

JURNAL TECHNOLOGIE

E-ISSN : XXXX | P-ISSN : XXXX
VolumeXX, NumberX, Bulanxx 2025, pp. 36-43

IDENTIFIKASI TULISAN TANGAN MENJADI TEKS DIGITAL MENGUNAKAN ALGORITMA CNN

Rudy Putra Tantowi¹, Saut Dohot Siregar^{2*}

^{1,2}Universitas Prima Indonesia
rudy.phan04@gmail.com¹, sautdohotsiregar@gmail.com²

ARTICLE INFO

Article History

Received : January 2026

Revised : January 2026

Accepted : January 2026

Keywords

handwriting recognition
convolutional neural network
residual connection
deep learning

ABSTRACT

Digitization of handwritten documents is an essential component in digital transformation in various sectors. This research aims to develop a handwriting identification system into digital text using the Convolutional Neural Network (CNN) algorithm with architectural modifications in the form of adding residual connections. An experimental quantitative approach is applied with a dataset containing 50,000 handwritten images obtained from 500 respondents with diverse demographic distributions. Experimental results show that the proposed CNN architecture achieves 93.5% accuracy on the test dataset, an increase of 3.8% compared with conventional CNN. Performance analysis by character category revealed the highest accuracy in recognition of numbers (96.8%) and capital letters (95.3%), while special characters showed relatively lower accuracy (89.4%). The implementation of batch normalization and data augmentation strategies proved effective in improving the generalization of the model to variations in handwriting styles. Although the inference time increases slightly, this trade-off is acceptable considering the significant increase in accuracy. The main contribution of this research is the development of a robust handwriting recognition system with potential implementation in various applications such as digitizing historical archives, administrative document processing, and security systems based on handwriting biometrics.

Pendahuluan

Digitalisasi informasi merupakan kebutuhan yang semakin mendesak di era revolusi industri 4.0. Salah satu tantangan signifikan dalam proses digitalisasi adalah konversi dokumen berbasis tulisan tangan menjadi format digital yang dapat diolah komputer. Meskipun kemajuan teknologi telah memungkinkan pengalihan berbagai jenis data ke dalam bentuk digital, identifikasi tulisan tangan

secara akurat masih menjadi permasalahan kompleks yang memerlukan pendekatan khusus (Tilasefana & Putra, 2023). Tulisan tangan manusia memiliki karakteristik yang sangat bervariasi dan tidak terstandarisasi, sehingga proses identifikasinya jauh lebih rumit dibandingkan dengan pengenalan teks cetak konvensional. Sistem pengenalan tulisan tangan atau Handwritten Text Recognition (HTR) memiliki peran strategis dalam berbagai bidang seperti digitalisasi arsip bersejarah, otomatisasi pemrosesan dokumen administrasi, sistem keamanan berbasis tanda tangan, hingga pengembangan antarmuka pengguna yang lebih intuitif pada perangkat teknologi modern. Keberhasilan sistem HTR sangat ditentukan oleh kemampuannya dalam mengidentifikasi pola-pola kompleks dan karakteristik unik dari tulisan tangan yang memiliki variasi bentuk, kemiringan, ukuran, serta gaya penulisan yang berbeda-beda (Pradana & Wijiyanto, 2024).

Dalam beberapa tahun terakhir, pendekatan berbasis pembelajaran mesin (machine learning) telah menunjukkan kemajuan signifikan dalam mengatasi permasalahan pengenalan tulisan tangan. Khususnya, metode deep learning seperti Convolutional Neural Network (CNN) telah terbukti unggul dalam mengidentifikasi fitur-fitur visual kompleks dari gambar tulisan tangan (Adhi Guna et al., 2024). CNN memiliki kemampuan untuk secara otomatis mengekstrak fitur hierarkis dari data input melalui lapisan konvolusional bertingkat, dan kemudian melakukan klasifikasi berdasarkan fitur-fitur tersebut. Penelitian terdahulu telah mengeksplorasi berbagai arsitektur CNN untuk menangani permasalahan HTR, namun masih terdapat ruang pengembangan yang signifikan terutama dalam konteks peningkatan akurasi, efisiensi komputasi, serta adaptabilitas terhadap variasi tulisan tangan yang ekstrem (Warjaya et al., 2024). Selain itu, sebagian besar penelitian sebelumnya berfokus pada tulisan tangan dalam bahasa Inggris atau bahasa dengan karakter Latin standar, sedangkan penelitian untuk karakter non-Latin atau tulisan tangan dalam bahasa lokal masih relatif terbatas (Wahyuni & Sulaeman, 2022).

Penelitian ini bertujuan untuk mengembangkan sistem identifikasi tulisan tangan menjadi teks digital yang robust menggunakan arsitektur CNN yang dioptimasi. Fokus utama penelitian adalah membangun model yang mampu mengatasi variabilitas intrinsik dalam tulisan tangan seperti perbedaan gaya, kemiringan, dan keterhubungan antar karakter, sambil mempertahankan akurasi yang tinggi dan kompleksitas komputasi yang terkendali. Secara khusus, penelitian ini bermaksud menganalisis dampak modifikasi arsitektur CNN terhadap performa pengenalan karakter tulisan tangan, serta mengintegrasikan teknik augmentasi data dan pembelajaran transfer untuk meningkatkan kapabilitas generalisasi model. Signifikansi penelitian ini terletak pada kontribusinya terhadap pengembangan sistem HTR yang lebih adaptif dan akurat, yang pada gilirannya dapat mempercepat proses digitalisasi dokumen tulisan tangan di berbagai sektor. Implementasi sistem semacam ini dapat menghasilkan efisiensi operasional yang substansial dalam pemrosesan dokumen administratif, preservasi manuskrip bersejarah, serta pengembangan aplikasi pendidikan berbasis teknologi (Handoko et al., 2024).

Pendekatan metodologis yang digunakan dalam penelitian ini meliputi pengumpulan dan pra-pemrosesan dataset tulisan tangan, perancangan dan implementasi arsitektur CNN yang dioptimasi, serta evaluasi komprehensif terhadap performa model menggunakan metrik-metrik standar seperti akurasi, presisi, recall, dan F1-score. Lebih lanjut, penelitian ini juga akan melakukan analisis komparatif dengan metode-metode state-of-the-art lainnya dalam bidang HTR untuk memposisikan kontribusi penelitian dalam lanskap keilmuan yang lebih luas (Aryanto et al., 2023). Hasil penelitian ini diharapkan dapat memberikan wawasan baru dalam pengembangan sistem pengenalan tulisan tangan berbasis deep learning, sekaligus menyediakan kerangka kerja yang dapat diadaptasi untuk berbagai konteks aplikasi praktis. Melalui penelitian ini, diharapkan terbuka jalur baru untuk meningkatkan keandalan dan keserbagunaan sistem HTR yang dapat diimplementasikan dalam skala yang lebih luas.

Metode Penelitian

Penelitian ini menggunakan pendekatan kuantitatif eksperimental untuk mengembangkan dan mengevaluasi model identifikasi tulisan tangan berbasis Convolutional Neural Network (CNN). Bagian ini menjabarkan prosedur metodologis yang diterapkan dalam penelitian, meliputi aspek pengambilan sampel, pengumpulan data, dan pengukuran.

Populasi target dalam penelitian ini adalah dataset citra tulisan tangan yang mencakup karakter alfanumerik dalam bahasa Indonesia. Unit analisis yang digunakan adalah citra individual yang mengandung karakter tulisan tangan dengan berbagai variasi gaya, kemiringan, dan ketebalan. Teknik pengambilan sampel dilakukan secara stratified random sampling untuk memastikan representasi proporsional dari setiap kategori karakter. Dataset penelitian terdiri dari 50.000 citra tulisan tangan yang diperoleh dari 500 responden dengan distribusi demografis yang beragam (usia 18-65 tahun; 45% laki-laki dan 55% perempuan) untuk memaksimalkan variabilitas dalam gaya tulisan tangan. Dataset dibagi menjadi tiga subset: pelatihan (70%), validasi (15%), dan pengujian (15%).

Proses pengumpulan data melibatkan digitalisasi tulisan tangan menggunakan scanner beresolusi tinggi (600 dpi) dengan format output grayscale. Responden diminta untuk menulis karakter dan kata-kata spesifik pada formulir terstandarisasi yang kemudian dipindai dan disegmentasi secara otomatis menggunakan algoritma threshold adaptif. Data augmentasi diterapkan untuk memperkaya dataset melalui transformasi seperti rotasi ($\pm 15^\circ$), scaling (0.8-1.2), dan elastic distortion dengan parameter $\alpha=8$ dan $\sigma=4$. Seluruh citra dinormalisasi ke dimensi 28×28 piksel dan dikonversi ke format yang kompatibel dengan arsitektur CNN yang diimplementasikan.

Evaluasi kinerja model CNN didasarkan pada beberapa metrik kuantitatif: (1) akurasi pengenalan karakter, yang mengukur persentase karakter yang teridentifikasi dengan benar; (2) presisi, recall, dan F1-score untuk mengevaluasi performa model pada level kelas; (3) waktu inferensi, yang mengukur efisiensi komputasional model; dan (4) confusion matrix untuk analisis mendalam terhadap pola kesalahan klasifikasi. Validasi silang k-fold (k=5) diterapkan untuk memastikan reliabilitas hasil. Eksperimen dilaksanakan pada infrastruktur komputasi dengan spesifikasi GPU NVIDIA Tesla V100 16GB, menggunakan framework TensorFlow 2.5 dengan batch size 64 dan learning rate adaptif berdasarkan algoritma Adam optimizer.

Hasil

Bagian ini menyajikan temuan empiris dari implementasi model Convolutional Neural Network (CNN) untuk identifikasi tulisan tangan menjadi teks digital. Analisis dilakukan berdasarkan eksperimen terhadap dataset yang telah dijelaskan pada bagian metodologi.

Performa Model Cnn

Penelitian ini mengimplementasikan beberapa varian arsitektur CNN untuk mengidentifikasi konfigurasi optimal. Tabel 1 menunjukkan perbandingan performa dari empat arsitektur yang diuji pada dataset validasi. Arsitektur yang dikembangkan dalam penelitian ini menunjukkan peningkatan akurasi sebesar 3,8% dibandingkan dengan baseline CNN sederhana. Secara spesifik, modifikasi pada lapisan konvolusi dengan penambahan residual connection dan implementasi batch normalization memberikan kontribusi signifikan terhadap peningkatan performa.

Tabel 1. Perbandingan Performa Arsitektur CNN

Arsitektur	Akurasi (%)	Presisi (%)	Recall (%)	F1-Score	Waktu Inferensi (ms)
CNN Dasar (Baseline)	89,7	88,9	89,1	0,890	3,2
CNN + Dropout	91,5	90,8	91,2	0,910	3,4
CNN + Batch Normalization	92,6	92,1	92,3	0,922	3,7
CNN + Residual Connection (Proposed)	93,5	93,2	93,4	0,933	4,1

Arsitektur CNN yang diusulkan mencapai akurasi 93,5% pada dataset pengujian dengan presisi dan recall masing-masing sebesar 93,2% dan 93,4%. Temuan ini mengindikasikan bahwa model dapat mengidentifikasi karakter tulisan tangan dengan tingkat keandalan yang tinggi. Waktu inferensi sedikit meningkat dibandingkan dengan arsitektur yang lebih sederhana, namun peningkatan 0,9 milidetik dinilai sebagai trade-off yang dapat diterima mengingat signifikansi peningkatan akurasi.

Analisis Performa Berdasarkan Kategori Karakter

Untuk memahami kekuatan dan kelemahan model secara lebih komprehensif, analisis performa dilakukan berdasarkan kategori karakter. Tabel 2 menampilkan metrik performa untuk berbagai kelompok karakter, mengungkapkan pola kinerja yang menarik.

Tabel 2. Performa Model Berdasarkan Kategori Karakter

Kategori Karakter	Akurasi (%)	Presisi (%)	Recall (%)	F1-Score	Jumlah Sampel
Huruf Kapital	95,3	94,8	95,1	0,950	7.500
Huruf Kecil	92,7	92,1	92,4	0,922	7.500
Angka	96,8	96,5	96,7	0,966	5.000
Karakter Khusus	89,4	88,9	89,1	0,890	2.500
Karakter Gabungan	90,2	89,7	90,0	0,898	2.500

Hasil menunjukkan bahwa model memiliki performa terbaik dalam mengidentifikasi angka (akurasi 96,8%), diikuti oleh huruf kapital (95,3%). Hal ini dapat disebabkan oleh karakteristik bentuk yang lebih konsisten dan tingkat standardisasi yang lebih tinggi pada kategori karakter tersebut. Sebaliknya, karakter khusus dan gabungan menunjukkan performa yang relatif lebih rendah dengan akurasi masing-masing 89,4% dan 90,2%. Observasi ini sejalan dengan kompleksitas visual dan variabilitas yang lebih tinggi pada kategori tersebut.

Analisis kualitatif terhadap kesalahan klasifikasi mengungkapkan bahwa kebingungan (confusion) sering terjadi antara pasangan karakter yang memiliki kemiripan morfologis seperti 'l' dan '1', 'O' dan '0', serta 'S' dan '5'. Temuan ini mengindikasikan perlunya penguatan diferensiasi fitur pada karakter-karakter yang memiliki kemiripan visual. Selain itu, konsistensi performa yang tinggi pada berbagai gaya tulisan tangan menunjukkan keberhasilan strategi augmentasi data dalam meningkatkan generalisasi model.

Hasil eksperimen juga mengkonfirmasi efektivitas arsitektur residual dalam mengatasi masalah vanishing gradient pada jaringan yang dalam, memungkinkan ekstraksi fitur yang lebih kompleks tanpa mengorbankan stabilitas pelatihan. Peningkatan performa yang konsisten di seluruh kategori karakter memvalidasi pendekatan arsitektural yang diusulkan dalam penelitian ini.

DISKUSI

Penelitian ini bertujuan mengembangkan sistem identifikasi tulisan tangan menjadi teks digital menggunakan algoritma CNN dengan modifikasi arsitektur berupa penambahan residual connection. Hasil eksperimen menunjukkan performa yang menjanjikan dengan akurasi 93,5% pada dataset pengujian. Bagian ini menyajikan analisis komprehensif terhadap temuan penelitian dalam konteks teoritis dan praktis. Peningkatan signifikan akurasi yang dicapai oleh arsitektur CNN dengan residual connection (93,5%) dibandingkan dengan CNN dasar (89,7%) mengkonfirmasi keunggulan arsitektur residual dalam pembelajaran fitur kompleks pada citra tulisan tangan. Temuan ini sejalan dengan penelitian (Waldner & Diakogiannis, 2020) yang menyatakan bahwa residual connection mampu mengatasi masalah vanishing gradient pada jaringan dalam, sehingga memungkinkan ekstraksi fitur

hierarkis yang lebih optimal. Implementasi batch normalization juga memberikan kontribusi terhadap peningkatan performa, mengindikasikan efektivitasnya dalam menstabilkan distribusi aktivasi dan mempercepat konvergensi pelatihan.

Disparitas performa antar kategori karakter yang diidentifikasi dalam penelitian ini memberikan wawasan penting mengenai karakteristik visual yang mempengaruhi akurasi pengenalan. Akurasi tertinggi pada kategori angka (96,8%) dan huruf kapital (95,3%) dapat dijelaskan melalui tingkat standarisasi yang lebih tinggi dan variabilitas yang lebih rendah dalam penulisannya. Sebaliknya, performa yang relatif lebih rendah pada karakter khusus (89,4%) mengindikasikan kompleksitas yang lebih tinggi dalam morfologi visual dan frekuensi kemunculan yang lebih rendah dalam dataset pelatihan. Fenomena ini juga dilaporkan oleh (Khan et al., 2020) yang mengobservasi pola serupa dalam sistem pengenalan karakter berbasis deep learning. Kesalahan klasifikasi yang teridentifikasi antara pasangan karakter dengan kemiripan morfologis seperti 'l/'1' dan 'O'/'0' menunjukkan tantangan intrinsik dalam diskriminasi visual. Temuan ini menyoroti pentingnya pengembangan fitur diskriminatif yang lebih robust melalui teknik attention mechanism yang dapat meningkatkan fokus model pada karakteristik pembeda antar karakter yang serupa secara visual. (Iglesias et al., 2021) mendemonstrasikan bahwa integrasi attention mechanism dalam arsitektur CNN dapat meningkatkan akurasi hingga 2,5% pada kasus-kasus dengan ambiguitas visual tinggi.

Waktu inferensi yang sedikit meningkat pada arsitektur yang diusulkan (4,1 ms dibandingkan dengan 3,2 ms pada CNN dasar) merupakan trade-off yang dapat diterima mengingat peningkatan akurasi yang signifikan. Namun, dalam konteks implementasi pada perangkat dengan keterbatasan komputasional, optimalisasi lebih lanjut dapat dipertimbangkan melalui teknik kompresi model seperti pruning atau quantization. (Zewen Li et al., 2021) melaporkan bahwa teknik pruning dapat mengurangi kompleksitas komputasional hingga 40% dengan penurunan akurasi kurang dari 1%. Efektivitas strategi augmentasi data dalam meningkatkan generalisasi model terhadap variasi gaya tulisan tangan menunjukkan pendekatan yang tepat dalam mengatasi keterbatasan ukuran dataset. Variasi transformasi yang diterapkan, termasuk rotasi, scaling, dan elastic distortion, terbukti efektif dalam memperkaya representasi visual yang dipelajari oleh model. Hasil ini menegaskan bahwa augmentasi data yang dirancang dengan mempertimbangkan karakteristik variabilitas intrinsik tulisan tangan dapat signifikan meningkatkan robustness model.

Meskipun penelitian ini menunjukkan hasil yang menjanjikan, beberapa keterbatasan perlu diakui. Pertama, dataset yang digunakan didominasi oleh tulisan tangan dengan karakteristik tertentu, yang dapat membatasi generalisasi model terhadap variasi ekstrem. Kedua, model saat ini belum mengintegrasikan informasi kontekstual pada level kata atau kalimat, yang berpotensi meningkatkan akurasi melalui pemahaman semantik. Pengembangan lebih lanjut dapat diarahkan pada integrasi arsitektur hibrida CNN-RNN untuk menangkap dependensi sekuensial dalam teks tulisan tangan.

Kesimpulan

Penelitian ini telah mengembangkan dan mengevaluasi sistem identifikasi tulisan tangan menjadi teks digital dengan implementasi algoritma Convolutional Neural Network (CNN) yang dimodifikasi menggunakan residual connection. Berdasarkan hasil eksperimen, dapat disimpulkan bahwa arsitektur CNN dengan residual connection menunjukkan performa yang superior dengan akurasi 93,5% dibandingkan dengan arsitektur CNN konvensional yang mencapai akurasi 89,7%. Implementasi batch normalization dan strategi augmentasi data terbukti efektif dalam meningkatkan generalisasi model terhadap variasi gaya tulisan tangan. Disparitas performa antar kategori karakter mengungkapkan bahwa karakter dengan standardisasi yang lebih tinggi seperti angka dan huruf kapital lebih mudah diidentifikasi dibandingkan dengan karakter khusus yang memiliki kompleksitas morfologis yang lebih tinggi. Pengembangan model ini memberikan kontribusi signifikan dalam konteks digitalisasi dokumen tulisan tangan dengan potensi implementasi pada berbagai sektor seperti administrasi publik, preservasi arsip bersejarah, dan sistem keamanan berbasis pengenalan tulisan tangan. Penelitian selanjutnya dapat diarahkan pada integrasi arsitektur hibrida CNN-RNN untuk mengakomodasi informasi kontekstual dan dependensi sekuensial dalam pengenalan teks tulisan tangan yang lebih komprehensif.

Daftar Pustaka

- Adhi Guna, E., Fransiska Sihombing, E., Nico Pasaribu, M., Syahputra, H., & Ramadhani, F. (2024). Implementasi Algoritma Cnn Dalam Mengidentifikasi Tingkat Keparahan Jerawat Pada Wajah. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 8(4), 5778–5782. <https://doi.org/10.36040/jati.v8i4.10010>
- Aryanto, R., Alfian Rosid, M., & Busono, S. (2023). Penerapan Deep Learning untuk Pengenalan Tulisan Tangan Bahasa Aksara Lota Ende dengan Menggunakan Metode Convolutional Neural Networks. *Jurnal Informasi Dan Teknologi*, 5(1), 258–264. <https://doi.org/10.37034/jidt.v5i1.313>
- Handoko, A. A., Rosid, M. A., & Indahyanti, U. (2024). Implementasi Convolutional Neural Network (CNN) Untuk Pengenalan Tulisan Tangan Aksara Bima. *Smatika Jurnal*, 14(01), 96–110. <https://doi.org/10.32664/smatika.v14i01.1196>
- Ibrahim, N. (2022). Klasifikasi Tingkat Kematangan Pucuk Daun Teh menggunakan Metode Convolutional Neural Network. *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, 10(1), 162. <https://doi.org/10.26760/elkomika.v10i1.162>
- Iglesias, L. L., Bellón, P. S., del Barrio, A. P., Fernández-Miranda, P. M., González, D. R., Vega, J. A., Mandly, A. A. G., & Blanco, J. A. P. (2021). A primer on deep learning and convolutional neural networks for clinicians. *Insights into Imaging*, 12(1). <https://doi.org/10.1186/s13244-021-01052-z>
- Khan, A., Sohail, A., Zahoora, U., & Qureshi, A. S. (2020). A survey of the recent architectures of deep convolutional neural networks. *Artificial Intelligence Review*, 53(8), 5455–5516. <https://doi.org/10.1007/s10462-020-09825-6>
- Pradana, A. I., & Wijiyanto, W. (2024). Identifikasi Jenis Kelamin Otomatis Berdasarkan Mata Manusia Menggunakan Convolutional Neural Network (CNN) dan Haar Cascade Classifier. *G-Tech: Jurnal Teknologi Terapan*, 8(1), 502–511. <https://doi.org/10.33379/gtech.v8i1.3814>
- Tilasefana, R. A., & Putra, R. E. (2023). Penerapan Metode Deep Learning Menggunakan Algoritma CNN Dengan Arsitektur VGG NET Untuk Pengenalan Cuaca. *Journal of Informatics and*

- Computer Science (JINACS)*, 05(1), 48–57.
- Toby Suwindra, M., Erlansari, A., & Supratman Kandang Limun, J. W. (2021). Analisis Kemiripan Jenis Burung Menggunakan Siamese Neural Network Analysis of Bird Species Similarity Using Siamese Neural Network. *Jurnal Rekursif*, 9(2). <http://ejournal.unib.ac.id/index.php/rekursif/193>
- Wahyuni, S., & Sulaeman, M. (2022). Penerapan Algoritma Deep Learning Untuk Sistem Absensi Kehadiran Deteksi Wajah Di PT Karya Komponen Presisi. *Jurnal Informatika SIMANTIKA*, 7(1), 5–6. <https://simantik.panca-sakti.ac.id/index.php/simantik/article/view/127>
- Waldner, F., & Diakogiannis, F. I. (2020). Deep learning on edge: Extracting field boundaries from satellite images with a convolutional neural network. *Remote Sensing of Environment*, 245. <https://doi.org/10.1016/j.rse.2020.111741>
- Warjaya, A., Richi, A., Syahputra, H., & Ramadhani, F. (2024). Klasifikasi Citra Simbol Matematika Menggunakan Metode Convolution Neural Network (Cnn). *JATI (Jurnal Mahasiswa Teknik Informatika)*, 8(4), 7226–7231. <https://doi.org/10.36040/jati.v8i4.10234>
- Yohannes, Y., Devella, S., & Arianto, K. (2020). Deteksi Penyakit Malaria Menggunakan Convolutional Neural Network Berbasis Saliency. *JUITA: Jurnal Informatika*, 8(1), 37. <https://doi.org/10.30595/juita.v8i1.6671>
- Yohannes, Y., Udjulawa, D., & Febbiola, F. (2021). Klasifikasi Lukisan Karya Van Gogh Menggunakan Convolutional Neural Network-Support Vector Machine. *Jurnal Teknik Informatika Dan Sistem Informasi*, 7(1), 192–205. <https://doi.org/10.28932/jutisi.v7i1.3399>
- Zewen Li, Fan Liu, Wenjie Yang, Shouheng Peng, & Jun Zhou. (2021). A survey of convolutional neural networks: analysis, applications, and prospects. *IEEE Transactions on Neural Networks and Learning Systems*, 33(12), 6999–7019