

## KLASIFIKASI CITRA DIGITAL TULISAN TANGAN ANGKA MENGGUNAKAN METODE CONVOLUTIONAL NEURAL NETWORK

**Antonius Angga Kurniawan<sup>a</sup>, Rama Dian Syah<sup>b\*</sup>, Rizki Ariyani<sup>c</sup>**

<sup>a</sup> Ilmu Komputer dan Teknologi Informasi, [rama\\_ds@staff.gunadarma.ac.id](mailto:rama_ds@staff.gunadarma.ac.id), Universitas Gunadarma

<sup>b\*</sup> Teknologi Industri, [anggaku@staff.gunadarma.ac.id](mailto:anggaku@staff.gunadarma.ac.id), Universitas Gunadarma

<sup>c</sup> Ilmu Komputer dan Teknologi Informasi, [rizkiariyani@staff.gunadarma.ac.id](mailto:rizkiariyani@staff.gunadarma.ac.id), Universitas Gunadarma

### ABSTRAK

Rapid technological advances have led to the development of computer vision science in various fields. This research aims to detect handwriting using deep learning technology with the Convolutional Neural Network (CNN) method. The research stages are data sample selection, data preprocessing, data training, data testing, and evaluation of results. This research succeeded in detecting handwriting with an accuracy value of 0.9800 and a loss value of 0.0665. There are several classification errors because images with numbers are less clear and almost look like numbers that they should not be. The more training data, the more the network will learn so that the accuracy will be better.

**Keywords:** Convolutional Neural Network, Deep Learning, Handwriting, Artificial Intelligence

### Abstrak

Kemajuan teknologi yang pesat menyebabkan perkembangan ilmu computer vision di berbagai bidang. Penelitian ini bertujuan untuk mendeteksi tulisan tangan menggunakan teknologi deep learning dengan metode Convolutional Neural Network (CNN). Tahapan penelitian yaitu pemilihan sampel data, Data preprocessing, Data training, Data testing, dan evaluasi hasil. Penelitian ini berhasil mendeteksi tulisan tangan dengan nilai akurasi 0.9800 dan nilai loss 0.0665. Terdapat beberapa kesalahan klasifikasi karena citra dengan angka kurang jelas dan hampir mirip dengan angka yang tidak seharusnya. Semakin banyak data training maka jaringan akan semakin banyak belajar sehingga keakurasian akan semakin baik.

**Kata Kunci:** Convolutional Neural Network, Deep Learning, Tulisan Tangan, Artificial Intelligence

## 1. PENDAHULUAN

*Computer vision* merupakan ilmu yang berfokus pada computer yang melakukan pembelajaran sehingga dapat menganalisa data visual. *Computer Vision* merupakan kombinasi dari konsep, teknik dan ide dari pengolahan citra digital, pengenalan pola, kecerdasan buatan dan grafik computer [1]. Hasil dari *Computer Vision* merupakan pemahaman citra dengan mengadaptasi dari kemampuan penglihatan manusia dalam mengambil informasi. *Computer vision* sangat dipengaruhi oleh kualitas citra dalam proses pengenalan citra.

*Deep Learning* dapat digunakan pada *Computer Vision* untuk pengenalan citra pada data visual. *Deep Learning* merupakan *Machine Learning* yang mampu memodelkan berbagai data kompleks. *Deep Learning* memungkinkan proses komputasi untuk pembelajaran dan representasi data dengan mengadaptasi kemampuan otak dalam memahami informasi dari data skala besar [2].

Implementasi *Deep Learning* menggunakan metode CNN dilakukan untuk membedakan jenis objek citra. Dataset yang digunakan yaitu data citra digital angka Mnist Tensorflow Keras. Proses *Deep Learning* dilakukan dengan *training* jaringan, kemudian jaringan tersebut diterapkan pada data tes.

## 2. Dasar Teori

### A. Convolutional Neural Network

*Convolutional Neural Network* (CNN) yang pertama kali dirancang oleh Kohiko Fukushima bernama *NeoCognitron* [3]. Model komputasi CNN pertama kali berdasarkan hubungan antara neuron dan

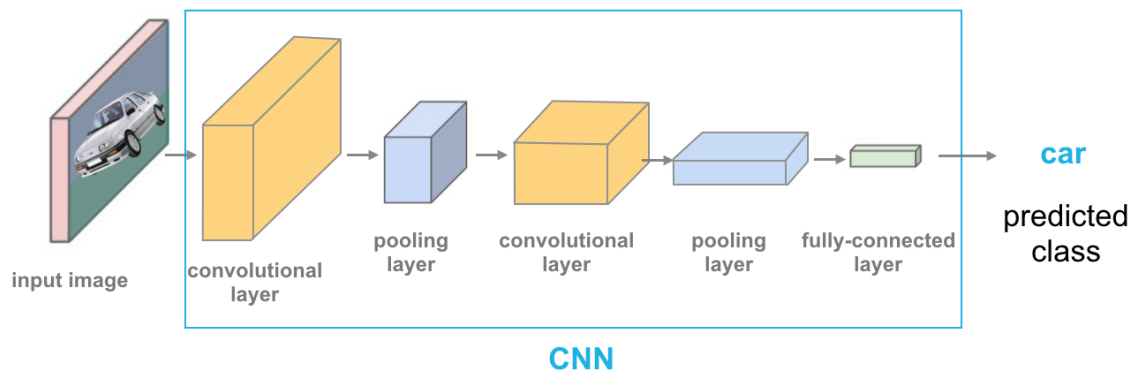
---

transformasi gambar secara hierarkis. Konsep tersebut kemudian dikembangkan lagi oleh Yann Lechun dengan model CNN yang bernama LeNet untuk pengenalan angka dan tulisan tangan [4]

CNN termasuk dalam jenis *Deep Neural Network* karena kedalaman jaringan yang tinggi dan banyak diaplikasikan pada data citra. CNN dapat melakukan pengenalan citra dengan akurasi yang mirip dengan manusia pada dataset tertentu [5]. CNN mampu mengolah informasi citra karena meniru system pengenalan citra pada visual cortex manusia [3].

#### B. Arsitektur CNN

CNN terdiri dari 3 lapisan saraf yaitu lapisan *Convolutional*, lapisan *pooling*, dan lapisan *Fully Connected*. Setiap jenis lapisan memiliki fungsi yang berbeda dan akan mengubah volume data input menjadi volume data output ke lapisan *fully connected* dan menghasilkan vector 1 dimensi dari pemetaan data input. Berikut arsitektur *Convolutional neural network* terdapat pada Gambar 1.



(sumber: <https://cezannec.github.io/>)  
Gambar 1. Arsitektur CNN

#### 1. Lapisan *Convolutional*

Lapisan *Convolutional* merupakan lapisan untuk mengekstraksi objek dari citra input menggunakan suatu filter. Dalam filter tersebut terdapat bobot yang berfungsi untuk mengetahui karakter dari objek seperti tepi, kurva, atau warna. Hasil dari lapisan *convolutional* yaitu transformasi linier dari citra input berdasarkan informasi spasial pada data. Output dari konvolusi digunakan untuk input lapisan konvolusi selanjutnya [6].

#### 2. Lapisan *Pooling*

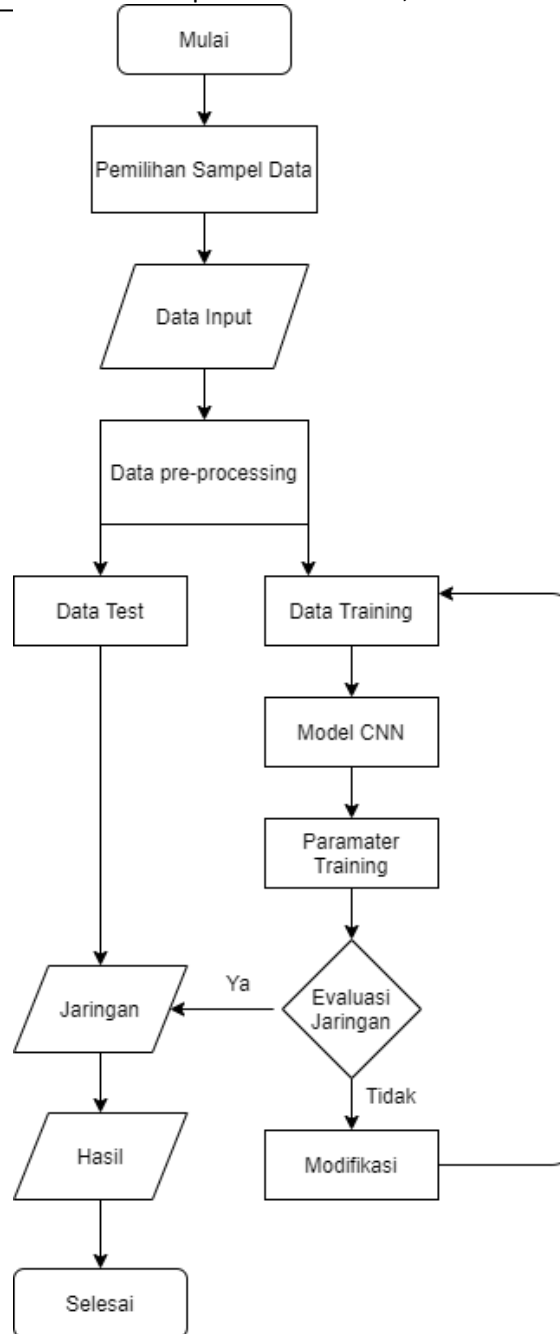
*Pooling* adalah proses pengecilan ukuran matriks. Ada dua macam pooling yang dapat digunakan yaitu *average pooling* dan *max pooling* [7]. Nilai yang diambil dari *average pooling* merupakan nilai rata-rata sedangkan untuk *max pooling* adalah nilai maksimal [8].

#### 3. Lapisan *Fully Connected*

Lapisan *Fully Connected* adalah kumpulan dari beberapa proses konvolusi [9]. Lapisan ini menentukan fitur mana yang paling berhubungan dengan kelas tertentu dengan mendapatkan input dari proses sebelumnya. Lapisan ini berfungsi untuk memadukan semua node menjadi satu dimensi [10]

### 3. METODOLOGI PENELITIAN

Implementasi *Deep Learning* ini menggunakan dataset citra digital angka. Dataset diambil dari Mnist Tensorflow Keras dengan 10 klasifikasi. Dataset citra digital yang digunakan merupakan citra RGB. Model yang digunakan untuk implementasi *Deep Learning* yaitu *Convolutional Neural Network*. Pembuatan model dilakukan dengan perangkat lunak *Jupyter Notebook* Berikut langkah kerja pada implementasi *Deep Learning* menggunakan model CNN terdapat pada Gambar 2.



Gambar 2. Diagram Alur

Alur pengerjaan dimulai dari pemilihan data sample yang digunakan sebagai data input untuk data *training* dan pengujian/tes. Kemudian perancangan jaringan model CNN untuk melakukan klasifikasi pada objek citra digital tulisan tangan angka. Rancangan jaringan diimplementasikan pada data training untuk pembelajaran pengenalan objek. Apabila hasil training mendapatkan hasil yang baik, maka model jaringan digunakan untuk klasifikasi pada data tes.


#### 4. HASIL DAN PEMBAHASAN

##### A. Implementasi CNN

Implementasi CNN dilakukan dengan 2 tahapan yaitu training dan tes. Tahapan training merupakan proses pelatihan jaringan untuk mempeleajari data input. Tahapa tes akan melakukan klasifikasi data apabila hasil dari tahapan training mendapatkan hasil yang baik.

B. Data Latih

Data yang digunakan untuk penelitian ini didapat dari dataset Mnist Tensorflow Keras. Data latih yang digunakan berjumlah 1563 gambar. Berikut merupakan dataset yang digunakan terdapat pada Gambar 3.




(sumber: <http://yann.lecun.com/exdb/mnist/>)

Gambar 3. Dataset Mnist Tensorflow Keras

Pada Gambar 2 terdapat 10 klasifikasi dari dataset yang digunakn. Proses training dilakukan dengan menggunakan single GPU. Training dilakukan dengan *Optimizer Adam* dengan jumlah epoch 10, Hasil dari training disajikan pada Tabel 1 dan Gambar 4.

Tabel 1. Hasil Training Jaringan CNN

Epoch	Waktu (s)	Loss	Accuracy	Val Loss	Val Accuracy
1	229	1.1071	0.6531	0.2867	0.9225
2	244	0.3118	0.9111	0.1213	0.9638
3	247	0.2390	0.9333	0.0834	0.9766
4	260	0.2078	0.9433	0.0750	0.9767
5	239	0.1887	0.9482	0.0907	0.9744
6	235	0.1675	0.9552	0.0705	0.9808
7	228	0.1669	0.9536	0.0716	0.9772
8	225	0.1626	0.9555	0.0585	0.9827
9	231	0.1530	0.9594	0.0592	0.9832
10	233	0.1393	0.9631	0.0665	0.9800



Gambar 4. Grafik akurasi dan kesalahan *training*

Pada Tabel 1 dan Gambar 4 terlihat bahwa kesalahan semakin menurun dan akurasi semakin naik. Waktu kecepatan training dipengaruhi oleh GPU. Proses training dilakukan pada computer dengan GPU NVIDIA GTX 1650. Percobaan *running* model jaringan ini pada DGX1 kampus Universitas Gunadarma tidak bisa dilakukan karena terjadi Kernel yang selalu restart, sehingga percobaan pada DGX1 tidak bisa diujikan kecepatannya. Setelah proses training dilakukan dapat dilihat *confusion matrix* untuk melihat performa dari klasifikasi. Berikut tabel *confusion matrix*.


Tabel 2. Confusion Matrix

Kelas	Precision	Recall	f1-score
0	0.99	0.99	0.99
1	0.98	1.00	0.99
2	0.99	0.94	0.96
3	0.94	0.99	0.99
4	0.94	1.00	0.97
5	0.94	0.99	0.96
6	0.97	0.97	0.97
7	0.98	0.98	0.98
8	1.00	0.98	0.99
9	0.99	0.94	0.97

Tabel 2 menjelaskan bahwa nilai *Precision* dan *Recall* mempunyai nilai yang tinggi mendekati 1. Hal ini membuktikan bahwa model yang dirancang memiliki kualitas pembelajaran yang baik. Nilai *f1-score* merupakan nilai rata-rata dari *Precision* dan *Recall*. Nilai *f1-score* mendekati 1 mengindikasikan bahwa model mampu mengklasifikasikan objek dengan baik.

B. Data Tes

Sample data dapat dimasukkan untuk mengetahui jenis klasifikasi pada jaringan, kemudian jaringan akan mengeluarkan label jenis objek berdasarkan data yang dimasukkan. Hasil label klasifikasi yang keluar dari jaringan dapat dilihat klasifikasi dalam menentukan angka pada citra digital. Sedangkan ada beberapa prediksi klasifikasi angka yang salah pada model jaringan ini. Berikut merupakan gambar dari prediksi klasifikasi yang salah dan klasifikasi angka yang seharusnya terdapat pada Gambar 5.



Gambar 5. Prediksi Kesalahan Klasifikasi

Gambar 5 menjelaskan bahwa pada model terdapat kesalahan prediksi klasifikasi angka. Hal ini karena citra dengan tulisan angka yang kurang jelas dan hampir mirip dengan klasifikasi angka yang tidak seharusnya.

## 5. KESIMPULAN DAN SARAN

Implementasi metode CNN untuk klasifikasi objek citra menunjukkan bahwa arsitektur CNN dapat mengklasifikasi angka pada citra digital dengan baik. Training jaringan CNN terhadap citra digital tulisan tangan angka mencapai nilai akurasi 0.9800 dan nilai loss 0.0665. Terdapat beberapa kesalahan klasifikasi karena citra dengan angka kurang jelas dan hampir mirip dengan angka yang tidak seharusnya. Akurasi jaringan sangat dipengaruhi oleh jumlah data training. Semakin banyak data training maka jaringan akan semakin banyak belajar sehingga keakurasian akan semakin baik. Untuk melakukan proses training jaringan dengan data training yang banyak diperlukan komputasi yang besar.

## DAFTAR PUSTAKA

- [1] O. Cosido *et al.*, "Hybridization of convergent photogrammetry, computer vision, and artificial intelligence for digital documentation of cultural heritage-A case study: The magdalena palace," *Proc. - 2014 Int. Conf. Cyberworlds, CW 2014*, pp. 369–376, 2014, doi: 10.1109/CW.2014.58.
- [2] A. Voulodimos, N. Doulamis, A. Doulamis, and E. Protopapadakis, "Deep Learning for Computer Vision: A Brief Review," *Comput. Intell. Neurosci.*, vol. 2018, 2018, doi: 10.1155/2018/7068349.
- [3] K. Fukushima, "Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position," *Biol. Cybern.*, vol. 36, no. 4, pp. 193–202, 1980, doi: 10.1007/BF00344251.
- [4] Y. Le Cun *et al.*, "Handwritten Digit Recognition with a Back-Propagation Network," 1990.
- [5] A. Coates, H. Lee, and A. Y. NG, "An Analysis of Single-Layer Networks in Unsupervised Feature Learning," 2011.
- [6] M. Castelluccio, G. Poggi, C. Sansone, and L. Verdoliva, "Land Use Classification in Remote Sensing Images by Convolutional Neural Networks," pp. 1–11, 2015, [Online]. Available: <http://arxiv.org/abs/1508.00092>.
- [7] M. B. Bejiga, A. Zeggada, A. Nouffidj, and F. Melgani, "A convolutional neural network approach for assisting avalanche search and rescue operations with UAV imagery," *Remote Sens.*, vol. 9, no. 2, 2017, doi: 10.3390/rs9020100.
- [8] T. Zhi, L. Y. Duan, Y. Wang, and T. Huang, "Two-stage pooling of deep convolutional features for image retrieval," *Proc. - Int. Conf. Image Process. ICIP*, vol. 2016-Augus, pp. 2465–2469, 2016, doi: 10.1109/ICIP.2016.7532802.
- [9] S. Hijazi, R. Kumar, and C. Rowen, "Image Recognition Using Convolutional Neural Networks," *Cadane Whitepaper*, pp. 1–12, 2015.
- [10] S. Albelwi and A. Mahmood, "A framework for designing the architectures of deep Convolutional Neural Networks," *Entropy*, vol. 19, no. 6, 2017, doi: 10.3390/e19060242.