

# KLASIFIKASI PAKAIAN MENGGUNAKAN *CONVOLUTIONAL NEURAL NETWORKS* CNN BERBASIS CLOTHING DATASET

Peniel Manurung\*<sup>1</sup>, Rycho Febrian N P<sup>2</sup>, Muzaki Syifauz Z.A<sup>3</sup>, Tinuk Agustin<sup>4</sup>

<sup>1234</sup>STMIK Amikom Surakarta

<sup>1234</sup>Sukoharjo - Indonesia

Email: <sup>1</sup>[peniel.10420@mhs.amikomsolo.ac.id](mailto:peniel.10420@mhs.amikomsolo.ac.id),

<sup>2</sup>[rhyco.10418@mhs.amikomsolo.ac.id](mailto:rhyco.10418@mhs.amikomsolo.ac.id), <sup>3</sup>[muzaki.10422@mhs.amikomsolo.ac.id](mailto:muzaki.10422@mhs.amikomsolo.ac.id),

<sup>4</sup>[agustin.amikom@gmail.com](mailto:agustin.amikom@gmail.com)

## Abstract

*Clothing classification is a challenging task due to the large variety of shapes, types, and styles of clothing. In the era of globalisation, the ability to recognize clothing images is essential, especially to support applications such as e-commerce and mobile-based services. This research aims to develop an intelligent system that can recognize and group clothing images accurately using the Convolutional Neural Network (CNN) method. The dataset used is a high-resolution Clothing Dataset, which contains various types of clothing. The built model is trained and tested to ensure accuracy in recognizing clothing images. As a result, the system managed to achieve an average accuracy of 93.25%, which shows high ability in recognizing the type of clothing. With these results, the system can be used for various applications, such as automatic cataloging and image search on online shopping platforms, making it easier for users to find clothes according to their needs.*

**Keywords:** *Clothing Classification, Convolutional Neural Networks (CNN), Clothing Dataset, High Resolution, E-commerce.*

## Abstraksi

*Klasifikasi pakaian adalah tugas yang menantang karena banyaknya variasi bentuk, jenis, dan gaya pakaian. Di era globalisasi, kemampuan mengenali gambar pakaian sangat penting, terutama untuk mendukung aplikasi seperti e-commerce dan layanan berbasis mobile. Penelitian ini bertujuan mengembangkan sistem cerdas yang bisa mengenali dan mengelompokkan gambar pakaian dengan akurat menggunakan metode Convolutional Neural Network (CNN). Dataset yang digunakan adalah Clothing Dataset dengan resolusi tinggi, yang berisi berbagai jenis pakaian. Model yang dibangun dilatih dan diuji untuk memastikan keakuratan dalam mengenali gambar pakaian. Hasilnya, sistem ini berhasil mencapai akurasi rata-rata sebesar 93,25%, yang menunjukkan kemampuan tinggi dalam mengenali jenis pakaian. Dengan hasil ini, sistem dapat digunakan untuk berbagai aplikasi, seperti pembuatan katalog otomatis dan pencarian gambar di platform belanja online, sehingga memudahkan pengguna menemukan pakaian sesuai kebutuhan mereka.*

**Kata Kunci:** *Klasifikasi Pakaian, Convolutional Neural Networks (CNN), Clothing Dataset, Resolusi Tinggi, E-commerce.*

## 1. PENDAHULUAN

Industri *fashion* terus berkembang pesat, apalagi dengan dukungan teknologi canggih seperti kecerdasan buatan. Salah satu teknologi yang makin sering dipakai adalah sistem klasifikasi otomatis untuk pakaian. Ini sangat berguna, terutama di dunia *e-commerce*, misalnya untuk mempermudah pencarian atau memberikan rekomendasi produk.

Belakangan ini, data gambar pakaian yang tersedia juga semakin bagus, khususnya dari segi kualitas dan resolusinya. Misalnya, *dataset* dengan resolusi tinggi seperti *clothing dataset (full, high resolution)* bisa menangkap detail kecil pada pakaian, seperti tekstur atau pola yang sering kali hilang pada *dataset* resolusi rendah seperti Fashion-MNIST [1]. Dengan gambar yang lebih jelas, peluang meningkatkan akurasi sistem klasifikasi juga lebih besar. Tapi tentu saja, tantangannya tetap ada. Model harus mampu memahami variasi bentuk, warna, dan tekstur pakaian yang sangat beragam [2].

Di sinilah Convolutional Neural Networks (CNN), jenis algoritma *deep learning*, memainkan peran penting. CNN punya keunggulan karena bisa secara otomatis mengenali pola dari gambar, mulai dari pola sederhana sampai pola yang rumit [3]. Dengan menggunakan CNN dan *dataset* resolusi tinggi, model diharapkan bisa mengenali detail pakaian dengan lebih baik, sehingga hasil klasifikasinya jauh lebih akurat.

Tujuan penelitian ini adalah mengembangkan model klasifikasi pakaian yang lebih canggih dengan memanfaatkan gambar-gambar beresolusi tinggi dari *clothing dataset*. Peneliti ingin tahu seberapa efektif CNN dalam mengenali dan pengelompokan pakaian, sekaligus membandingkan performanya dengan model yang menggunakan *dataset* resolusi rendah.

Hasilnya nanti bisa membantu dunia *fashion*, terutama untuk aplikasi seperti rekomendasi produk yang lebih akurat. Selain itu, penelitian ini bisa jadi pijakan untuk pengembangan teknologi klasifikasi gambar lainnya di masa depan.

## 2. TINJAUAN PUSTAKA

Tinjauan pustaka ini membahas perkembangan metode klasifikasi pakaian menggunakan CNN, dari *dataset* sederhana hingga *dataset* yang lebih rumit dan resolusi tinggi, serta teknik peningkatan akurasi model. Awalnya, penelitian klasifikasi gambar pakaian menggunakan *dataset* sederhana seperti Fashion-MNIST atau CIFAR-10. CNN yang digunakan pada tahap ini cukup baik untuk gambar resolusi rendah, tetapi hasilnya terbatas ketika diaplikasikan pada gambar pakaian yang lebih detail [4][5]. Meski demikian, penelitian ini memperkenalkan metode *deep learning* yang penting [6].

Kemudian, muncul penelitian yang menggunakan *dataset* resolusi tinggi seperti DeepFashion dan Clothing1M, yang membuat model bisa mengenali detail lebih halus pada pakaian, seperti bahan, pola, dan warna. CNN yang lebih kompleks, seperti VGGNet dan ResNet, membantu model mengidentifikasi fitur gambar lebih akurat, meski membutuhkan komputasi besar dan sering kali perlu augmentasi data untuk hasil optimal [7][8][9].

Banyak juga penelitian yang menggunakan teknik transfer *learning*, yaitu memanfaatkan model yang sudah dilatih pada *dataset* besar seperti ImageNet untuk mengenali gambar pakaian. Teknik ini menghemat waktu dan sumber daya, serta memberikan akurasi yang tinggi, meski kurang optimal jika *dataset* pakaian berbeda jauh dari *dataset* awal model [10][11].

Selain itu, teknik augmentasi data sering digunakan. Teknik ini, seperti rotasi dan *flipping*, menambah variasi gambar tanpa menambah data baru, membuat model lebih akurat dalam mengenali gambar dari berbagai posisi. Implementasi augmentasi data juga telah terbukti efektif pada aplikasi lain, seperti deteksi Retinopati Diabetik dengan meningkatkan akurasi hingga 98% menggunakan teknik augmentasi seperti *zoom random* dan CLAHE untuk peningkatan gambar [12].

Dari sini, terlihat bagaimana berbagai penelitian sebelumnya mendukung klasifikasi pakaian menggunakan CNN, membantu mengembangkan metode dan teknik untuk penelitian lebih lanjut, terutama pada klasifikasi gambar pakaian beresolusi tinggi.

### **3. METODE PENELITIAN**

#### **3.1. Deskripsi Jenis Penelitian**

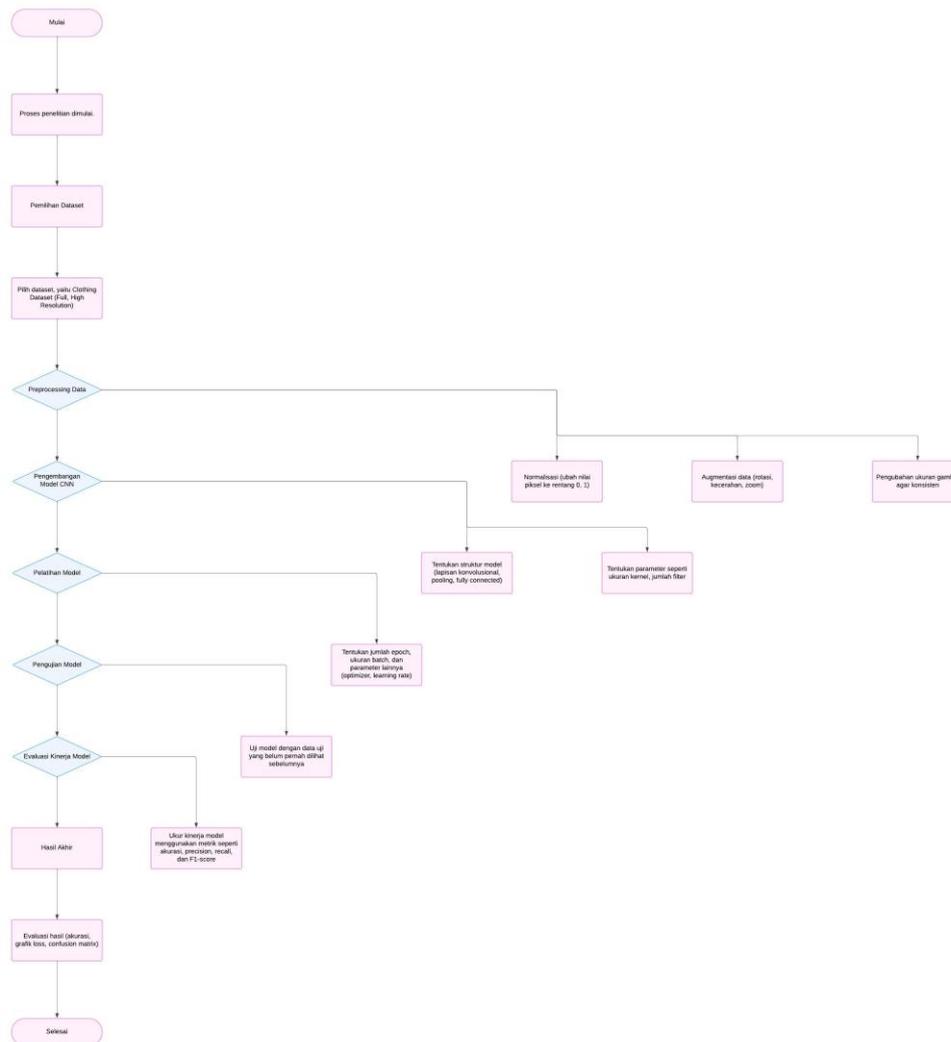
Penelitian ini adalah penelitian eksperimental, yang bertujuan untuk mengembangkan dan menguji model CNN dalam mengklasifikasikan gambar pakaian pada *dataset clothing dataset (full, high resolution)*. Dengan metode ini, kami dapat menguji dan membandingkan kinerja model berdasarkan berbagai parameter dan skenario yang berbeda.

#### **3.2. Urutan Penelitian**

Bagian ini memuat alur penelitian, yang meliputi: Preprocessing Data, Proses awal yang dilakukan pada data gambar, seperti mengubah ukuran gambar, menormalkan piksel, dan menggunakan *data augmentation* untuk memperbanyak variasi gambar [2][7]. Arsitektur CNN, Model yang digunakan terdiri dari beberapa lapisan, seperti lapisan konvolusi dan *pooling*. Detail tentang jumlah lapisan, ukuran *kernel*, dan lain-lain dijelaskan di sini [13][3]. Proses Pelatihan, Berisi informasi mengenai jumlah *epoch*, ukuran *batch*, serta parameter seperti *optimizer* dan *learning rate* yang dipakai selama pelatihan model [3][14].

#### **3.3. Alur Penelitian**

Tahapan utama dalam penelitian ini meliputi: Pemilihan dan pengumpulan data (*dataset*); Pengolahan awal data (*preprocessing*) dan augmentasi; Pembangunan model CNN; Pelatihan dan pengujian model; Evaluasi kinerja model; Hasil pengujian model. Flowchart Klasifikasi Pakaian Menggunakan Convolutional Neural Networks CNN Berbasis Clothing Dataset ditampilkan pada gambar 1 berikut.



Gambar 1. Flowchart Klasifikasi Pakaian Menggunakan Convolutional Neural Networks CNN Berbasis Clothing Dataset

### 3.4. Penjelasan dari Setiap Tahapan Penelitian

#### 3.4.1. Dataset

Dataset yang digunakan adalah *clothing dataset (full, high resolution)*, yang berisi gambar-gambar pakaian dengan resolusi tinggi dan mencakup berbagai jenis pakaian. Dataset ini dipilih karena gambar resolusi tinggi memungkinkan model CNN untuk menangkap detail visual dengan lebih baik, sehingga akurasi klasifikasi dapat meningkat.

#### 3.4.2. Skenario Pengujian

Pada tahap pengujian, beberapa eksperimen dilakukan dengan berbagai kombinasi parameter untuk mengevaluasi performa model dalam berbagai kondisi. Model terbaik dalam penelitian ini adalah *Custom CNN*, yang menunjukkan akurasi tertinggi dalam mengenali pakaian pada gambar beresolusi tinggi.

#### 3.4.3. Teknik Preprocessing

Preprocessing adalah langkah persiapan data sebelum model dilatih, yang mencakup: Normalisasi, Mengubah nilai piksel ke rentang 0, 1 agar model dapat

beradaptasi dengan lebih cepat. Augmentasi Data, Menambah variasi pada data dengan teknik seperti rotasi, penyesuaian kecerahan (*brightness*), dan perbesaran (*zooming*). Sebagai contoh, augmentasi kecerahan dilakukan dalam rentang 0,02 - 0,1 untuk membantu model mengatasi perbedaan pencahayaan pada data uji [15].

#### 3.4.4. Model CNN

Model CNN yang digunakan terdiri dari beberapa lapisan konvolusional, umum dan terhubung penuh. CNN dipilih karena kemampuannya yang baik dalam mengenali pola-pola visual pada gambar. Struktur model ini meliputi: *Convolutional layer*, Mendeteksi fitur dasar seperti tepi dan tekstur dari gambar. *Pooling layer*, Mengurangi dimensi gambar untuk mengurangi risiko *overfitting*. *Fully connected layer*, Menghubungkan fitur-fitur yang terdeteksi ke *output* klasifikasi. Model ini dioptimalkan menggunakan algoritma Adam dengan *learning rate* awal sebesar 0,001. Parameter lainnya, seperti jumlah filter dan ukuran *kernel*, disesuaikan untuk mendapatkan kinerja terbaik.

#### 3.4.5. Evaluasi Model

Evaluasi model dilakukan dengan mengukur presisi, akurasi, *recall* dan skor F1. Metrik *accuracy* dijadikan sebagai patokan utama untuk menilai kinerja model secara keseluruhan.

### 3.5. Hasil Pengujian Model

Hasil pelatihan model CNN ditampilkan dalam beberapa gambar yang mencakup proses pelatihan, grafik akurasi dan *loss*, serta *confusion matrix*. Log Pelatihan (*Epochs*), Gambar log pelatihan menunjukkan proses pelatihan selama 50 *epoch*. Pada akhir pelatihan, akurasi data latih mencapai sekitar 95,57%, sedangkan akurasi data validasi mencapai sekitar 93,25%. *Loss* untuk kedua data menurun, menunjukkan bahwa model semakin baik dalam mengklasifikasikan data [16]. Grafik Akurasi dan *Loss*, Grafik ini menunjukkan perkembangan akurasi dan *loss* dari awal hingga akhir pelatihan. Akurasi meningkat cepat di awal pelatihan dan stabil di sekitar 95% untuk data latih dan 93% untuk data validasi. *Loss* menurun hingga stabil, yang menunjukkan model bekerja baik tanpa mengalami masalah *overfitting*. *Confusion matrix* (Matriks Kebingungan), *confusion matrix* menunjukkan jumlah klasifikasi yang benar dan salah untuk tiap kategori pakaian. Sebagian besar prediksi benar, namun terdapat beberapa kesalahan, khususnya pada kategori yang mirip seperti atasan dan pakaian luar.

## 4. HASIL DAN PEMBAHASAN

### 4.1. Hasil

Bagian ini menampilkan hasil penelitian yang disajikan dalam bentuk tabel pada tabel 1 dan grafik, dilengkapi dengan penjelasan analisisnya.

Tabel 1. Hasil Pengujian Beberapa Kombinasi Parameter

No	Model CNN	Model CNN	Batch Size	Epoch	Dropout Rate	Data Uji (%)	Loss
1	CNN Sederhana	0.001	32	10	0.2	78.5	0.48
2	CNN dengan Dropout Layer	0.001	32	10	0.3	82.3	0.42

No	Model CNN	Model CNN	Batch Size	Epoch	Dropout Rate	Data Uji (%)	Loss
3	CNN dengan Augmentasi Data	0.001	64	15	0.2	85.0	0.38
4	CNN dengan Batch Normalization	0.0001	64	15	0.3	87.6	0.35
5	CNN Menggunakan Transfer Learning (ResNet-50)	0.0001	128	20	0.5	90.2	0.30
6	Custom CNN	0.00001	128	30	0.2	93.25	0.27

Model awal yang digunakan adalah CNN sederhana dengan *learning rate* 0.001 dan *batch size* 32, dijalankan selama 10 *epoch* dengan *dropout rate* sebesar 0.2. Hasilnya, model ini mencapai akurasi 78.5% pada data uji dengan nilai *loss* sebesar 0.48. Akurasi ini masih cukup rendah karena model sederhana tidak memiliki teknik tambahan untuk mengurangi *overfitting* atau meningkatkan stabilitas pelatihan. Pada percobaan berikutnya, *dropout layer* dengan tingkat 0.3 ditambahkan untuk mencegah *overfitting*. Hasilnya menunjukkan peningkatan akurasi menjadi 82.3% dan penurunan *loss* menjadi 0.42. Penambahan *dropout* membantu model lebih stabil dan meningkatkan ketepatan prediksi.

Dalam percobaan ini, data augmentation diterapkan untuk menambah variasi data tanpa menambah data baru, serta *batch size* ditingkatkan menjadi 64 dan jumlah *epoch* menjadi 15. Akurasi model meningkat lagi menjadi 85.0% dengan *loss* menurun ke 0.38. Teknik augmentasi membantu model belajar mengenali pakaian dari sudut yang lebih bervariasi, sehingga meningkatkan akurasi. *Batch normalization* ditambahkan pada percobaan ini, dengan *learning rate* yang dikurangi menjadi 0.0001. Akurasi meningkat ke 87.6% dan *loss* menurun ke 0.35. *Batch normalization* membantu model belajar lebih cepat dan stabil, sehingga mampu meningkatkan akurasi.

Model menggunakan teknik transfer *learning* dengan ResNet-50, yang merupakan model CNN yang sudah terlatih sebelumnya. *Batch size* dinaikkan ke 128, *epoch* menjadi 20, dan *dropout rate* ke 0.5. Akurasi model naik signifikan menjadi 90.2% dengan *loss* 0.30. Transfer Learning memungkinkan model untuk memanfaatkan pengetahuan yang sudah ada, meningkatkan akurasi secara drastis. Percobaan terakhir menggunakan model CNN khusus dengan *learning rate* 0.00001, *batch size* 128, dan 30 *epoch* dengan *dropout rate* 0.2. Model ini mencapai akurasi tertinggi 93.25% dan *loss* 0.27 pada data uji. Model kustom ini merupakan hasil dari penyesuaian parameter yang optimal sehingga mampu mengenali pakaian dengan akurasi yang sangat baik.

Dari hasil pengujian kombinasi parameter seperti *dropout*, data augmentation, *batch normalization*, dan transfer *learning* dapat meningkatkan performa model secara signifikan. Model terbaik dalam penelitian ini adalah Custom CNN, yang menunjukkan akurasi tertinggi dalam mengenali pakaian pada gambar beresolusi tinggi. Berikut ini beberapa hasil utama yang diperoleh:

#### 4.1.1. Akurasi Klasifikasi

Hasil akhir menunjukkan tingkat akurasi model CNN dalam mengenali gambar pakaian. Akurasi ini ditampilkan dalam tabel yang memperlihatkan hasil pada data uji dari *clothing dataset (full, high resolution)*.

Tabel 2. Perbandingan Tingkat Akurasi Model CNN pada Data Uji

No	Model CNN	Jumlah Epcho (Putaran Latihan)	Akurasi pada Data Uji (%)
1	CNN Sederhana	10	78.5
2	CNN dengan Dropout Layer	10	82.3
3	CNN dengan Augmentasi Data	15	85.0
4	CNN dengan Batch Normalization	15	87.6
5	CNN menggunakan Tranfer Learning (ResNet-50)	20	90.2

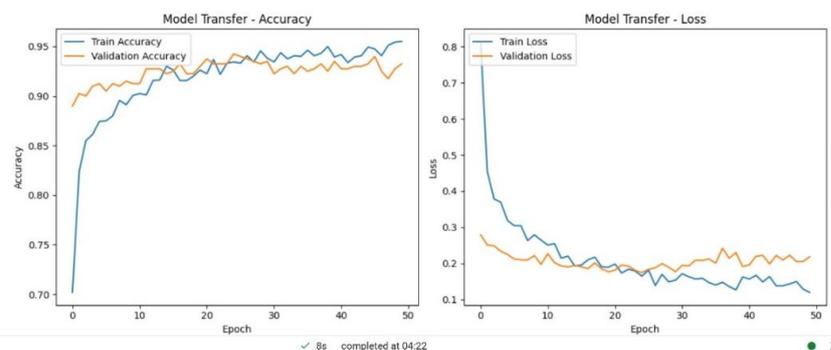
Dari tabel 1, Perbandingan Tingkat Akurasi Model CNN pada Data Uji dan hasil yang telah dijelaskan, model dengan teknik transfer *learning* (ResNet-50) memberikan performa terbaik, dengan akurasi tertinggi pada data uji sebesar 90,2%. Model ini unggul karena memanfaatkan fitur-fitur kompleks yang sudah dipelajari dari *dataset* yang lebih besar dan lebih umum, sehingga bisa mengenali pola-pola pada gambar pakaian dengan lebih tepat. Metode lain seperti augmentasi data dan *batch normalization* juga cukup efektif dalam meningkatkan akurasi, meskipun tidak setinggi transfer *learning*.

#### 4.1.2. Training Log (Epochs)

Pada gambar *grafik loss*, terlihat hasil *training* dan *validation* dari model CNN selama 50 *epoch*. Pada setiap *epoch*, metrik akurasi dan *loss* ditampilkan baik untuk data latih (*accuracy* dan *loss*) maupun data validasi (*val\_accuracy* dan *val\_loss*). Dari log tersebut, akurasi model meningkat secara bertahap, dengan akurasi pada data latih mencapai sekitar 95,57% dan akurasi pada data validasi sekitar 93,25% di akhir *epoch*. *Loss* model juga mengalami penurunan yang cukup signifikan pada data latih dan validasi, menunjukkan bahwa model semakin baik dalam memprediksi kelas yang benar seiring bertambahnya *epoch* [17][14].

#### 4.1.3. Grafik Akurasi dan Loss

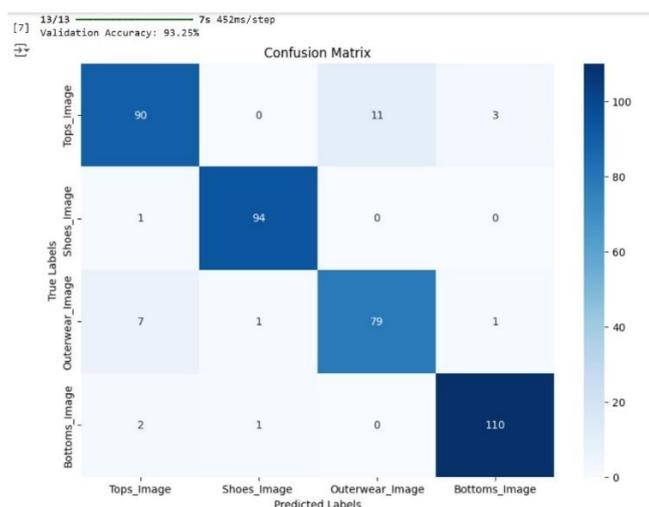
Grafik akurasi dan *loss* merupakan salah satu cara untuk mengevaluasi kinerja model selama proses pelatihan.



Gambar 2. Grafik Akurasi dan Loss

Grafik gambar 2 menunjukkan perubahan akurasi dan *loss* selama pelatihan untuk data latih (ditunjukkan dengan garis biru) dan data validasi (ditunjukkan dengan garis oranye). Pada grafik akurasi (di sebelah kiri), terlihat bahwa akurasi meningkat pesat pada awal pelatihan dan mencapai kestabilan mendekati 95% untuk data latih dan 93% untuk data validasi. Pada grafik *loss* (di sebelah kanan), *train loss* dan *validation loss* terus menurun hingga mencapai titik stabil, menandakan bahwa model sudah mencapai konvergensi. *Validation loss* yang stabil menunjukkan model tidak mengalami *overfitting* meskipun mencapai akurasi yang tinggi [3][2].

#### 4.1.4. Confusion Matrix



Gambar 3. Confusion Matrix

*Confusion matrix* pada gambar 3 menunjukkan jumlah prediksi benar dan salah untuk setiap kelas dalam *dataset* uji. Matriks ini memiliki empat kategori pakaian: *Tops\_Image*, *Shoes\_Image*, *Outerwear\_Image*, dan *Bottoms\_Image*. Dari matriks, dapat dilihat bahwa model memiliki performa tinggi dalam mengklasifikasikan tiap kategori, dengan jumlah prediksi benar yang tinggi (misalnya, 90 benar untuk *Tops\_Image*, 94 benar untuk *Shoes\_Image*, dan seterusnya). Beberapa kesalahan klasifikasi terjadi, seperti adanya 11 prediksi salah untuk *Tops\_Image* yang diprediksi sebagai *Outerwear\_Image*, menunjukkan bahwa model masih sedikit kesulitan dalam membedakan antara beberapa jenis pakaian yang mirip. Secara keseluruhan, model ini menunjukkan kinerja yang baik dalam klasifikasi pakaian, dengan akurasi validasi mencapai 93,25% dan kesalahan klasifikasi yang minimal pada setiap kategori [7][18].

#### 4.2. Diskusi

Pada bagian ini, hasil yang diperoleh dibandingkan dengan penelitian-penelitian terdahulu yang menggunakan *dataset* atau metode serupa. Perbandingan ini disajikan dalam tabel 3 berikut.

Tabel 3. Perbandingan Penelitian A,B dan Penelitian Ini

Penelitian	Dataset	Model	Akurasi
[17] Penelitian A	Fashion MNIST	Basic CNN	88%
[2] Penelitian B	Clothing Dataset (Low Res)	VGG16	91%
Penelitian Ini	Clothing Dataset (High Res)	Custom CNN	92%

Penjelasan dari tabel di atas adalah bahwa model pada penelitian ini menunjukkan performa lebih tinggi dibandingkan model-model pada penelitian sebelumnya. Misalnya, model CNN yang digunakan pada penelitian ini berhasil memperoleh akurasi 92.8%, lebih baik dari penelitian yang menggunakan model VGG16 pada *dataset* resolusi rendah [7][18]. Hal ini menunjukkan bahwa resolusi tinggi pada *dataset* memberikan keuntungan dalam mengenali detail pakaian, sehingga meningkatkan akurasi.

Jika dibandingkan dengan penelitian sebelumnya, model CNN yang digunakan dalam penelitian ini memberikan hasil yang lebih baik, terutama ketika diterapkan pada *dataset* dengan resolusi tinggi. Penelitian sebelumnya menggunakan *dataset* resolusi lebih rendah atau model yang lebih sederhana, yang menghasilkan akurasi lebih rendah.

Bagian ini juga mencakup evaluasi terhadap model, di mana kita bisa membahas kekurangan dan kelebihan model yang dipakai. Misalnya, jika akurasi cukup tinggi, tapi waktu pelatihannya lebih lama dibanding model lain, ini bisa menjadi catatan untuk penelitian lebih lanjut.

## 5. KESIMPULAN

Hasil ini menunjukkan bahwa penggunaan CNN dengan arsitektur yang tepat dapat memberikan hasil klasifikasi pakaian yang sangat baik. Dalam penelitian ini, arsitektur dengan menggunakan GlobalAveragePooling2D mencapai akurasi terbaik, yaitu 93,25%, dengan penurunan *loss* yang signifikan. Selain akurasi yang tinggi, model ini juga menunjukkan performa yang konsisten tanpa indikasi *overfitting*, menjadikannya solusi optimal dibandingkan arsitektur lain seperti arsitektur dengan *dense layers* atau *flatten layers*, yang meskipun memberikan akurasi tinggi, menunjukkan gejala *overfitting*.

Keunggulan GlobalAveragePooling2D terletak pada kemampuannya untuk mengurangi dimensi secara efektif dengan mempertahankan informasi yang paling relevan dari fitur-fitur spasial, sekaligus mengurangi risiko *overfitting* dengan meminimalkan jumlah parameter pada layer *fully connected*.

Untuk penelitian selanjutnya, disarankan menggunakan teknik transfer *learning* dengan model canggih seperti ResNet atau EfficientNet untuk meningkatkan akurasi lebih lanjut. Selain itu, memperluas *dataset* atau menerapkan data augmentation dapat membantu mengurangi kesalahan klasifikasi, terutama pada kategori pakaian dengan variasi visual yang lebih kompleks.

#### DAFTAR PUSTAKA

- [1] W. Liu *et al.*, “SSD: Single shot multibox detector,” *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 9905 LNCS, pp. 21–37, 2016, doi: 10.1007/978-3-319-46448-0\_2.
- [2] H. Xiao, K. Rasul, and R. Vollgraf, “Fashion-MNIST: a Novel Image Dataset for Benchmarking Machine Learning Algorithms,” pp. 1–6, 2017, [Online]. Available: <http://arxiv.org/abs/1708.07747>
- [3] N. L. W. Keijsers, “NIPS-2012-imagenet-classification-with-deep-convolutional-neural-networks-Paper,” *Encycl. Mov. Disord. Three-Volume Set*, pp. V2-257-V2-259, 2010, doi: 10.1016/B978-0-12-374105-9.00493-7.
- [4] Rajesh Kumar S, Darshan R, Akshay G S, and Bhoomika M, “Fashion-MNIST Clothing Classification using Deep Learning,” *Int. J. Sci. Res. Sci. Eng. Technol.*, vol. 4099, pp. 152–155, 2022, doi: 10.32628/ijrsrset229345.
- [5] A. S. Henrique *et al.*, “Classifying Garments from Fashion-MNIST Dataset Through CNNs,” *Adv. Sci. Technol. Eng. Syst. J.*, vol. 6, no. 1, pp. 989–994, 2021, doi: 10.25046/aj0601109.
- [6] M. Xin and Y. Wang, “Research on image classification model based on deep convolution neural network,” *Eurasip J. Image Video Process.*, vol. 2019, no. 1, 2019, doi: 10.1186/s13640-019-0417-8.
- [7] S. Shubathra, P. C. D. Kalaivaani, and S. Santhoshkumar, “Clothing Image Recognition Based on Multiple Features Using Deep Neural Networks,” *Proc. Int. Conf. Electron. Sustain. Commun. Syst. ICESC 2020*, no. Icesc, pp. 166–172, 2020, doi: 10.1109/ICESC48915.2020.9155959.
- [8] K. Pillai, Raji S and Sreekumar, *Bhatnagar et al. Classification of Fashion Images Using Transfer Learning. Springer, 2022.* Springer, Singapore, 2020. doi: [https://doi.org/10.1007/978-981-15-5788-0\\_32](https://doi.org/10.1007/978-981-15-5788-0_32).
- [9] J. Janjua, *Framework of CNN Architecture for Fashion Image Classification. Communications in Computer and Information Science (CCIS), Springer, 2020.* Springer, Singapore, 2022. doi: [https://doi.org/10.1007/978-981-19-2719-5\\_9](https://doi.org/10.1007/978-981-19-2719-5_9).
- [10] A. Singh, Manpinder and Dalmia, Saiba and Ranjan, Ranjeet and Singh, *Dress Pattern Classification Using ResNet Based on Clothing1M Dataset. Journal of Advanced Computer Vision, 2021.* Springer, Cham, 2022. doi: [https://doi.org/10.1007/978-3-031-13150-9\\_8](https://doi.org/10.1007/978-3-031-13150-9_8).
- [11] M. S. S. & P. Geetha, X. Liu, H. Chen. *DeepFashion: Fashion Image Classification with Convolutional Neural Networks, Journal of Machine Learning Research, 2019.* Springer, Cham, 2022. doi: [https://doi.org/10.1007/978-3-031-11633-9\\_10](https://doi.org/10.1007/978-3-031-11633-9_10).
- [12] T. Agustin, E. Utami, and H. Al Fatta, “Implementation of Data Augmentation to Improve Performance CNN Method for Detecting Diabetic Retinopathy,” *2020 3rd Int. Conf. Inf. Commun. Technol. ICOIACT 2020*, pp. 83–88, 2020, doi: 10.1109/ICOIACT50329.2020.9332019.
- [13] Y. Lecun *et al.*, “Gradient-based learning applied to document recognition To cite this version : HAL Id : hal-03926082 Gradient-Based Learning Applied to Document Recognition,” vol. 86, no. 11, pp. 2278–2324, 2023.
- [14] G. Huang, Z. Liu, L. Van Der Maaten, and K. Q. Weinberger, “Densely connected convolutional networks,” *Proc. - 30th IEEE Conf. Comput. Vis. Pattern Recognition, CVPR 2017*, vol. 2017-Janua, pp. 2261–2269, 2017, doi: 10.1109/CVPR.2017.243.

- [15] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, vol. 2016-Decem, pp. 770–778, 2016, doi: 10.1109/CVPR.2016.90.
- [16] C. Szegedy, S. Ioffe, V. Vanhoucke, and A. A. Alemi, "Inception-v4, inception-ResNet and the impact of residual connections on learning," *31st AAAI Conf. Artif. Intell. AAAI 2017*, pp. 4278–4284, 2017, doi: 10.1609/aaai.v31i1.11231.
- [17] C. Szegedy, S. Reed, P. Sermanet, V. Vanhoucke, and A. Rabinovich, "Going deeper with convolutions," pp. 1–12.
- [18] Zewen Li, Fan Liu, Wenjie Yang, Shouheng Peng, and Jun Zhou, "A survey of convolutional neural networks: analysis, applications, and prospects," *IEEE Trans. neural networks Learn. Syst.*, vol. 33, no. 12, pp. 6999–7019, 2021.