

IDENTIFIKASI JENIS KENDARAAN BERMOTOR DENGAN ALGORITMA CONVOLUTIONAL NEURAL NETWORKS

Identification of Motor Vehicle Types Using Convolutional Neural Networks Algorithm

Muhammad Athoillah^{1*}, Rani Kurnia Putri²

¹Program Studi Statistika, Universitas PGRI Adi Buana Surabaya

²Program Studi Pendidikan Matematika, Universitas PGRI Adi Buana Surabaya

Jl. Dukuh Menanggal XII, Kota Surabaya, 60234, Jawa Timur, Indonesia

E-mail Corresponding Author: athoillah@unipasby.ac.id

Abstrak: Deteksi jenis kendaraan bermotor memainkan peran sentral dalam pengaturan lalu lintas, penegakan hukum, keamanan, dan sistem transportasi pintar. Dengan kemampuan luar biasa dalam mendeteksi dan mengklasifikasikan kendaraan yang akurat, pihak berwenang dapat mengoptimalkan waktu sinyal lalu lintas, pengelolaan jalur, dan aliran lalu lintas secara efisien. Deteksi jenis kendaraan juga memberikan dukungan penting dalam penegakan peraturan lalu lintas dan memverifikasi kepatuhan kendaraan terhadap batasan tertentu, termasuk jalur kendaraan bersama, tol, dan peraturan parkir. Di sisi keamanan, teknologi ini berperan krusial dalam mengidentifikasi kendaraan mencurigakan, mencegah ancaman, dan meningkatkan keselamatan di area sensitif. Salah satu pendekatan populer dalam mendukung sistem deteksi jenis kendaraan bermotor otomatis adalah menggunakan algoritma *deep learning*, khususnya *Convolutional Neural Network* (CNN). Dengan kemampuannya mengenali pola dan fitur pada citra kendaraan menggunakan struktur jaringan syaraf tiruan, CNN mampu memberikan hasil yang luar biasa. Penelitian ini bertujuan mengembangkan sistem otomatis deteksi jenis kendaraan bermotor dengan menggunakan algoritma CNN. Hasil penelitian menunjukkan kinerja yang sangat baik, dengan rata-rata presisi sebesar 97,00%, sensitivitas/*recall* sebesar 97,60%, spesifisitas sebesar 97,59%, dan akurasi sebesar 97,30%.

Kata Kunci: *Deep Learning*, Jaringan Syaraf Tiruan, Lalu - lintas, *Machine Learning*, Pengolahan Citra Digital

Abstract: Motor vehicle type detection plays a central role in traffic management, law enforcement, security, and smart transportation systems. With its extraordinary ability to accurately detect and classify vehicles, authorities can efficiently optimize traffic signal timing, lane management, and traffic flow. Vehicle type detection also supports enforcing traffic regulations and verifying vehicle compliance with certain restrictions, including shared vehicle lanes, tolls, and parking regulations. On the security side, this technology plays a crucial role in identifying suspicious vehicles, preventing threats, and increasing safety in sensitive areas. One popular approach to support automatic motor vehicle-type detection systems is deep learning algorithms, especially *Convolutional Neural Networks* (CNN). With its ability to recognize patterns and features in-vehicle images using an artificial neural network structure, CNN can provide extraordinary results. This research aims to develop an automatic system for detecting motor vehicle types using the CNN algorithm. The research results showed excellent performance, with an average precision of 97.00%, sensitivity/*recall* of 97.60%, specificity of 97.59%, and accuracy of 97.30%.

Keywords: *Artificial Neural Networks*, *Deep Learning*, *Digital Image Processing*, *Machine Learning*, *Traffic*

1. PENDAHULUAN

Deteksi jenis kendaraan melibatkan identifikasi dan klasifikasi kendaraan berdasarkan berbagai karakteristik dan fitur. Proses ini sangat penting untuk beberapa tujuan, termasuk pengaturan lalu lintas, penegakan hukum, keamanan, dan sistem transportasi pintar. Salah satu aplikasi utama deteksi jenis kendaraan adalah dalam

pengelolaan lalu lintas [1], [2]. Dengan mendeteksi dan mengklasifikasikan kendaraan dengan akurat, pihak berwenang lalu lintas dapat mengumpulkan data berharga tentang pola lalu lintas, volume, dan tingkat kemacetan. Informasi ini membantu dalam mengoptimalkan waktu sinyal lalu lintas, pengelolaan jalur, dan aliran lalu lintas secara keseluruhan. Dengan memahami jenis kendaraan di jalan, pihak berwenang juga dapat merencanakan dan menerapkan langkah-langkah yang sesuai untuk kelas kendaraan tertentu, seperti jalur khusus untuk bus atau rute khusus untuk truk berat [3].

Instansi penegak hukum menggunakan deteksi jenis kendaraan untuk menegakkan peraturan lalu lintas dan memastikan kepatuhannya. Dengan mengidentifikasi tipe kendaraan secara otomatis, pihak berwenang dapat memverifikasi apakah kendaraan tersebut mematuhi batasan atau persyaratan tertentu. Misalnya, beberapa jalan mungkin memiliki batasan berat atau tinggi untuk kendaraan yang lebih besar, dan sistem deteksi dapat memberi peringatan jika terjadi pelanggaran. Selain itu, deteksi jenis kendaraan membantu dalam menegakkan aturan terkait jalur kendaraan bersama (*carpool lanes*), tol, dan peraturan parkir [4]. Dalam hal keamanan, deteksi jenis kendaraan memainkan peran penting dalam memantau dan melindungi ruang publik. Dengan menggunakan sistem pengawasan yang dilengkapi dengan kemampuan deteksi jenis kendaraan, petugas keamanan dapat mengidentifikasi kendaraan yang mencurigakan atau tidak diizinkan. Hal ini membantu mencegah potensi ancaman keamanan, mengelola kontrol akses, dan meningkatkan keselamatan secara keseluruhan di area sensitif seperti bandara, fasilitas pemerintah, dan zona keamanan tinggi [5]. Dengan kata lain, deteksi jenis kendaraan memainkan peran sentral dalam menciptakan sistem transportasi yang efisien, aman, dan terkelola dengan baik.

Selain itu, deteksi jenis kendaraan mendukung berbagai aplikasi komersial. Perusahaan pengiriman dapat memanfaatkan deteksi yang akurat untuk melacak dan mengelola armada mereka dengan efisien. Misalnya, mereka dapat menggunakan deteksi jenis kendaraan untuk memastikan bahwa kendaraan yang sesuai ditugaskan untuk tugas pengiriman tertentu berdasarkan kapasitas muatan atau ukurannya. Perusahaan asuransi juga dapat memanfaatkan teknologi ini untuk menentukan premi yang sesuai berdasarkan jenis kendaraan yang diasuransikan [6].

Deteksi kendaraan bermotor dapat dilakukan dengan cara mempelajari dan mengenali pola dan fitur pada citra kendaraan dimana hal ini dapat dilakukan dengan berbagai macam algoritma *Deep Learning* [7], [8] termasuk salah satunya adalah *Convolutional Neural Network* (CNN) [9]. CNN adalah model pembelajaran *deep learning* yang umumnya digunakan untuk pengenalan gambar dan visi komputer. Struktur CNN terdiri dari lapisan konvolusi untuk mendeteksi fitur visual, lapisan pooling untuk menurunkan ukuran peta fitur, fungsi aktivasi untuk memperkenalkan non-linearitas, dan lapisan terhubung sepenuhnya untuk klasifikasi atau regresi. Proses pelatihan menggunakan *backpropagation*, dimana model belajar dari data berlabel dengan memperbarui bobot dan biasnya. CNN juga dapat memanfaatkan model pra-pelatihan dan transfer *learning* untuk memperoleh representasi yang telah dipelajari sebelumnya [10], [11].

Penggunaan CNN telah mencapai tingkat keberhasilan yang sangat mengesankan. CNN telah membuktikan kemampuannya dalam mengenali objek dengan akurasi yang tinggi dalam membedakan kategori yang kompleks [9]. Beberapa contoh penelitian terbaru terkait dengan algoritma ini adalah penelitian oleh [12] yang membuktikan bahwa dengan CNN dapat memperbaiki akurasi pengenalan citra bila dibandingkan dengan metode tradisional lainnya. Adapula penelitian lain yang dilakukan oleh [13] dimana mereka memanfaatkan algoritma CNN untuk mengenali jenis makanan dari gambar, hasil yang didapatkan dari penelitian ini membuktikan bahwa algoritma tersebut dapat mengenali jenis makanan dengan sangat baik. Sedangkan penelitian lainnya dilakukan oleh [14], dengan fokus pada penggunaan analisis citra berbasis CNN untuk diagnosis malaria, melalui proses pelatihan menggunakan *dataset* citra darah yang berlabel. CNN dapat mengidentifikasi pola-pola yang terkait dengan infeksi malaria, hasilnya, sistem dapat mengenali dan membedakan antara sel darah normal dan sel darah yang terinfeksi parasit malaria dengan tingkat keberhasilan yang tinggi. Tentunya banyak penelitian lainnya pula yang tidak dapat disebutkan semua dalam penelitian ini.

Artikel ini menjelaskan penelitian tentang pembuatan dan analisis hasil dari sistem yang dibuat untuk mengenali jenis kendaraan bermotor dengan memanfaatkan algoritma CNN. Artikel ini memberikan perspektif yang lebih luas terkait dengan penelitian-penelitian yang serupa. Selain studi kasus dan objek penelitian yang berbeda, serta parameter *training* proses yang pastinya tidak sama. Ada pula beberapa perbedaan lain seperti penelitian menggunakan metode pra-proses dengan histogram, berbeda dengan [13] yang melakukan klasifikasi tanpa proses.

2. METODOLOGI

2.1 Data Penelitian

Data yang digunakan dalam penelitian ini adalah *dataset* berupa citra kendaraan roda dua dan roda empat (Gambar 1). Jumlah citra dalam masing-masing kelompok adalah 500 citra, sehingga total *dataset* yang digunakan terdiri dari 1000 citra. Dalam proses tersebut, 90% dari total citra digunakan untuk pelatihan (*training*), sementara sisanya sebesar 10% digunakan sebagai data pengujian (*testing*).



Gambar 1. Contoh *Dataset* Gambar yang Digunakan Dalam Penelitian

Penelitian ini menggunakan metode validasi *hold out* [15]. Keuntungan dari metode ini karena metode ini relatif sederhana dan cepat untuk diimplementasikan sesuai dengan *dataset* yang digunakan dalam penelitian ini. Dalam prosesnya, *dataset* penelitian dibagi menjadi sepuluh bagian secara acak. Dari kesepuluh bagian tersebut, sembilan bagian digunakan sebagai data pelatihan (*training*) dan satu bagian digunakan sebagai data pengujian (*testing*). Proses validasi dilakukan sepuluh kali dengan kombinasi yang berbeda antara kelompok data pelatihan dan pengujian pada setiap percobaan. Hal ini dilakukan untuk memastikan bahwa hasil evaluasi model yang dihasilkan tidak tergantung pada satu pembagian data tertentu, tetapi mewakili kinerja secara umum. Dengan pendekatan ini, penelitian dapat menghasilkan estimasi yang lebih reliabel tentang kinerja model dalam mengklasifikasikan kendaraan roda dua dan roda empat [15].

2.2 Pra-Proses

Penelitian ini dimulai dengan tahap pra-pemrosesan, di mana file-file gambar dalam *dataset* penelitian mulanya diubah menjadi representasi data matriks. Setelah itu, dilakukan perhitungan untuk memperoleh histogram nilai citra tersebut. Histogram adalah metode untuk menghitung frekuensi relatif kemunculan intensitas piksel dalam sebuah citra, sehingga diperoleh pemahaman yang lebih baik tentang distribusi intensitas piksel dalam citra-citra tersebut [16].

Secara matematis, nilai histogram sebuah citra dapat dihitung menggunakan persamaan berikut:

$$h_i = \frac{n_i}{n}, \text{ dengan } i = 0, 1, 2, 3, \dots, L - 1 \quad (1)$$

Di sini, h_i adalah nilai frekuensi kemunculan relatif dari derajat keabuan i , sedangkan n_i mewakili jumlah piksel dalam citra yang memiliki derajat keabuan i . n adalah total jumlah piksel dalam citra, dan L adalah jumlah nilai yang mungkin untuk derajat keabuan [17].

2.3 Proses Identifikasi

Terdapat dua tahap penting dalam proses pengenalan dengan menggunakan algoritma CNN, yaitu *training* dan *testing*. *Training* atau pelatihan dilakukan untuk melatih model CNN dengan tujuan agar model dapat mempelajari pola dan fitur-fitur yang relevan dalam gambar kendaraan. Sedangkan proses *testing* atau uji coba hasil dilakukan dengan memprediksi gambar kendaraan baru. Proses ini melibatkan penerapan gambar ke model CNN untuk mendapatkan prediksi jenis kendaraan yang tepat berdasarkan fitur-fitur yang telah dipelajari selama pelatihan.

Proses pelatihan model CNN melibatkan penyesuaian parameter dan penyusunan lapisan-lapisan CNN untuk memungkinkan model dapat mempelajari pola dan fitur-fitur yang relevan dari gambar kendaraan. Hal ini dilakukan dengan tujuan untuk meningkatkan kemampuan model dalam mengenali dan membedakan jenis kendaraan bermotor.

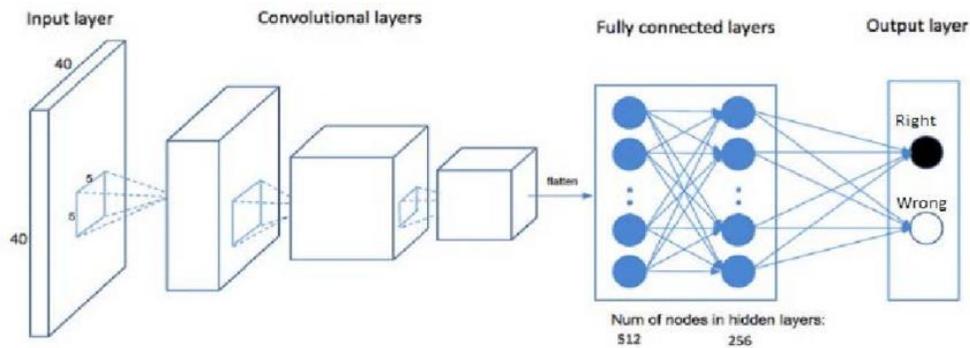
Langkah pertama dari proses algoritma ini ialah menentukan parameter model CNN yang tepat. Parameter ini meliputi ukuran filter, jumlah filter, langkah (*stride*) konvolusi, dan metode pengisian (*padding*) yang digunakan. Dalam domain matematika, konvolusi merupakan operasi yang melibatkan dua fungsi f dan g , menghasilkan sebuah fungsi ketiga h . Terdapat dua jenis utama konvolusi, yakni konvolusi kontinu dan konvolusi diskrit. Dalam konteks pengolahan citra, konsep ini diterapkan dalam domain spasial, sehingga digunakan jenis konvolusi diskrit [18]. Secara umum, operasi ini dapat didefinisikan sebagai berikut:

$$(x, y) = (f * g)(x, y) = \sum_{a=-\infty}^{\infty} \sum_{b=-\infty}^{\infty} f(a, b)g(x - a, y - b) \tag{2}$$

Fungsi $f(x, y)$ merupakan fungsi dari representasi sebuah citra, sementara fungsi $g(x, y)$ merupakan kernel konvolusi atau filter penapis. Selanjutnya, Kernel $g(x, y)$ merupakan jendela yang digerakkan secara berulang pada sinyal *input* $f(x, y)$. Dalam proses ini, hasil konvolusi yang diwakili oleh keluaran fungsi $h(x, y)$ diperoleh dengan melakukan perkalian antara kedua fungsi pada setiap titik dengan kata lain fungsi $h(x, y)$ merupakan fungsi hasil dari perkalian *feature* objek data. Karena citra memiliki ukuran terbatas $M \times N$ dan kernel memiliki ukuran $m \times n$, maka operasi konvolusi pada Persamaan (2) dijelaskan dengan cara berikut Persamaan (3):

$$(f * g)(x, y) = \sum_{a=x-h}^{x+h} \sum_{b=y-w}^{y+h} f(a, b)g(x - a, y - b) \tag{3}$$

Langkah berikutnya adalah penyesuaian parameter, dimana langkah ini memungkinkan model untuk menangkap fitur-fitur dengan skala yang berbeda dan memperoleh representasi yang lebih baik dari gambar kendaraan. Selanjutnya, lapisan-lapisan CNN disusun dengan benar. Lapisan konvolusi pertama digunakan untuk mengidentifikasi fitur-fitur dasar seperti tepi dan garis. Lapisan konvolusi berikutnya dilakukan untuk menangkap fitur-fitur yang semakin kompleks dan abstrak. Pada akhirnya, lapisan *fully connected* digunakan untuk menghubungkan hasil pengolahan dari lapisan konvolusi dengan kelas-kelas kendaraan bermotor yang ingin diidentifikasi [19], [20] sebagai gambaran arsitektur dari algoritma CNN dapat dilihat pada Gambar 2 berikut.



Gambar 2. Arsitektur Algoritma CNN [21]

Selama proses pelatihan, model CNN diberikan data pelatihan yang telah diketahui kelasnya. Model ini kemudian melakukan pengolahan data dengan melalui lapisan-lapisan CNN dan menghasilkan prediksi awal. Perbedaan antara prediksi awal dengan label yang diketahui digunakan untuk menghitung kesalahan (*loss*) yang merupakan indikator sejauh mana model "salah" dalam memprediksi kelas kendaraan. Tujuan dari pelatihan adalah untuk meminimalkan kesalahan tersebut dengan mengoptimalkan parameter model menggunakan algoritma optimisasi seperti *Stochastic Gradient Descent* (SGD) [22]. Proses algoritma SGD adalah mencari nilai θ yang dapat meminimalkan fungsi $J(\theta)$. Untuk menginisialisasi nilai awal θ , digunakan algoritma pencarian dan pada setiap langkah, nilai θ diperbarui secara berulang hingga titik minimum atau nilai J yang paling rendah ditemukan. Proses pembaruan nilai θ dalam setiap langkah menggunakan Persamaan (4). Pembaruan dilakukan secara

bersamaan untuk semua nilai $j = 0, \dots, n$. Parameter α adalah *learning rate* yang mengatur sejauh mana pembaruan nilai dilakukan. Persamaan nilai $J(\theta)$ dapat ditemukan dalam Persamaan (5), dimana L adalah fungsi kerugian yang digunakan pada data pelatihan $(x_1, y_1), \dots, (x_n, y_n)$ dan R adalah regularisasi atau hukuman terhadap kompleksitas model [23].

$$\theta_j = \theta_j - \alpha \frac{\partial y}{\partial x} J\theta \quad (4)$$

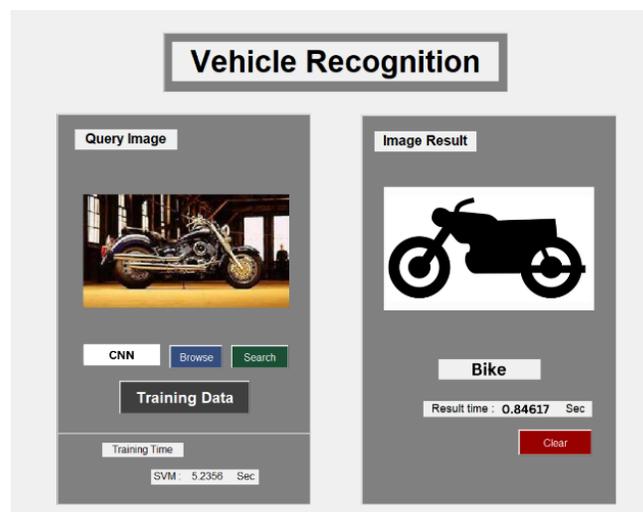
$$J(\theta) = \frac{1}{n} \sum_{i=1}^n L(y_i, f(x)) + \alpha R(W) \quad (5)$$

Proses pelatihan ini dilakukan dengan menggunakan data pelatihan berulang kali (biasanya dalam beberapa *epoch*) untuk memberikan kesempatan kepada model untuk belajar dari data dengan iterasi yang berulang. Selama setiap iterasi, parameter model diperbarui dengan menggunakan algoritma optimisasi yang diatur sebelumnya. Dalam setiap iterasi, model secara bertahap memperbaiki kemampuannya dalam mengenali dan membedakan jenis kendaraan bermotor yang berbeda [20]. Secara keseluruhan, proses pelatihan model CNN melibatkan penyesuaian parameter dan penyusunan lapisan-lapisan CNN, diikuti dengan penggunaan data pelatihan untuk mengoptimalkan model agar dapat mempelajari pola dan fitur-fitur yang relevan dari gambar kendaraan. Hal ini memungkinkan model untuk memiliki kemampuan yang lebih baik dalam mengenali dan membedakan jenis kendaraan bermotor.

3. HASIL DAN PEMBAHASAN

Pada penelitian ini, sejumlah uji coba telah dilakukan untuk mengevaluasi kinerja sistem klasifikasi kendaraan bermotor yang dikembangkan. Evaluasi tersebut melibatkan penghitungan nilai akurasi, presisi, spesifisitas, dan *recall*, yang bertujuan untuk menentukan sejauh mana sistem mampu mengenali dan membedakan citra *input* sebagai kendaraan beroda dua atau beroda empat. Nilai akurasi menggambarkan sejauh mana sistem dapat secara benar mengklasifikasikan citra *input*, dengan membandingkan hasil klasifikasi yang diberikan oleh sistem dengan kebenaran yang sebenarnya. Presisi mengukur tingkat ketepatan sistem dalam mengidentifikasi citra *input* sebagai kendaraan beroda dua atau beroda empat. Spesifisitas, di sisi lain, mengindikasikan seberapa baik sistem dalam mengenali citra kendaraan yang sebenarnya beroda dua dan memperoleh hasil klasifikasi yang benar. *Recall*, atau juga dikenal sebagai sensitivitas, mengukur kemampuan sistem dalam mengidentifikasi citra kendaraan beroda empat dan mengklasifikasikannya secara tepat [24].

Gambar 3 merupakan antarmuka pengguna yang telah dirancang dan dikembangkan dalam penelitian ini. Antarmuka pengguna ini bertujuan untuk mempermudah pengguna dalam mengoperasikan sistem klasifikasi kendaraan bermotor, dan melibatkan elemen-elemen seperti *input* citra, tombol pengoperasian, dan tampilan hasil klasifikasi yang disajikan kepada pengguna.



Gambar 3. User Interface Sistem

Hasil penelitian menunjukkan bahwa algoritma CNN yang digunakan memiliki kinerja yang baik dalam mendeteksi jenis kendaraan bermotor. Dari hasil tersebut, terdapat beberapa karakteristik penting yang menunjukkan kinerja algoritma CNN dalam deteksi jenis kendaraan bermotor, diantaranya:

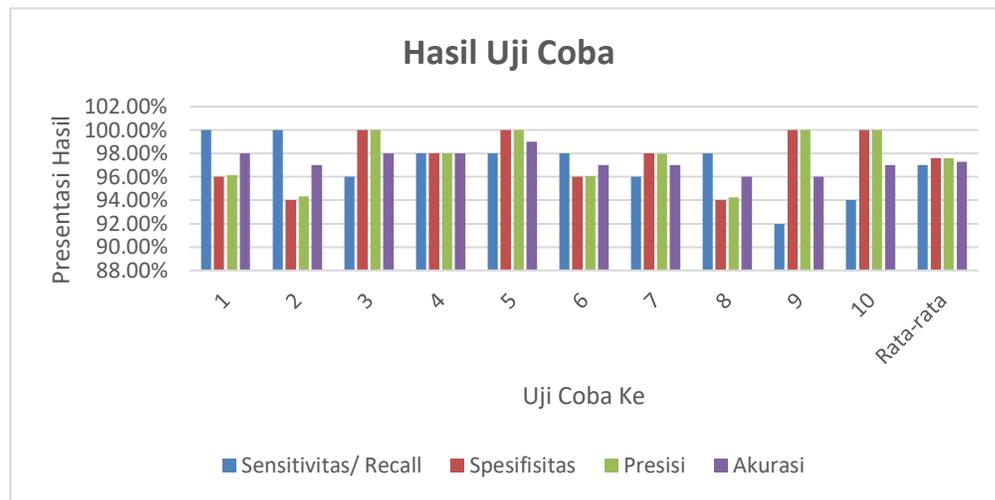
- **Konsistensi Kinerja:** Dalam semua uji coba yang dilakukan, terlihat bahwa algoritma CNN memberikan hasil yang konsisten dan stabil. Hal ini dapat dilihat dari nilai yang relatif serupa untuk setiap metrik evaluasi (sensitivitas, spesifisitas, presisi, dan akurasi) antara uji coba yang berbeda. Misalnya, rata-rata sensitivitas sebesar 97,00%, rata-rata spesifisitas sebesar 97,60%, rata-rata presisi sebesar 97,59%, dan rata-rata akurasi sebesar 97,30%. Konsistensi kinerja ini menunjukkan bahwa algoritma memiliki kemampuan yang stabil dalam mengenali kendaraan bermotor dengan akurasi tinggi.
- **Sensitivitas yang Tinggi:** Sensitivitas atau pemanggilan kembali menunjukkan persentase kendaraan bermotor yang berhasil dideteksi dengan benar dari keseluruhan kendaraan yang ada pada gambar. Dalam data tersebut, rata-rata sensitivitas mencapai 97,00%. Angka ini menunjukkan bahwa algoritma CNN jarang mengabaikan kendaraan yang sebenarnya ada pada gambar, sehingga mampu mendeteksi sebagian besar kendaraan yang hadir.
- **Spesifisitas yang Tinggi:** Spesifisitas mengukur persentase objek yang bukan kendaraan yang berhasil diabaikan dengan benar dari keseluruhan objek yang sebenarnya bukan kendaraan pada gambar. Dalam data tersebut, rata-rata spesifisitas mencapai 97,60%. Hal ini menunjukkan bahwa algoritma memiliki kemampuan yang baik dalam mengklasifikasikan objek yang bukan kendaraan sebagai bukan kendaraan, sehingga jarang memberikan kesalahan dengan menganggap objek lain sebagai kendaraan.
- **Presisi yang Tinggi:** Presisi mengindikasikan persentase kendaraan yang berhasil dideteksi dengan benar dari keseluruhan objek yang terdeteksi sebagai kendaraan pada gambar. Dalam data tersebut, rata-rata presisi mencapai 97,59%. Angka ini menunjukkan bahwa sebagian besar kendaraan yang terdeteksi oleh algoritma memang merupakan kendaraan yang sebenarnya ada pada gambar. Algoritma cenderung memberikan sedikit *false positif*, yaitu mengklasifikasikan objek lain sebagai kendaraan.
- **Akurasi yang Tinggi:** Akurasi mencerminkan tingkat keberhasilan keseluruhan algoritma dalam mengklasifikasikan jenis kendaraan bermotor pada gambar. Dalam data tersebut, rata-rata akurasi mencapai 97,30%.

Karakteristik data tersebut menunjukkan bahwa algoritma CNN yang digunakan dalam penelitian memiliki kinerja yang konsisten dan efektif dalam deteksi jenis kendaraan bermotor. Tabel 1 berikut ini menunjukkan rata-rata kinerja sistem berdasarkan hasil penelitian tiap uji coba dengan pendekatan *hold-out validation*.

Tabel 1. Hasil Uji Coba Penelitian

Uji ke	Sensitivitas/ <i>Recall</i>	Spesifisitas	Presisi	Akurasi
1	100,00%	96,00%	96,15%	98,00%
2	100,00%	94,00%	94,34%	97,00%
3	96,00%	100,00%	100,00%	98,00%
4	98,00%	98,00%	98,00%	98,00%
5	98,00%	100,00%	100,00%	99,00%
6	98,00%	96,00%	96,08%	97,00%
7	96,00%	98,00%	97,96%	97,00%
8	98,00%	94,00%	94,23%	96,00%
9	92,00%	100,00%	100,00%	96,00%
10	94,00%	100,00%	100,00%	97,00%
Rata-rata	97,00%	97,60%	97,59%	97,30%

Untuk memberikan pemahaman yang lebih mudah, berikut adalah gambaran visual dari perbandingan hasil penelitian yang diterjemahkan dari Tabel 1.



Gambar 4. Perbandingan Hasil Uji Coba

4. KESIMPULAN

Penelitian ini mengeksplorasi penggunaan algoritma CNN untuk mengklasifikasikan jenis kendaraan berdasarkan citra. Data yang digunakan dalam penelitian ini terdiri dari citra kendaraan roda dua dan roda empat. Metode validasi *hold-out* digunakan untuk mengevaluasi kinerja algoritma CNN. Hasil penelitian menunjukkan bahwa algoritma CNN memiliki kinerja yang sangat baik dalam mendeteksi kendaraan bermotor. Algoritma ini menunjukkan konsistensi dan kestabilan dalam mengklasifikasikan citra kendaraan. Sensitivitas yang tinggi dari algoritma ini memungkinkan deteksi yang akurat terhadap gambar kendaraan. Sementara itu, spesifisitas yang tinggi memungkinkan algoritma ini untuk mengklasifikasikan dengan benar objek-objek bukan kendaraan. Selain itu, algoritma CNN juga memiliki presisi yang tinggi dalam mengidentifikasi kendaraan yang sebenarnya ada pada gambar. Hal ini ditunjukkan oleh tingkat akurasi yang tinggi dalam mengklasifikasikan jenis kendaraan bermotor.

Dengan demikian, penelitian ini memberikan bukti bahwa penggunaan algoritma CNN dapat meningkatkan sistem klasifikasi kendaraan bermotor secara efektif. Dalam konteks pengembangan sistem klasifikasi kendaraan bermotor, penelitian ini memiliki dampak yang signifikan. Algoritma CNN yang telah dievaluasi dan divalidasi dengan baik mampu mengenali dan membedakan kendaraan roda dua dan roda empat dengan tingkat akurasi yang tinggi. Hal ini dapat memiliki implikasi penting dalam berbagai aplikasi, termasuk sistem keamanan kendaraan, pemantauan lalu lintas, atau pengembangan teknologi otonom kendaraan. Dengan kemampuan mengidentifikasi jenis kendaraan secara otomatis berdasarkan citra, sistem yang diperkuat dengan algoritma CNN ini dapat memberikan kontribusi nyata dalam meningkatkan efisiensi dan keamanan di sektor transportasi.

DAFTAR PUSTAKA

- [1] A. A. Fauzi *et al.*, *Pemanfaatan Teknologi Informasi di Berbagai Sektor Pada Masa Society 5.0*. PT. Sonpedia Publishing Indonesia, 2023.
- [2] Y. Tang, C. Zhang, R. Gu, P. Li, and B. Yang, "Vehicle detection and recognition for intelligent traffic surveillance system," *Multimed Tools Appl*, vol. 76, pp. 5817–5832, 2017.
- [3] L. Suhao, L. Jinzhao, L. Guoquan, B. Tong, W. Huiqian, and P. Yu, "Vehicle type detection based on deep learning in traffic scene," *Procedia Comput Sci*, vol. 131, pp. 564–572, 2018.
- [4] Z. Wang, J. Zhan, C. Duan, X. Guan, P. Lu, and K. Yang, "A Review of Vehicle Detection Techniques for Intelligent Vehicles," *IEEE Trans Neural Netw Learn Syst*, pp. 1–21, 2022, doi: 10.1109/TNNLS.2021.3128968.
- [5] R. Ravish, S. Rangaswamy, and K. Char, "Intelligent traffic violation detection," in *2021 2nd Global Conference for Advancement in Technology (GCAT)*, IEEE, 2021, pp. 1–7.

- [6] H. Canton, “Economic Commission for Europe—UNECE,” in *The Europa Directory of International Organizations 2021*, Routledge, 2021, pp. 132–136.
- [7] A. Gholamhosseinian and J. Seitz, “Vehicle Classification in Intelligent Transport Systems: An Overview, Methods and Software Perspective,” *IEEE Open Journal of Intelligent Transportation Systems*, vol. 2, pp. 173–194, 2021.
- [8] H. Nguyen, L. Kieu, T. Wen, and C. Cai, “Deep learning methods in transportation domain: a review,” *IET Intelligent Transport Systems*, vol. 12, no. 9, pp. 998–1004, 2018.
- [9] M. Manana, C. Tu, and P. A. Owolawi, “A survey on vehicle detection based on convolution neural networks,” in *2017 3rd IEEE international conference on computer and communications (ICCC)*, IEEE, 2017, pp. 1751–1755.
- [10] F. Chollet, *Deep learning with Python*. Simon and Schuster, 2021.
- [11] I. Goodfellow, Y. Bengio, and A. Courville, *Deep learning*. MIT press, 2016.
- [12] G. Lou and H. Shi, “Face image recognition based on convolutional neural network,” *China Communications*, vol. 17, no. 2, pp. 117–124, 2020, doi: 10.23919/JCC.2020.02.010.
- [13] Y. Lu, “Food image recognition by using convolutional neural networks (cnns),” *arXiv preprint arXiv:1612.00983*, 2016.
- [14] Z. Liang *et al.*, “CNN-based image analysis for malaria diagnosis,” in *2016 IEEE international conference on bioinformatics and biomedicine (BIBM)*, IEEE, 2016, pp. 493–496.
- [15] R. M. Oxford and L. G. Daniel, “Basic Cross-Validation: Using the " Holdout" Method To Assess the Generalizability of Results.,” *Research in the Schools*, vol. 8, no. 1, pp. 83–89, 2001.
- [16] Y. N. Nabuasa, “Pengolahan Citra Digital Perbandingan Metode Histogram Equalization Dan Spesification Pada Citra Abu-Abu,” *Jl Komputer, UN Cendana, C. Digital, and E. Histogram*, vol. 7, no. 1, pp. 87–95, 2019.
- [17] M. Athoillah, “Klasifikasi Kendaraan Bermotor Dengan Multi Kernel Support Vector Machine,” *Buana Matematika : Jurnal Ilmiah Matematika dan Pendidikan Matematika*, vol. 8, no. 1 SE-, pp. 1–8, Jun. 2018, doi: 10.36456/buanamatematika.v8i1:.1515.
- [18] M. Zufar and B. Setiyono, “Convolutional neural networks untuk pengenalan wajah secara real-time,” *Jurnal Sains dan Seni ITS*, vol. 5, no. 2, p. 128862, 2016.
- [19] K. O’Shea and R. Nash, “An introduction to convolutional neural networks,” *arXiv preprint arXiv:1511.08458*, 2015.
- [20] S. Albawi, T. A. Mohammed, and S. Al-Zawi, “Understanding of a convolutional neural network,” in *2017 international conference on engineering and technology (ICET)*, Ieee, 2017, pp. 1–6.
- [21] J. Mlyahilu, Y. Kim, and J. Kim, “Classification of 3D Film Patterns with Deep Learning,” *Journal of Computer and Communications*, vol. 07, pp. 158–165, Jan. 2019, doi: 10.4236/jcc.2019.712015.
- [22] J. Wu, “Introduction to convolutional neural networks,” *National Key Lab for Novel Software Technology. Nanjing University. China*, vol. 5, no. 23, p. 495, 2017.
- [23] F. T. Admojo and Y. I. Sulistya, “Analisis performa algoritma Stochastic Gradient Descent (SGD) dalam mengklasifikasi tahu berformalin,” *Indonesian Journal of Data and Science*, vol. 3, no. 1, pp. 1–8, 2022.
- [24] A. Baratloo, M. Hosseini, A. Negida, and G. el Ashal, “Part 1: Simple Definition and Calculation of Accuracy, Sensitivity and Specificity,” *Emerg (Tehran)*, vol. 3, no. 2, pp. 48–49, 2015.