training* dan *Validation Accuracy*



Gambar 4. Grafik *Training* dan *Validation Loss*

Hasil evaluasi menggunakan *confusion matrix* pada (Gambar 5) menunjukkan bahwa dari 500 gambar *data testing*, model mampu mengidentifikasi 249 (*true negative*) gambar lahan kosong dan 208 (*true positive*) gambar pemukiman dengan benar. Namun, terdapat 1 gambar lahan kosong yang salah diidentifikasi sebagai pemukiman (*false positive*) kemungkinan disebabkan oleh adanya fitur visual tertentu, seperti permukaan tanah yang menyerupai atap bangunan atau keberadaan objek kecil yang mirip dengan struktur pemukiman. Lalu 42 gambar pemukiman yang salah diidentifikasi sebagai lahan kosong (*false negative*) dapat terjadi karena pemukiman dalam gambar tersebut memiliki kepadatan bangunan yang rendah, banyak area terbuka, atau tertutup oleh vegetasi, sehingga model sulit membedakannya dari lahan kosong. Selain itu, perbedaan pencahayaan, bayangan, atau resolusi citra juga dapat menyebabkan model salah mengenali pola yang sebenarnya. Dari hasil ini, akurasi model dihitung sebesar 91.4%, yang menunjukkan bahwa model dapat memprediksi sebagian besar gambar dengan

benar. *Precision* dan *recall* untuk kelas Lahan Kosong masing-masing adalah 85.5% dan 99.6%, sedangkan *precision* dan *recall* untuk kelas Pemukiman adalah 99.5% dan 83.2%.



Gambar 5. *Confusion Matrix*

Berikut perhitungan *matrix* evaluasi.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

$$Accuracy = \frac{249 + 208}{249 + 1 + 42 + 208} = \frac{457}{500} = 0,914 \text{ (91,4\%)}$$

$$Precision = \frac{TP}{TP + FP}$$

$$Precision_{LahanKosong} = \frac{249}{249 + 42} = 0,855$$

$$Precision_{Pemukiman} = \frac{208}{208 + 1} = 0,995$$

$$Recall = \frac{TP}{TP + FN}$$

$$Recall_{LahanKosong} = \frac{249}{249 + 1} = 0,996$$

$$Recall_{Pemukiman} = \frac{208}{208 + 42} = 0,832$$

$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall}$$

$$F1 - Score_{LahanKosong} = 2 \times \frac{0,855 \times 0,996}{0,855 + 0,996} = 2 \times \frac{0,851}{1,851} = 0,919$$

$$F1 - Score_{Pemukiman} = 2 \times \frac{0,995 \times 0,832}{0,995 + 0,832} = 2 \times \frac{0,827}{1,827} = 0,905$$

#### 4.2 Pembahasan

Hasil penelitian ini menunjukkan bahwa metode CNN, khususnya dengan arsitektur ResNet50, memiliki potensi besar dalam mengatasi tantangan identifikasi citra satelit, terutama dalam identifikasi lahan kosong dan pemukiman. Dengan akurasi sebesar 91.4%, model ini menunjukkan performa yang cukup baik dalam mengidentifikasi citra satelit secara otomatis, yang dapat mendukung pengelolaan lahan berbasis data dengan lebih efisien. Namun, kecenderungan model untuk lebih sering mengidentifikasi gambar sebagai lahan kosong dibandingkan pemukiman menjadi tantangan tersendiri. Hal ini terlihat dari *recall* kelas lahan kosong yang mencapai 99.6%, sedangkan *recall* kelas pemukiman hanya 83.2%. Dengan demikian, meskipun model dapat mengenali lahan kosong dengan sangat baik, terdapat risiko yang lebih besar dalam salah mengidentifikasi pemukiman sebagai lahan kosong.

Dalam kaitannya dengan penelitian terdahulu, hasil ini sejalan dengan studi yang telah dilakukan dalam bidang klasifikasi citra satelit menggunakan CNN. Penelitian yang dilakukan oleh Miranda dan Aryuni, yang mengimplementasikan CNN dalam klasifikasi tutupan lahan menggunakan citra satelit Sentinel-2, mampu mencapai akurasi keseluruhan sebesar 98,4%[3]. Studi lainnya oleh Magdalena yang memanfaatkan metode CNN pada citra satelit SPOT-6 untuk klasifikasi tutupan lahan berhasil mencapai akurasi sebesar 95,45%[19]. Penelitian lain yang dilakukan oleh Alvadeano menganalisis perubahan tutupan lahan pada citra satelit Sentinel-2 dengan memanfaatkan *Google Earth Engine* dan CNN, yang menghasilkan performa menjanjikan dalam klasifikasi lahan[20].

Dibandingkan dengan penelitian sebelumnya, hasil ini menunjukkan bahwa *ResNet50* mampu mencapai hasil yang kompetitif, tetapi masih memiliki kelemahan dalam menangani kelas pemukiman dengan lebih akurat. Kinerja identifikasi pemukiman juga berpotensi ditingkatkan melalui pendekatan seperti *fine-tuning* model dan penerapan teknik *augmentasi data* yang lebih beragam. Dengan demikian, penelitian ini tidak hanya membuktikan efektivitas CNN dalam mengidentifikasi citra satelit, tetapi juga memberikan gambaran mengenai tantangan yang masih perlu diselesaikan dalam penerapannya. Penelitian ini memperkuat bukti bahwa *deep learning*, khususnya dengan arsitektur yang lebih dalam seperti *ResNet50*, dapat digunakan secara efektif dalam pemetaan lahan berbasis citra satelit dan dapat menjadi dasar bagi penelitian lebih lanjut untuk meningkatkan performanya.

#### 5. Simpulan

Penelitian ini berhasil mengimplementasikan *deep learning* untuk mengidentifikasi citra satelit menjadi dua kelas, yaitu pemukiman dan lahan kosong, menggunakan algoritma CNN dengan arsitektur *ResNet50*. Model dilatih selama 50 *epoch* dengan hasil sebesar 91,4% pada *data testing*. Hasil evaluasi menunjukkan model mampu mengidentifikasi sebagian besar gambar dengan baik, meskipun masih terdapat kesalahan pada beberapa gambar, terutama pada pemukiman yang salah diidentifikasi sebagai lahan kosong (*false negative*). Grafik akurasi dan loss menunjukkan model belajar dengan baik, meskipun terdapat indikasi *overfitting* ringan. Model ini menunjukkan performa lebih baik dalam mengenali lahan kosong dibandingkan pemukiman, yang sejalan dengan penelitian terdahulu terkait identifikasi citra satelit menggunakan CNN.

Penggunaan dataset yang lebih luas dan beragam serta eksplorasi model *deep learning* lain seperti *EfficientNet* atau *Inception* disarankan untuk digunakan dipenelitian selanjutnya guna meningkatkan kinerja model. Selain itu, penelitian ini dapat diperluas untuk mengidentifikasi perubahan lahan atau area pemukiman dari waktu ke waktu menggunakan data citra satelit *multi-temporal*, sehingga memberikan wawasan tentang dinamika penggunaan lahan di suatu wilayah. Integrasi model dengan sistem informasi geografis (GIS) juga dapat memberikan manfaat praktis bagi perencanaan tata ruang atau pemantauan lingkungan. Dengan adanya penelitian lebih lanjut, diharapkan model ini dapat dioptimalkan untuk meningkatkan dan memperluas pengaplikasiannya dalam berbagai konteks geospasial.

#### Daftar Referensi

- [1] E. D. Meutia, M. Fikri, and R. Munadi, "Analisis Data Citra Satelit Terra Modis Sebagai Indikasi Potensi Ikan di Wilayah Kreung Raya," *J. Komput. Teknol. Inf. dan Elektro*, vol. 7, no. 1, pp. 9–14, 2022, doi: <https://doi.org/10.24815/kitektro.v7i1.25875>.
- [2] A. S. Sriani, Armansyah Nabila, "Deep Learning mengidentifikasi Umur Manusia menggunakan Convolutional Neural Network (CNN)," *J. Inform. dan Tek. Elektro Terap.*,

- vol. 12, no. 3, pp. 1836–1843, 2024, doi: <http://dx.doi.org/10.23960/jitet.v12i3.4457>.
- [3] Eka Miranda and Mediana Aryuni, “Klasifikasi Tutupan Lahan Menggunakan Convolutional Neural Network pada Citra Satelit Sentinel-2 \_ Miranda \_ Sistemasi\_ Jurnal Sistem Informasi,” *J. Sist. Inf.*, vol. 10, no. 2, pp. 323–335, 2021.
- [4] R. Akmal, P. Annand, K. Iswari, M. D. Kautsar, and D. A. Tyas, “Eksplorasi Pemanfaatan Transfer Learning untuk Deteksi Citra Kapal sebagai Pendukung Pengawasan Maritim,” *Bul. Pagelaran Mhs. Nas. Bid. Teknol. Inf. dan Komun.*, vol. 2, no. April, pp. 53–57, 2024.
- [5] Adam Jaelani, “Deteksi dan Klasifikasi Tipe Bangunan pada Citra Satelit menggunakan Metode K Nearest Neighbor”, Skripsi, Program Studi Teknik Informatika, Universitas Islam Negeri Maulana Malik Ibrahim Malang, 2020.
- [6] Theresia Susim dan Cahyo Darujati, “Pengolahan Citra untuk Pengenalan Wajah (Face Recognition) menggunakan OPENCV,” *J. Syntax Admiration*, vol. 2, no. 3, pp. 2722–5356, 2021, doi: <https://doi.org/10.46799/jsa.v2i3.202>.
- [7] R. Setiawan and B. Salam, “Sistem Informasi Geografis Daerah Rawan Kriminalitas di Kabupaten Garut,” *J. Algoritm.*, vol. 19, no. 1, pp. 10–17, 2021, doi: <https://doi.org/10.33364/algoritma/v.18-1.824>.
- [8] D. Suherman, Y. S. Sugandi, and M. Benny, “Aktor Politik dan Kolaborasi Quadruple Helix dalam Pembentukan Daerah Otonomi Baru Kabupaten Garut Selatan Political Actor and Collaboration Quadruple Helix in the Formation of the New Autonomous Region of South Garut Regency,” *J. Ilmu Polit.*, vol. 3, no. 1, pp. 60–87, 2021, doi: <https://doi.org/10.15575/politicon.v3i1.11197>.
- [9] Tika Christy Novian, “Klasifikasi Landsat 8 Oli untuk Tutupan Lahan di Kota Palembang menggunakan Google,” *J. Swarnabhumi (Jurnal Geogr.)*, vol. 6, no. 1, pp. 2622–2701, 2021, doi: <https://doi.org/10.31851/swarnabhumi.v6i1.5105>.
- [10] B. Sasmito, B. H. Setiadji, and R. Isnanto, “Deteksi Kerusakan Jalan Menggunakan Pengolahan Citra Deep Learning di Kota Semarang,” *J. Ilim. Bid. Ilmu Kerekayasaan*, vol. 44, no. 1, pp. 7–14, 2023, doi: <https://doi.org/10.14710/teknik.v44i1.51908>.
- [11] P. A. Nugroho, I. Fenriana, R. Arijanto, and M. Kom, “Implementasi Deep Learning menggunakan Convolutional Neural Network (CNN) pada Ekspresi Manusia,” *J. Algor*, vol. 2, no. 1, pp. 12–20, 2020.
- [12] M. F. Naufal and S. F. Kusuma, “Analisis Perbandingan Algoritma Machine Learning dan Deep Learning untuk Klasifikasi Citra Sistem Isyarat Bahasa Indonesia (SIBI) Comparison Analysis Of Machine Learning And Deep Learning Algorithms For Image Classification Of Indonesian Language Signin,” *J. Teknol. Inf. dan Ilmu Komput.*, vol. 10, no. 4, pp. 873–882, 2023, doi: <https://doi.org/10.25126/jtiik.20241046823>.
- [13] D. R. Pratama, Muhammad Raiza, “Klasifikasi Penutupan Lahan Menggunakan Google Earth Engine dengan Metode Klasifikasi Terbimbing pada Wilayah Penajam Paser Utara,” *J. Jupiter*, vol. 1, no. 1, pp. 637–650, 2022.
- [14] M. A. Setiawan, I. Ariawan, and L. Anzani, “Identifikasi Potensi Lahan Budidaya Udang Di Pesisir Teluk Banten Menggunakan Algoritma CNN,” *J. Comput. Sci. Appl. Informatics*, vol. 4, no. 3, pp. 262–273, 2022, doi: <https://doi.org/10.28926/ilkomnika.v4i3.514>.
- [15] D. W. Trisowati, W. P. Buana, and A. H. Marsuhandi, “Pemetaan Potensi Lahan Jagung Menggunakan Citra Satelit Dan Random Forest Pada Cloud computing Google Earth Engine,” *semnasoffstat*, vol. 1, no. 1, pp. 1001–1011, 2021, doi: <https://doi.org/10.34123/semnasoffstat.v2021i1.889>.
- [16] R. Novidianto, “Berdasarkan Data Citra Multitemporal Landsat-8 dengan Metode Convolutional Neural Network (CNN) dan Rotation Forest Multiclass (Rotfor) Studi Kasus Sampel Survei KSA Kabupaten Poso Berdasarkan Data Citra Multitemporal Landsat-8 dengan Metode Convo”, Tesis, Departemen Statistik, Institut Teknologi Sepuluh November, Surabaya, 2021.
- [17] D. A. Kusuma, A. Dwi, and P. Wicaksono, “Analisis Klastering Dampak Lingkungan Berdasarkan Konsumsi Energi Perusahaan Berbasis Industri 4.0 menggunakan Metode,” *J. Sist. dan Teknol. Inf.*, vol. 9, no. 2, pp. 2620–3227, 2023.
- [18] Ali Khumaidi, “Data Mining For Predicting The Amount Of Coffee Production Using CRISP-DM Method,” *J. Techno Nusa Mandiri*, vol. 17, no. 1, pp. 1–8, 2020, doi: [10.33480/techno.v17i1.1240](https://doi.org/10.33480/techno.v17i1.1240).

- 
- [19] R. Magdalena, S. Saidah, N. Kumalasari, C. Pratiwi, and A. T. Putra, "Klasifikasi Tutupan Lahan Melalui Citra Satelit SPOT-6 dengan Metode Convolutional Neural," *J. Edukasi dan Penelit. Inform.*, vol. 7, no. 3, pp. 335–339, 2021.
- [20] M. A. Alvadeano, "Klasifikasi Perubahan Tutupan Lahan pada Citra Satelit Sentinel-2 menggunakan Google Earth Engine dan Convolutional Neural Network", Skripsi, Fakultas Teknik Industri Universitas Pembangunan Nasional "Veteran" Yogyakarta, 2024.