

Sistem Identifikasi Tanda Nomor Kendaraan Bermotor Indonesia Berbasis Artificial Neural Network

Laras Prameswari Ristantyo¹; Herminarto Nugroho^{1*}; Wahyu Agung Pramudito¹

1. Program Studi Teknik Elektro, Universitas Pertamina, Kebayoran, Jakarta Selatan, DKI Jakarta 12220, Indonesia

^{*)}Email: herminarto.nugroho@universitaspertamina.ac.id

Received: 18 April 2022 | Accepted: 5 Desember 2022 | Published: 5 Desember 2022

ABSTRACT

License plates is one of a prerequisite which have to be owned on a vehicle as an identity and registration mark. Along with the increasing number of vehicles every year in Indonesia, a system which can detect a license plate as an object and recognize the characters in a license plate automatically is needed in order to facilitate work in terms of parking system management, as well as electronic traffic law enforcement. In this paper, a total of 6541 Indonesian license plates image data has been obtained using the Convolutional Neural Network (CNN) method to detect a license plate and the Optical Character Recognition (OCR) method to recognize characters on license plates which contains of letters and numbers. Convolutional Neural Network is implemented to detect the license plates due to Convolutional Neural Network has good performance in machine learning problems, especially in the application of image data. Optical Character Recognition is implemented for character recognition in license plates due to the Character Recognition OCR algorithm can convert characters from the image of license plate into a text resulting 84.59% system accuracy.

Keywords: object detection, character recognition, convolutional neural network, optical character recognition, license plates

ABSTRAK

Tanda Nomor Kendaraan Bermotor (TNKB) merupakan prasyarat yang wajib dimiliki pada kendaraan bermotor yang berfungsi sebagai identitas dan tanda registrasi yang sesuai dengan Surat Tanda Nomor Kendaraan (STNK). Seiring dengan meningkatnya jumlah kendaraan bermotor tiap tahun, maka diperlukan sistem yang dapat mendeteksi objek Tanda Nomor Kendaraan Bermotor serta mengenali karakter yang ada pada Tanda Nomor Kendaraan Bermotor secara otomatis agar dapat mempermudah pekerjaan dalam hal manajemen sistem parkir, maupun sistem tilang elektronik. Pada jurnal ini, digunakan total 6541 data citra Tanda Nomor Kendaraan Bermotor Indonesia yang telah diolah menggunakan metode Convolutional Neural Network (CNN) untuk mendeteksi keberadaan objek dan metode Optical Character Recognition (OCR) untuk mengenali karakter pada objek yang berupa huruf dan angka. Convolutional Neural Network diimplementasikan untuk mendeteksi keberadaan objek TNKB dikarenakan CNN memiliki kinerja yang baik dalam permasalahan pembelajaran mesin (machine learning) khususnya dalam pengaplikasian pada data citra. Optical Character Recognition diimplementasikan untuk pengenalan karakter pada objek dikarenakan algoritma Optical Character Recognition dapat mengkonversi karakter pada citra menjadi sebuah teks dengan akurasi sistem sebesar 84.59%.

Kata kunci: deteksi objek, pengenalan karakter, convolutional neural network, optical character recognition, tanda nomor kendaraan bermotor

1. PENDAHULUAN

Setiap unit kendaraan bermotor di Indonesia wajib dilengkapi dengan Tanda Nomor Kendaraan Bermotor. Dasar hukum pemakaian Tanda Nomor Kendaraan Bermotor pada setiap unit kendaraan adalah Undang-Undang Republik Indonesia Nomor 22 Tahun 2009 Tentang Lalu Lintas Dan Angkutan Jalan [1]. Dengan jumlah total unit kendaraan yang meningkat sekitar 5.12% dari tahun 2018 ke 2019, maka diperlukan sistem yang dapat mendeteksi dan mengenali karakter pada Tanda Nomor Kendaraan Bermotor secara otomatis untuk mengetahui identitas dari kendaraan secara optimal, mengurangi kesalahan manusia dalam sistem parkir, serta mendukung kegiatan ketertiban lalu lintas dengan adanya tilang otomatis. Metode *Convolutional Neural Network* dipilih untuk mendeteksi objek dikarenakan cara kerjanya mirip dengan cara manusia melihat atau menghasilkan persepsi visual [2]. Untuk pengenalan karakter pada Tanda Nomor Kendaraan Bermotor, digunakan metode *Optical Character Recognition* dikarenakan metode tersebut dapat mengenali karakter yang berupa karakter yaitu huruf dan angka pada suatu objek yang kemudian dapat diterjemahkan ke bentuk teks. Penelitian terkait pendeteksian objek Tanda Nomor Kendaraan Bermotor telah dikembangkan sebelumnya dengan mengimplementasikan metode *Convolutional Neural Network*. Metode tersebut diaplikasikan untuk mendeteksi keberadaan objek dan mengklasifikasikan 37 kelas yang terdiri dari 26 huruf dan 10 angka, serta 1 plat pada objek Tanda Nomor Kendaraan Bermotor Indonesia yang menghasilkan *loss function* hasil pelatihan sebesar 0.4603 [3]. Untuk implementasi terkait pengenalan karakter menggunakan metode *Optical Character Recognition* [4], hasil pengujian pada citra plat nomor menghasilkan pembacaan karakter pada plat nomor Irak dengan performa sistem mencapai 86.6% [5]. Berdasarkan uraian diatas, sistem yang dirancang adalah sistem untuk mendeteksi keberadaan dan mengenali karakter pada Tanda Nomor Kendaraan Bermotor dengan mengaplikasikan metode *Convolutional Neural Network* dan *Optical Character Recognition*.

Berdasarkan Undang-Undang Nomor 28 Tahun 2009 Tentang Pajak Daerah dan Retribusi Daerah, pada Pasal 1 berbunyi : “Kendaraan Bermotor adalah semua kendaraan beroda beserta gandengannya yang digunakan di semua jenis jalan darat, dan digerakkan oleh peralatan teknik berupa motor atau peralatan lainnya yang berfungsi untuk mengubah suatu sumber daya energi tertentu menjadi tenaga gerak kendaraan bermotor yang bersangkutan, termasuk alat-alat berat dan alat-alat besar yang dalam operasinya menggunakan roda dan motor dan tidak melekat secara permanen serta kendaraan bermotor yang dioperasikan di air [6].”


Citra digital merupakan representasi dari matriks dari gambar 2 dimensi yang menggunakan bilangan terbatas untuk elemen titik sel atau pada umumnya disebut dengan piksel (elemen gambar). Masing-masing piksel direpresentasikan dengan nilai numerik [7]. Citra digital yang umum digunakan dapat dikategorikan menjadi 3 bagian berdasarkan format penyimpanan warnanya, antara lain citra biner (monokrom), citra *grayscale*, dan citra warna RGB (*true color*) [8].

Pengolahan citra digital adalah penggunaan komputer digital untuk melakukan beberapa urutan atau serangkaian tindakan pemrosesan pada gambar [9]. Pengolahan citra merupakan proses mengolah piksel pada citra digital. Proses dari pengolahan citra dapat dimulai dengan pengambilan citra, kemudian perbaikan kualitas citra, hingga proses representatif citra [10].

Pendeteksian objek merupakan salah satu teknik *computer vision* yang bertujuan untuk menemukan lokasi dari suatu objek dalam gambar maupun video. Tujuan utama dari deteksi objek adalah untuk mereplikasi kecerdasan menggunakan komputer [11]. Dalam pengolahan citra digital, pendeteksian objek merupakan proses yang dilakukan untuk menentukan keberadaan dari suatu objek tertentu yang berada pada suatu citra digital [12].


Pengenalan pola merupakan disiplin ilmu cabang kecerdasan buatan yang bertujuan untuk mengklasifikasikan objek ke dalam suatu kategori atau kelas. Pengklasifikasian objek dilakukan agar objek dapat dikenali sesuai dengan ciri-cirinya. Bergantung pada penerapannya, objek-objek tersebut dapat berupa gambar atau sinyal dalam bentuk gelombang atau jenis pengukuran apapun yang diperlukan untuk diklasifikasi [13].

Jaringan syaraf tiruan (*artificial neural network*) merupakan sistem pengolahan informasi yang mempunyai karakteristik kinerja tertentu yang mereplikasi cara kerja jaringan syaraf biologis pada manusia [14], [15], [16]. Contoh arsitektur *artificial neural network* direpresentasikan pada Gambar 1:



Gambar 1. Arsitektur Jaringan Syaraf Tiruan [17]

Pembelajaran mendalam (*deep learning*) mengacu pada jaringan syaraf tiruan (*artificial neural network*) yang memiliki banyak lapisan. Salah satu pembelajaran dalam yang cukup populer dan secara umum digunakan untuk deteksi objek dan pengenalan pola adalah *Convolutional Neural Network* (CNN). Istilah CNN berasal dari operasi linier matematis antara matriks yang disebut dengan konvolusi. CNN memiliki banyak lapisan (*layer*). Lapisan tersebut terdiri dari *convolutional layer*, *non linearity layer*, *pooling layer*, dan *fully-connected layer* [18]. Contoh arsitektur *convolutional neural network* direpresentasikan pada Gambar 2:




Gambar 2. Contoh Arsitektur *Convolutional Neural Network* [19]

Metode yang dapat digunakan untuk menerjemahkan karakter yang ada pada suatu citra menjadi bentuk teks adalah *Optical Character Recognition* (OCR). *Input* dari suatu OCR adalah citra, kemudian diproses sehingga menjadi *output* yang berupa teks [20].

2. METODE PENELITIAN

Berikut merupakan visualisasi dari arsitektur jaringan untuk sistem yang dirancang:




Gambar 3. Visualisasi Arsitektur Jaringan pada Perancangan Sistem

Perancangan sistem dilakukan secara simulasi terhadap objek citra Tanda Nomor Kendaraan Indonesia. *Output* dari sistem ini adalah berupa persen keakuratan dari pendeteksian objek yang dan teks yang berupa pembacaan hasil pengenalan karakter pada objek.

Tabel 1. *Output* pada Sistem yang Dirancang

Keterangan	<i>Output</i>
Mendeteksi objek yang berupa citra TNKB Indonesia	Persen keakuratan dari sistem untuk mendeteksi TNKB dan kecepatan pengujian
Mengenali karakter yang berupa angka dan huruf pada citra TKNB	Teks hasil pengenalan karakter huruf dan angka pada TNKB dan kecepatan pengujian

Cara kerja sistem secara keseluruhan dapat direpresentasikan pada diagram alir sebagai berikut:



Gambar 4. Diagram Alir Cara Kerja Sistem

Peralatan dan bahan penunjang untuk merancangan sistem ditunjukkan pada Tabel 2:

Tabel 2. Peralatan dan Bahan untuk Merancang Sistem

Alat dan Bahan	Jumlah
Personal Computer (PC)	1 set
Perangkat Lunak Jupyter Notebook dan Library	1 unit
Framework TensorFlow	1 unit

Pembagian untuk set data latih dan data uji dengan rasio 80%:20% dan 70%:30% ditentukan dengan menerapkan pertimbangan sebagai berikut [21]:

- Rasio pembagian data latih harus lebih banyak daripada data uji.
- Jumlah data latih yang banyak dapat membuat model mempelajari lebih banyak permasalahan sehingga dapat menghasilkan performa pengujian yang baik.
- Jumlah data uji yang banyak dapat memberi perancangan pemahaman bahwa model dapat melakukan generalisasi ke data yang tidak terlihat dengan baik.

Total set data yang digunakan adalah sebanyak 6541 citra yang diambil dari internet dan diambil langsung dengan menggunakan *camera smartphone*. Rasio pembagian data latih dan data uji pada perancangan sistem ini dibagi menjadi 2 studi kasus sebagai berikut :

Tabel 3. Rasio Pembagian Set Data Latih dan Data Uji

Studi Kasus	Data Latih	Data Uji
Studi Kasus 1	80%	20%
Studi Kasus 2	70%	30%


Berdasarkan rasio pembagian set data latih dan data uji pada Tabel 3, maka berikut merupakan jumlah dari data latih dan data uji untuk masing-masing studi kasus:

Tabel 4. Data Latih dan Data Uji

Studi Kasus	Data Latih	Data Uji	Jumlah
Studi Kasus 1	5233	1308	6541
Studi Kasus 2	4579	1962	6541

3. HASIL DAN PEMBAHASAN


Berdasarkan hasil yang telah diperoleh, dapat disimpulkan bahwa penentuan rasio untuk membagi jumlah data pada data latih dan data uji dapat mempengaruhi akurasi sistem yang ditunjukkan dalam grafik batang sebagai berikut:



Gambar 5. Perbandingan Akurasi Sistem

Fungsi yang digunakan untuk membandingkan performa sistem dengan 2 studi kasus yang berbeda adalah akurasi. Pada Gambar 5 ditunjukkan bahwa akurasi sistem dari kedua studi kasus tidak jauh berbeda secara signifikan. Pada studi kasus 1 dengan rasio perbandingan data latih dan data uji adalah sebesar 80%:20%, akurasi sistem adalah mencapai 84.59%. Sedangkan pada studi kasus 2 dengan rasio data latih dan data uji adalah sebesar 70%:30%, akurasi sistem adalah 82.89%. Hal ini disebabkan oleh jumlah data latih pada studi kasus 1 lebih banyak yaitu sejumlah 5233 data citra, sedangkan pada studi kasus 2 jumlah data latih hanya sejumlah 4579 data citra. Dapat disimpulkan bahwa semakin banyak data pada proses pelatihan, maka dapat meningkatkan akurasi sistem menjadi lebih baik.

Selain akurasi sistem, rasio pembagian data latih dan data uji juga mempengaruhi rata-rata akurasi pada pengujian yaitu sebagai berikut:




Gambar 6. Perbandingan Rata-Rata Akurasi pada Pengujian

Proses pendeteksian keberadaan Tanda Nomor Kendaraan Bermotor dan pengenalan karakter huruf dan angka pada Tanda Nomor Kendaraan Bermotor dilakukan dengan melakukan pengujian pada set data yang tidak disertakan dalam set data latih dan juga tidak diberi label. Hal ini bertujuan agar dapat mengukur performa sistem dalam mempelajari data yang belum pernah dilihat sebelumnya. Pengujian juga dibagi menjadi 2 jenis yaitu yang pertama adalah pengujian secara *non-real time* atau yang dimaksud dengan pengujian citra TNKB yang berada pada *test folder* dan yang kedua adalah secara *real time* atau menggunakan Webcam sebagai *hardware*. Melalui kedua jenis

pengujian tersebut, didapatkan hasil yang dijabarkan dalam bentuk grafik pada Gambar 4. Dari hasil pengujian, rata-rata akurasi pada studi kasus 1 dengan rasio pembagian set data latih dan data uji sebesar 80%:20% lebih tinggi yaitu sebesar 78.46% dibandingkan dengan rata-rata akurasi pada studi kasus 2 sebesar 72% dengan rasio pembagian set data latih dan data uji sebesar 70%:30% . Hal ini juga berlaku pada pengujian pendeteksian Tanda Nomor Kendaraan Bermotor secara *real time* menggunakan Webcam. Untuk pengujian pengenalan karakter pada Tanda Nomor Kendaraan Bermotor secara *non-real time*, rata-rata akurasi pengenalan huruf dan angka pada studi kasus 1 dengan rasio pembagian set data latih dan data uji sebesar 80%:20% lebih tinggi yaitu sebesar 97.96% dibandingkan dengan rata-rata akurasi pada studi kasus 2 sebesar 91.55% dengan rasio pembagian set data latih dan data uji sebesar 70%:30%. Hal yang sama juga berlaku pada pengujian pengenalan huruf dan angka pada Tanda Nomor Kendaraan Bermotor secara *real time* menggunakan Webcam.

Rata-rata kecepatan juga menjadi parameter dalam pengujian pendeteksian keberadaan Tanda Nomor Kendaraan Bermotor dan pengenalan karakter pada TNKB yang ditunjukkan pada Gambar 7.



Gambar 7. Perbandingan Rata-Rata Kecepatan Pengujian

Berdasarkan hasil pengujian kecepatan yang hasilnya telah disajikan pada grafik batang yang ada pada Gambar 7, dapat ditarik kesimpulan bahwa semakin banyak data uji, semakin besar pula waktu yang dibutuhkan untuk melakukan pengujian. Namun, semakin lama waktu yang diperlukan untuk proses pengujian, semakin tinggi pula akurasi yang diperoleh untuk mendeteksi keberadaan TNKB dan pengenalan karakter berupa huruf dan angka pada TNKB.

4. KESIMPULAN DAN SARAN

Berdasarkan hasil perancangan yang dilakukan dan hasil simulasi yang diperoleh mengenai identifikasi Tanda Nomor Kendaraan Bermotor (TNKB) Indonesia berbasis *Artificial Neural Network* (ANN), dapat diambil kesimpulan yaitu perbandingan rasio set data latih dan data uji mempengaruhi hasil keakuratan sistem. Dengan rasio set data latih dan data uji sebesar 80:20 tingkat akurasi yang tinggi yaitu sebesar 84.59%, sedangkan rasio set data sebesar 70:30 menghasilkan akurasi sebesar 82.89%. Tingkat akurasi yang rendah pada hasil pendeteksian dan kesalahan (*error*) pada pengenalan karakter Tanda Nomor Kendaraan Bermotor dapat terjadi karena beberapa faktor antara lain kualitas resolusi citra Tanda Nomor Kendaraan Bermotor yang rendah. Dalam penelitian ini, resolusi citra TNKB adalah 300 dpi. Selain itu faktor dari pengambilan citra Tanda Nomor Kendaraan Bermotor juga mempengaruhi hasil pengenalan karakter pada objek. Citra Tanda Nomor

Kendaraan Bermotor yang diambil dari samping atau secara miring dan terlalu jauh dapat menyebabkan karakter huruf dan angka pada Tanda Nomor Kendaraan Bermotor tidak dapat dikenali secara keseluruhan. Dalam penelitian ini, posisi citra diambil dari berbagai variasi arah dan jarak sehingga terdapat karakter pada citra yang tidak dikenali dengan baik.

Saran yang dapat diberikan untuk memperbaiki dan kelanjutan untuk perancangan ini antara lain yaitu proses pelabelan set data citra TNKB dapat dilakukan secara lebih baik agar hasil Tanda Nomor Kendaraan Bermotor yang terdeteksi dapat memiliki akurasi yang tinggi dan dapat dikenali karakternya dengan lebih jelas, serta posisi Tanda Nomor Kendaraan Bermotor yang ingin diidentifikasi tidak miring dan terlalu jauh agar dapat dideteksi dan dikenali karakternya secara jelas.

DAFTAR PUSTAKA

- [1] P. R. Indonesia, Undang-undang Republik Indonesia nomor 22 tahun 2009 tentang lalu lintas dan angkutan jalan. 2009.
- [2] H. Nugroho, M. Susanty, A. Irawan, M. Koyimatu, and A. Yunita, "Fully convolutional variational autoencoder for feature extraction of fire detection system," *J. Ilmu Komput. dan Inf.*, vol. 13, no. 1, pp. 9–15, 2020.
- [3] N. H. Harani, C. Prianto, and M. Hasanah, "Deteksi Objek Dan Pengenalan Karakter Plat Nomor Kendaraan Indonesia Menggunakan Metode Convolutional Neural Network (CNN) Berbasis Python," *J. Tek. Inform.*, vol. 11, no. 3, pp. 47–53, 2019.
- [4] M. Susanty and H. Nugroho, "OPTICAL CHARACTER RECOGNITION IMPLEMENTATION FOR ADMISSION SYSTEM IN UNIVERSITAS PERTAMINA," *Simetris J. Tek. Mesin, Elektro dan Ilmu Komput.*, vol. 11, no. 1, pp. 165–170, 2020.
- [5] S. S. Omran and J. A. Jarallah, "Iraqi car license plate recognition using OCR," in *2017 annual conference on new trends in information & communications technology applications (NTICT)*, 2017, pp. 298–303.
- [6] P. R. Indonesia, Undang-undang Republik Indonesia nomor 28 tahun 2009 tentang pajak daerah dan retribusi daerah. 2009.
- [7] V. Tyagi, *Understanding digital image processing*. CRC Press, 2018.
- [8] P. N. Andono, T. Sutojo, and others, *Pengolahan citra digital*. Penerbit Andi, 2017.
- [9] M. P. Ekstrom, *Digital image processing techniques*, vol. 2. Academic Press, 2012.
- [10] A. Basuki, N. Ramadijanti, and S. Kom, "Metode Numerik dan Algoritma Komputasi," 2005.
- [11] Z.-Q. Zhao, P. Zheng, S. Xu, and X. Wu, "Object detection with deep learning: A review," *IEEE Trans. neural networks Learn. Syst.*, vol. 30, no. 11, pp. 3212–3232, 2019.
- [12] D. Nagataries, S. Hardiristanto, M. H. Purnomo, and A. A. G. Klasik, "Deteksi Objek pada Citra Digital Menggunakan Algoritma Genetika untuk Studi Kasus Sel Sabit," *Mhs. Jur. Tek. Elektro FTI Inst. Teknol. Sepuluh Novemb. Surabaya*. Diambil dari <http://digilib.its.ac.id/deteksi-objek-pada-citra-digital-menggunakan-algoritma-genetika-untuk-studi-kasus-sel-sabit-21993.html>, 2012.
- [13] S. Theodoridis and K. Koutroumbas, *Pattern recognition*. Elsevier, 2006.
- [14] L. V Fausett, *Fundamentals of neural networks: architectures, algorithms and applications*. Pearson Education India, 2006.
- [15] H. Nugroho, "Tuning of Optical Beamforming Networks: A Deep Learning Approach." 2015.
- [16] M. Susanty, S. Sahrul, E. Setiawan, and H. Nugroho, "DEEP LEARNING IMPLEMENTATION FOR EMPLOYEE ATTENDANCE SYSTEM IN UNIVERSITAS PERTAMINA," *Simetris J. Tek. Mesin, Elektro dan Ilmu Komput.*, vol. 11, no. 2, pp. 462–468, 2020.

-
- [17] N. Gupta and others, "Artificial neural network," *Netw. Complex Syst.*, vol. 3, no. 1, pp. 24–28, 2013.
 - [18] S. Albawi, T. A. Mohammed, and S. Al-Zawi, "Understanding of a convolutional neural network," in 2017 international conference on engineering and technology (ICET), 2017, pp. 1–6.
 - [19] P. Kim, "Convolutional neural network," in *MATLAB deep learning*, Springer, 2017, pp. 121–147.
 - [20] P. Hidayatullah, N. Syakrani, I. Suhartini, and W. Muhlis, "Optical character recognition improvement for license plate recognition in Indonesia," in 2012 Sixth UKSim/AMSS European Symposium on Computer Modeling and Simulation, 2012, pp. 249–254.
 - [21] R. Draelos, "Best use of train/val/test splits, with tips for medical data," *Glas. Box Artif. Intell. Med.* <https://glassboxmedicine.com/2019/09/15/best-use-of-train-val-test-splits-with-tips-for-medical-data>, 2019.