



Penerapan ResNet-50 CNN untuk Optimalisasi Klasifikasi pada Data Fashion

Arimbi Puspitasari^{a,1,*}, Diana Sava Salsabila^{b,2}, Dwi Roliawati^{b,3}

^{a,b} Sistem Informasi, Uin Sunan Ampel, Surabaya, Indonesia

¹ arimbipuspitasari69068@gmail.com*; ² dianasavasalsabila@gmail.com; ³ dwi_roll@uinsa.ac.id

* arimbipuspitasari69068@gmail.com

ABSTRAK

ARTICLE INFO

Penelitian ini bertujuan untuk menerapkan arsitektur *Convolutional Neural Network (CNN)* berbasis *ResNet-50* dalam klasifikasi gambar produk fashion. Model ini dikembangkan untuk mengenali berbagai kategori produk, seperti kaos, celana, dan sepatu, dengan memanfaatkan konsep *residual learning* yang memungkinkan jaringan mempelajari fitur visual kompleks secara lebih efektif. Metode penelitian meliputi pengumpulan dan pemrosesan data gambar, pelatihan model *CNN* menggunakan *ResNet-50*, serta evaluasi performa menggunakan metrik *accuracy*, *precision*, *recall*, dan *F1-score*. Hasil eksperimen menunjukkan bahwa model mencapai *accuracy* sebesar 99,44% pada data *training* dan 97,83% pada data *testing*, menunjukkan kemampuan generalisasi yang baik terhadap data yang belum pernah dilihat sebelumnya. Evaluasi lebih lanjut menggunakan *confusion matrix* menunjukkan bahwa sebagian besar sampel diklasifikasikan dengan benar, meskipun masih terdapat beberapa kesalahan prediksi pada kategori tertentu. Dengan rata-rata *precision*, *recall*, dan *F1-score* mencapai 98%, model ini terbukti memiliki performa tinggi dalam klasifikasi gambar fashion. Hasil penelitian ini menunjukkan bahwa *ResNet-50* dapat menjadi solusi yang andal untuk sistem rekomendasi produk, katalog digital, dan pengelolaan inventaris berbasis gambar, meskipun masih terdapat ruang untuk peningkatan terutama pada kelas yang sulit diklasifikasikan.

This is an open access article under the [CC-BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license.



Article history

Received: 13 Desember 2024

Revised: 7 Februari 2025

Accepted: 14 Februari 2025

Keywords

Convolutional Neural Network (CNN)

ResNet-50

Klasifikasi Gambar

Fashion

1. Pendahuluan

Dalam beberapa tahun terakhir, teknologi *deep learning*, khususnya *Convolutional Neural Networks (CNN)*, telah menjadi salah satu metode utama dalam pemrosesan citra, menunjukkan kemajuan yang signifikan dalam berbagai aplikasi, termasuk klasifikasi gambar, pengenalan objek, dan diagnosis medis. *CNN* dirancang untuk mengenali pola visual dengan efisiensi tinggi, berkat kemampuannya dalam mengekstraksi fitur dari data citra secara otomatis, tanpa memerlukan pemrosesan fitur manual yang sering kali diperlukan dalam metode tradisional [1][2][3]. Penelitian menunjukkan bahwa *CNN*, termasuk arsitektur yang lebih kompleks seperti *ResNet*, telah berhasil diterapkan dalam berbagai konteks, termasuk segmentasi tumor otak dan analisis citra medis [4][5]. *ResNet-50*, sebagai salah satu varian dari *Residual Networks*, telah terbukti efektif dalam mengatasi



masalah vanishing gradien yang sering muncul pada jaringan yang lebih dalam. Dengan menggunakan teknik sisa pembelajaran, *ResNet-50* memungkinkan pelatihan jaringan yang lebih dalam tanpa kehilangan penting, sehingga meningkatkan *accuracy* dalam klasifikasi informasi citra [6][7].

Dalam konteks efektivitas dan efisiensi, *ResNet-50* menunjukkan kinerja yang lebih baik dibandingkan dengan arsitektur *CNN* lainnya, seperti *VGG16* dan *GoogLeNet*, terutama dalam tugas klasifikasi yang kompleks [8] [9]. Definisi efektif dalam hal ini merujuk pada kemampuan model untuk mencapai *accuracy* tinggi dalam pengenalan pola, sementara efisien mengacu pada kecepatan pelatihan dan penggunaan sumber daya komputasi yang lebih rendah. Misalnya, penelitian menunjukkan bahwa arsitektur ini tidak hanya meningkatkan kinerja dalam pengenalan objek, tetapi juga dalam aplikasi medis, di mana *accuracy* diagnosis sangat penting [2][3]. Lebih lanjut, *CNN* telah digunakan dalam berbagai aplikasi industri dan medis, termasuk dalam pengenalan objek dan analisis citra radiologi. Misalnya, dalam konteks diagnosis *COVID-19*, *CNN* telah digunakan untuk menganalisis citra *X-ray* dan *CT scan*, menunjukkan hasil yang menjanjikan dalam deteksi dan klasifikasi penyakit [10][11]. Penelitian ini menunjukkan bahwa dengan memanfaatkan arsitektur *CNN* yang dalam, seperti *ResNet*, para peneliti dapat mencapai tingkat *accuracy* yang lebih tinggi dalam pengolahan citra dibandingkan dengan metode konvensional [6][10].

Secara keseluruhan, perkembangan teknologi *deep learning*, khususnya *CNN* dan arsitektur seperti *ResNet-50*, telah merevolusi cara kita memproses dan menganalisis citra, memberikan alat yang kuat untuk berbagai aplikasi di bidang medis dan industri. Dengan kemampuan untuk belajar dari data yang besar dan kompleks, *CNN* terus menjadi pilihan utama dalam pengembangan sistem pengolahan citra yang lebih canggih dan efisien [1][2][3].

ResNet-50, yang memiliki 50 lapisan, menggunakan konsep *residual learning* untuk memudahkan pelatihan jaringan yang lebih dalam dan kompleks. Hal ini memungkinkan model untuk belajar dari data dengan lebih efisien dan meminimalkan kesalahan dalam proses pelatihan. *ResNet-50* telah berhasil diterapkan pada berbagai bidang, seperti klasifikasi gambar histopatologi untuk diagnosis kanker payudara [12], pengenalan fitur makanan untuk analisis matriks kompleks [13], dan klasifikasi citra satelit [14].

Dalam industri *fashion*, pengklasifikasian gambar produk pakaian menjadi tantangan tersendiri. Variasi dalam jenis, warna, dan tekstur pakaian memerlukan model yang mampu mengenali pola-pola visual yang halus dan kompleks. Penerapan *ResNet-50* dalam klasifikasi gambar *fashion* menawarkan potensi besar, terutama dengan konsep *transfer learning* yang memungkinkan model untuk memanfaatkan pengetahuan yang telah diperoleh dari *dataset* lain yang lebih umum seperti *ImageNet*. Namun, alasan utama pemilihan *dataset fashion* dalam penelitian ini perlu ditetapkan dengan lebih jelas. Berdasarkan tinjauan literatur, beberapa pendekatan sebelumnya dalam klasifikasi *fashion* masih menghadapi tantangan dalam hal *accuracy* dan generalisasi model terhadap variasi gambar pakaian yang luas. Sebagai contoh, penelitian terdahulu menunjukkan bahwa beberapa model *CNN* mengalami kesulitan dalam membedakan pakaian dengan bentuk dan tekstur yang serupa [15]. Oleh karena itu, penelitian ini berusaha mengevaluasi sejauh mana *ResNet-50* dapat meningkatkan kinerja klasifikasi gambar *fashion* dibandingkan dengan pendekatan sebelumnya, serta menguji efektivitas *transfer learning* dalam mengatasi tantangan klasifikasi gambar dengan variasi tinggi.

Selain itu, *fine-tuning* telah digunakan secara efektif dalam klasifikasi gambar sel malaria, yang menunjukkan keberhasilan model dalam menangani tugas spesifik dengan *accuracy* tinggi [16]. Lebih lanjut, dalam konteks pengolahan citra medis, pendekatan berbasis *ResNet-50* telah diterapkan untuk diagnosis penyakit Alzheimer. Dalam penelitian ini, model *CNN* berbasis *ResNet-50* digunakan untuk menganalisis citra medis, memanfaatkan kemampuan *residual learning* untuk mengenali pola-pola yang tidak mudah terdeteksi dengan metode konvensional. Penggunaan *ResNet-50* dalam diagnosis Alzheimer menunjukkan peningkatan *accuracy* klasifikasi, baik pada gambar medis maupun non-gambar, memberikan kontribusi signifikan dalam mendiagnosis penyakit *neurodegeneratif* dengan lebih cepat dan akurat [17]. Selain itu, penerapan model *deep learning* ini

juga telah menunjukkan hasil yang menjanjikan dalam mengatasi masalah lainnya, seperti diagnosis kelainan atau cacat pada mesin industri, menggunakan pendekatan *transfer learning* untuk mendiagnosis kerusakan berdasarkan citra komponen [18].

Penelitian ini bertujuan menerapkan *ResNet-50*, untuk mengoptimalkan proses klasifikasi gambar pada *dataset fashion*. Dengan menggunakan *ResNet-50*, yang memiliki kemampuan *residual learning* yang unggul, model diharapkan dapat mengenali pola-pola visual dalam gambar produk *fashion* dengan lebih baik dan akurat. *Dataset* yang digunakan dalam penelitian ini terdiri dari berbagai gambar produk *fashion* yang dikategorikan ke dalam kelas-kelas seperti kaos, celana, sepatu, dan sebagainya. Pemilihan *dataset* ini didasarkan pada tantangan klasifikasi unik dalam *fashion*, yang melibatkan kompleksitas pola, tekstur, dan variasi bentuk yang berbeda dibandingkan dengan *dataset* lain seperti pengenalan wajah atau citra medis. Studi sebelumnya telah menunjukkan bahwa *dataset fashion* sering mengalami permasalahan terkait dengan perbedaan pencahayaan, sudut pengambilan gambar, dan variasi tekstur, yang membuat tugas klasifikasi menjadi lebih kompleks dan menantang.

Proses penelitian mencakup beberapa tahapan penting, dimulai dari pengumpulan dan pemrosesan data, pembangunan model menggunakan *ResNet-50*, pelatihan model, serta evaluasi kinerja model melalui metrik-metrik relevan seperti *accuracy*, *precision*, *recall*, dan *F1-score*. Dalam penelitian ini, diharapkan model *CNN* berbasis *ResNet-50* dapat memberikan hasil klasifikasi yang optimal dan dapat diandalkan, serta memberikan kontribusi terhadap pengembangan aplikasi klasifikasi gambar dalam industri *fashion*. Melalui penelitian ini, diharapkan dapat ditemukan pendekatan yang lebih efisien dalam mengklasifikasikan data *fashion*, yang pada gilirannya dapat mendukung berbagai aplikasi praktis seperti sistem rekomendasi produk, katalog digital, dan sistem manajemen inventaris berbasis gambar.

2. Metode Penelitian


Jaringan Saraf Konvolusional (*Convolutional Neural Networks* atau *CNN*) telah merevolusi bidang pemrosesan dan klasifikasi citra melalui arsitekturnya yang unik, yang dirancang untuk mengekstraksi fitur dari gambar secara efektif. *CNN* menggunakan lapisan konvolusi untuk mendeteksi berbagai fitur seperti tepi, tekstur, dan pola yang penting untuk memahami konten gambar. Arsitektur ini biasanya terdiri dari beberapa lapisan konvolusi diikuti oleh lapisan *pooling* yang mengurangi dimensi data, meningkatkan efisiensi komputasi sambil mempertahankan informasi penting. Akhirnya, lapisan *fully connected* digunakan untuk menghasilkan klasifikasi *output*, memungkinkan *CNN* mencapai *accuracy* tinggi dalam tugas pengenalan objek [19] [20].

Salah satu arsitektur terkemuka dalam lanskap *CNN* adalah *ResNet-50*, yang mengatasi masalah gradien menghilang (*vanishing gradient*) yang umum ditemui pada jaringan yang dalam. *ResNet-50* menggunakan pembelajaran *residual* melalui koneksi pintas, memungkinkan gradien mengalir melalui jaringan tanpa degradasi yang signifikan. Pendekatan inovatif ini memungkinkan pelatihan jaringan yang lebih dalam, sehingga meningkatkan kinerja pada tugas-tugas kompleks seperti klasifikasi gambar. *ResNet-50* telah dilatih secara ekstensif pada *dataset* besar seperti *ImageNet*, menjadikannya pilihan yang kuat untuk berbagai aplikasi, termasuk pengenalan pakaian berdasarkan warna dan jenis [19].

Kemajuan terkini dalam *CNN* juga berfokus pada pengoptimalan arsitektur dan peningkatan kinerja mereka. Misalnya, model *CNN* ringan telah dikembangkan untuk meningkatkan efisiensi klasifikasi sambil mempertahankan *accuracy*, terutama di lingkungan dengan sumber daya terbatas [21]. Selain itu, integrasi mekanisme perhatian ke dalam arsitektur *CNN* menunjukkan potensi dalam meningkatkan kemampuan ekstraksi fitur, memungkinkan model untuk fokus pada bagian data *input* yang paling relevan [21]. Perkembangan ini menyoroti evolusi berkelanjutan dari *CNN*, menjadikannya semakin efektif untuk berbagai tugas klasifikasi citra.

Singkatnya, *CNN*, terutama arsitektur seperti *ResNet-50*, telah secara signifikan memajukan bidang klasifikasi citra dengan memanfaatkan teknik pembelajaran mendalam untuk mengekstraksi dan memproses fitur dari gambar secara efisien. Peningkatan dan adaptasi arsitektur *CNN* yang

berkelanjutan memastikan relevansi dan efektivitas mereka dalam menghadapi tantangan pengenalan gambar yang kompleks di berbagai domain.



Gambar. 1 Alur Penelitian

3.1 Pengumpulan Data

Pengumpulan data merupakan langkah krusial dalam penelitian, termasuk dalam konteks klasifikasi gambar pakaian. Dalam penelitian ini, *dataset* yang digunakan adalah "*Fashion Apparel Image Classification Dataset*" yang diunduh dari platform *Kaggle*. *Dataset* ini terdiri dari 5.413 gambar berkualitas tinggi yang menampilkan berbagai jenis pakaian dalam dua warna utama, yaitu hitam dan biru, yang dikategorikan ke dalam 10 kelas. Rinciannya adalah *black dress* (450), *black pants* (871), *black shirt* (715), *black shoes* (766), *black shorts* (328), *blue dress* (502), *blue pants* (798), *blue shirt* (741), *blue shoes* (523), dan *blue shorts* (299). Setelah proses pengunduhan, data disimpan dalam bentuk *DataFrame* yang berisi path gambar dan label kategori masing-masing. Tidak dilakukan proses pemilahan file *non-image* karena *dataset* ini memang hanya terdiri dari gambar. Selanjutnya, data mengalami serangkaian transformasi, termasuk *resize* ke ukuran 224x224, normalisasi, dan konversi ke bentuk *tensor* agar dapat digunakan dalam pemodelan *deep learning*. *Dataset* kemudian dibagi menjadi tiga bagian, yaitu *training set* (80%), *validation set* (10%), dan *test set* (10%), guna memastikan model dapat belajar secara optimal dan diuji dengan baik.

3.2 Pemodelan

Dalam tahap pemodelan, digunakan arsitektur *ResNet-50*, yang merupakan salah satu jenis *Convolutional Neural Network (CNN)* yang telah terlatih sebelumnya. Untuk menyesuaikan dengan *dataset* yang memiliki 10 kategori pakaian, lapisan *fully connected* terakhir dimodifikasi agar menghasilkan 10 *output neurons* dengan aktivasi *softmax*. Proses *training* dilakukan menggunakan *optimizer Stochastic Gradient Descent (SGD)* dengan *Cross-Entropy Loss* sebagai fungsi *loss*. Selain itu, digunakan *scheduler StepLR* untuk menyesuaikan *learning rate* secara bertahap agar proses pelatihan lebih stabil dan efisien.

Model dilatih selama 10 *epoch*, dengan pencatatan *accuracy* dan *loss* di setiap iterasi untuk memantau kinerjanya. Evaluasi dilakukan menggunakan data validasi guna memastikan model tidak mengalami *overfitting*. Model terbaik kemudian disimpan berdasarkan hasil evaluasi pada data validasi, sehingga dapat digunakan untuk menguji performanya pada *dataset* uji dengan hasil yang lebih optimal.

3.3 Evaluasi

Pada tahap evaluasi, model diuji menggunakan *dataset test* dan dianalisis menggunakan beberapa metrik evaluasi utama, yaitu *accuracy*, *precision*, *recall*, *F1-score*, serta *confusion matrix*. Akurasi dihitung dengan rumus sebagai berikut:

$$accuracy = \frac{TP + TN}{TP + TP + FP + FN}$$

di mana *TP* (*True Positive*) adalah jumlah prediksi benar untuk kelas positif, *TN* (*True Negative*) adalah jumlah prediksi benar untuk kelas negatif, *FP* (*False Positive*) adalah jumlah prediksi salah yang diklasifikasikan sebagai positif, dan *FN* (*False Negative*) adalah jumlah prediksi salah yang diklasifikasikan sebagai negatif.

Precision dan *recall* dihitung untuk mengukur kinerja model dalam mengidentifikasi kategori yang benar, dengan rumus sebagai berikut:

$$precision = \frac{TP}{TP + FP}$$

$$recall = \frac{TP}{TP + FN}$$

Precision menunjukkan proporsi prediksi positif yang benar-benar positif, sedangkan *recall* menunjukkan sejauh mana model dapat menangkap seluruh *instance* positif yang ada dalam *dataset*. Untuk menyeimbangkan *precision* dan *recall*, digunakan *F1-score*, yang dirumuskan sebagai:

$$F1 = 2 \times \frac{precision \times recall}{precision + recall}$$


Selain itu, *confusion matrix* digunakan untuk memvisualisasikan distribusi prediksi model terhadap kelas yang sebenarnya. Evaluasi ini bertujuan untuk memastikan bahwa model dapat mengklasifikasikan gambar dengan baik di berbagai kategori.

Hasil evaluasi juga divisualisasikan dalam bentuk grafik *loss* dan *accuracy*, serta contoh prediksi gambar yang dilengkapi dengan *confidence score* untuk memberikan gambaran mengenai kualitas prediksi model. Dari evaluasi yang dilakukan, model menunjukkan performa yang stabil dan mampu mengklasifikasikan pakaian dengan tingkat keakuratan yang tinggi.

3. Hasil dan Pembahasan

3.4 Grafik Loss dan Accuracy

Sebelum membahas performa model *ResNet-50* dalam klasifikasi data *fashion*, penting untuk memahami bahwa evaluasi model tidak hanya bergantung pada satu metrik seperti *accuracy*, tetapi juga melibatkan analisis pola perubahan nilai *loss* dan *accuracy* selama proses pelatihan. Grafik *log Loss* dan *log Accuracy* menjadi alat penting untuk memantau kinerja model, memastikan bahwa model tidak hanya belajar dengan baik dari data *training* tetapi juga mampu menggeneralisasi terhadap data *validation*, sekaligus mendeteksi potensi masalah seperti *overfitting* atau *underfitting* [22] [23].




Gambar 1. Grafik *Loss* dan *Accuracy*

Grafik log *Loss* menunjukkan penurunan nilai *loss* pada data *training* dan *validation* secara konsisten selama proses pelatihan, hingga mencapai stabilitas mendekati nol. Penurunan signifikan di awal *epoch* menunjukkan *learning rate* yang optimal, sementara konvergensi nilai *loss* antara data *training* dan *validation* mengindikasikan tidak adanya gejala *overfitting* atau *underfitting*. Sementara itu, grafik log *Accuracy* menunjukkan peningkatan *accuracy* yang stabil pada kedua jenis data, mencapai 99.44% pada *epoch* terakhir.

ResNet-50, dengan konsep *residual learning*, terbukti mampu menangkap fitur kompleks dalam data *fashion* secara efektif. Hal ini terlihat dari stabilitas pelatihan serta keselarasan performa antara data *training* dan *validation*. Dengan performa yang unggul, stabilitas pelatihan yang baik, dan kemampuan menghindari *overfitting*, model ini membuktikan diri sebagai pilihan optimal untuk klasifikasi data *fashion*, dengan *accuracy* tinggi dan keandalan yang menjanjikan.

3.5 Confusion Matrix

Confusion matrix adalah alat yang penting dalam evaluasi kinerja model klasifikasi, yang memberikan gambaran jelas mengenai seberapa baik model memprediksi setiap kelas dibandingkan dengan hasil aktualnya. Dalam *confusion matrix*, sumbu x merepresentasikan hasil prediksi model (*predicted labels*), sementara sumbu y merepresentasikan label aktual (*true labels*). Setiap sel dalam matriks menunjukkan jumlah sampel yang tergolong dalam kombinasi tertentu, seperti *True Positive* (benar-benar terprediksi dengan tepat), *False Positive*, dan *False Negative* [24].



Gambar 2. *Confusion Matrix*

Pada gambar *confusion matrix* untuk model *ResNet-50 CNN* yang digunakan dalam klasifikasi data *fashion*, sebagian besar prediksi model terletak pada diagonal utama. Hal ini menunjukkan bahwa model berhasil mengklasifikasikan sebagian besar sampel dengan benar ke dalam kategori yang tepat, yang mengindikasikan bahwa model dapat mengenali pola-pola visual dalam gambar produk *fashion* dengan tingkat *accuracy* yang sangat tinggi. Meskipun demikian, beberapa kesalahan klasifikasi masih terjadi di luar diagonal utama, yang biasanya terkait dengan kelas-kelas tertentu yang lebih sulit bagi model untuk mengenali secara tepat.

Namun, jumlah kesalahan klasifikasi ini relatif kecil jika dibandingkan dengan jumlah sampel yang diklasifikasikan dengan benar. Hal ini mencerminkan bahwa model memiliki performa yang sangat baik, meskipun ada kelas yang sedikit lebih menantang. Dengan skor *accuracy* mencapai 97,83%, model *ResNet-50 CNN* menunjukkan potensi besar dalam aplikasi praktis seperti sistem rekomendasi produk, katalog digital, dan pengelolaan inventaris berbasis gambar, di mana tingkat *accuracy* dan keandalan sangat krusial.

Secara keseluruhan, *confusion matrix* ini memperlihatkan bahwa model *ResNet-50-CNN* memiliki *accuracy* yang tinggi, dengan kesalahan minimal, menjadikannya sangat andal dalam klasifikasi gambar *fashion*.

3.6 Laporan Evaluasi

Metrik evaluasi seperti *precision*, *recall*, *F1-score*, dan *accuracy* keseluruhan memegang peran krusial dalam menilai performa model klasifikasi. Metrik-metrik ini tidak hanya memberikan gambaran tentang seberapa akurat model dalam membuat prediksi, tetapi juga menilai keseimbangan antara kemampuannya mendeteksi semua sampel dari suatu kategori (*recall*) dan meminimalkan kesalahan prediksi (*precision*). Kombinasi metrik tersebut memberikan wawasan komprehensif mengenai keandalan

dan efektivitas model, terutama pada *dataset* dengan variasi visual antar kelas yang signifikan [25] [26] [27].

Tabel 1. Performa *ResNet-50* Untuk Klasifikasi *Fashion*

Kelas	<i>Precision</i>	<i>Recal</i>	<i>F1-Score</i>
<i>blue pants</i>	0.98	0.94	0.96
<i>black dress</i>	0.96	0.99	0.98
<i>black shirt</i>	0.97	0.99	0.98
<i>blue shirt</i>	0.97	1.00	0.99
<i>black shorts</i>	1.00	0.97	0.97
<i>blue shorts</i>	0.96	1.00	0.98
<i>blue shoes</i>	0.99	0.98	0.98
<i>black shoes</i>	1.00	0.97	0.99
<i>black pants</i>	1.00	0.98	0.99
<i>blue dress</i>	0.93	0.96	0.95
<i>accuracy</i>			0.98
<i>macro avg</i>	0.98	0.97	0.98
<i>wighted avg</i>	0.98	0.98	0.98

Laporan evaluasi model menunjukkan performa *ResNet-50* yang sangat baik dalam mengklasifikasikan gambar produk *fashion*. Dengan rata-rata *precision*, *recall*, dan *F1-score* masing-masing mencapai 98%, model mampu mengklasifikasikan gambar dengan tingkat *accuracy* dan konsistensi yang tinggi di berbagai kategori. Beberapa kelas, seperti *black short* dan *black shoes*, bahkan mencatatkan *precision* sempurna sebesar 100%, menunjukkan bahwa model mampu mengenali fitur visual khas dari kategori tersebut tanpa menghasilkan banyak *false positives*.

Namun, meskipun *precision* mencapai 100% di beberapa kelas, *F1-score* tertinggi yang dicapai hanya 99%, mencerminkan sedikit ketidakseimbangan antara *precision* dan *recall* pada beberapa kategori. Ketidakseimbangan ini mungkin disebabkan oleh variasi jumlah sampel atau tantangan visual tertentu. Meski demikian, *F1-score* yang tinggi menunjukkan bahwa model tetap mampu menjaga keseimbangan yang baik antara kedua metrik tersebut.

Dengan *accuracy* keseluruhan sebesar 98%, model menunjukkan tingkat keandalan yang sangat tinggi, menjadikannya sangat efektif untuk berbagai aplikasi praktis, seperti sistem rekomendasi produk, katalog digital, dan manajemen inventaris berbasis gambar. Performa yang stabil ini membuktikan bahwa *ResNet-50* adalah pilihan optimal untuk menangani tugas klasifikasi dalam domain *fashion*.

3.7 Pengenalan Objek

Model menunjukkan performa yang sangat baik dalam mengenali objek pada sembilan sampel data uji. Sebagian besar prediksi sesuai dengan label aktual, dengan tingkat *accuracy* yang sangat tinggi, mencapai 100%, seperti pada prediksi untuk kelas *black_shorts*, *blue_pants*, *black_dress*, dan *blue_shirt*. Ini menunjukkan bahwa model, kemungkinan besar berbasis arsitektur *ResNet-50*, sangat efektif dalam mengenali pola visual yang spesifik pada gambar produk *fashion*, sehingga dapat menghasilkan prediksi yang sangat akurat untuk sebagian besar kategori.



Gambar 3. Pengenalan Objek

Model menunjukkan performa yang sangat baik dalam mengenali objek pada sembilan sampel data uji, dengan sebagian besar prediksi sesuai dengan label aktual. Tingkat *accuracy* mencapai 100% untuk kategori seperti *black_shorts*, *blue_pants*, *black_dress*, dan *blue_shirt*. Hal ini menegaskan bahwa model, kemungkinan besar berbasis arsitektur *ResNet-50*, sangat efektif dalam mengenali pola visual spesifik pada gambar produk *fashion*, sehingga mampu menghasilkan prediksi yang sangat akurat untuk sebagian besar kategori.

Namun, terdapat satu kasus di mana *accuracy* model lebih rendah, yaitu pada prediksi kategori *black_dress* dengan *accuracy* 74%. Meskipun prediksi ini tetap sesuai dengan label aktual, nilai *accuracy* yang lebih rendah dibandingkan dengan sampel lainnya menunjukkan bahwa model menghadapi tantangan tertentu dalam mengenali pola visual pada kategori tersebut. Faktor-faktor seperti variasi tekstur, pencahayaan, atau fitur visual lainnya mungkin menjadi penyebab kesulitan model.

Secara keseluruhan, meskipun ada sedikit penurunan *accuracy* pada kategori tertentu, hasil ini tetap mencerminkan kemampuan model yang kuat dalam mengklasifikasikan data *fashion* secara umum. Performa yang sangat baik ini menunjukkan bahwa model sudah bekerja secara optimal, namun masih ada ruang untuk perbaikan, seperti melakukan *fine-tuning* atau memperkaya *dataset* dengan lebih banyak variasi gambar pada kategori-kategori yang lebih sulit. Langkah-langkah ini dapat meningkatkan kinerja model secara keseluruhan dan menjadikannya lebih andal untuk berbagai aplikasi praktis.

4. Kesimpulan

Penelitian ini menunjukkan bahwa model *Convolutional Neural Network (CNN)* berbasis arsitektur *ResNet-50* memiliki performa yang sangat baik dalam mengklasifikasikan data *fashion*. Berdasarkan grafik *loss* dan *accuracy* pada data *training* dan *validasi*, model menunjukkan penurunan *loss* yang konsisten dan peningkatan *accuracy* yang stabil. Pada data *training*, *accuracy* model mencapai 99,44% pada *epoch* terakhir, yang menandakan kemampuan model untuk belajar dari data dengan sangat efektif. Namun, saat diuji menggunakan data *testing* yang belum pernah dilihat sebelumnya, model mencapai *accuracy* 97,83%, yang mencerminkan kemampuan generalisasi model di luar data *training*. Evaluasi lebih lanjut menggunakan metrik *precision*, *recall*, dan *F1-score* menunjukkan hasil yang sangat tinggi, dengan rata-rata mencapai 98%, yang mengindikasikan bahwa model tidak hanya akurat tetapi juga andal dalam mengidentifikasi kelas yang berbeda.

Dalam kesimpulan ini, *accuracy* 97,83% pada data *testing* digunakan sebagai pedoman utama untuk menilai kinerja model, karena *accuracy* ini lebih mencerminkan kemampuan model dalam mengklasifikasikan data yang tidak terlihat sebelumnya. Sedangkan *accuracy* 99,44% pada data *training* hanya menunjukkan seberapa baik model belajar dari data yang sudah dikenalnya. *Confusion matrix* mengungkapkan bahwa model berhasil mengklasifikasikan sebagian besar data

dengan benar, meskipun terdapat sedikit kesalahan pada beberapa kelas tertentu. Pengenalan Objek juga memperlihatkan kemampuan model dalam mengenali fitur visual kompleks dari gambar dengan tingkat *accuracy* yang tinggi. Secara keseluruhan, hasil penelitian ini membuktikan bahwa *ResNet-50* adalah pilihan yang efektif dan dapat diandalkan untuk tugas klasifikasi gambar pakaian, namun tetap ada ruang untuk perbaikan, terutama pada kelas-kelas yang sering keliru terklasifikasi.

References

- [1] A. Kurniawan, E. Erlangga, T. Tanjung, F. Ariani, Y. Aprilinda, and R. Y. Endra, "Review of Deep Learning Using Convolutional Neural Network Model," in *Conference on Industrial Sciences, Engineering and Technology toward Digital Era (eICISSET 2023)*, Trans Tech Publications Ltd, Mar. 2024, pp. 49–55. doi: 10.4028/p-kzq3xe.
- [2] G. Litjens *et al.*, "A survey on *deep learning* in medical image analysis," *Medical Image Analysis*, vol. 42. Elsevier B.V., pp. 60–88, Dec. 2020. doi: 10.1016/j.media.2017.07.005.
- [3] D. Shen, G. Wu, and H. Il Suk, "Deep Learning in Medical Image Analysis," *Annu. Rev. Biomed. Eng.*, vol. 19, no. Volume 19, 2017, pp. 221–248, Jun. 2020, doi: 10.1146/ANNUREV-BIOENG-071516-044442/CITE/REFWORKS.
- [4] S. Hussain, S. M. Anwar, and M. Majid, "Segmentation of glioma tumors in brain using deep convolutional neural network," *Neurocomputing*, vol. 282, pp. 248–261, Mar. 2020, doi: 10.1016/j.neucom.2017.12.032.
- [5] D. Bordoloi, "A Deep Learning-based Approach for Medical Image Analysis and Diagnosis," <https://www.publishoa.com/index.php/journal/article/view/1436>.
- [6] M. Z. Che Azemin, R. Hassan, M. I. Mohd Tamrin, and M. A. Md Ali, "COVID-19 Deep Learning Prediction Model Using Publicly Available Radiologist-Adjudicated Chest X-Ray Images as Training Data: Preliminary Findings," *Int. J. Biomed. Imaging*, vol. 2020, 2020, doi: 10.1155/2020/8828855.
- [7] H. Alaeddine and M. Jihene, "Deep Residual Network in Network," *Comput. Intell. Neurosci.*, vol. 2021, 2021, doi: 10.1155/2021/6659083.
- [8] N. ALHAWAS and Z. TÜFEKÇİ, "The Effectiveness of Transfer Learning and Fine-Tuning Approach for Automated Mango Variety Classification," *Eur. J. Sci. Technol.*, Mar. 2022, doi: 10.31590/ejosat.1082217.
- [9] B. BEKTAŞ EKİCİ and S. T. USTAOĞLU, "Deep Learning for Physical Damage Detection in Buildings: A Comparison of Transfer Learning Methods," *Turkish J. Sci. Technol.*, vol. 18, pp. 291–299, Sep. 2023, doi: 10.55525/tjst.1291814.
- [10] T. Zebin and S. Rezvy, "COVID-19 detection and disease progression visualization: Deep learning on chest X-rays for classification and coarse localization," *Appl. Intell.*, vol. 51, no. 2, pp. 1010–1021, Feb. 2021, doi: 10.1007/S10489-020-01867-1/FIGURES/8.
- [11] A. Sharma, S. Rani, and D. Gupta, "Artificial Intelligence-Based Classification of Chest X-Ray Images into COVID-19 and Other Infectious Diseases," *Int. J. Biomed. Imaging*, vol. 2020, no. 1, p. 8889023, Jan. 2020, doi: 10.1155/2020/8889023.
- [12] Q. A. Al-haija, "Breast Cancer Diagnosis in Histopathological Images Using *ResNet-50* Convolutional Neural Network," vol. 50, 2020.

- [13] Y. Liu, H. Pu, and D. Sun, “Trends in Food Science & Technology Efficient extraction of deep image features using convolutional neural network (CNN) for applications in detecting and analysing complex food matrices,” *Trends Food Sci. Technol.*, vol. 113, no. April, pp. 193–204, 2021, doi: 10.1016/j.tifs.2021.04.042.
- [14] A. Shabbir *et al.*, “Satellite and Scene Image Classification Based on Transfer Learning and Fine Tuning of *ResNet-50*,” vol. 2021, 2021, doi: 10.1155/2021/5843816.
- [15] B. Kolisnik, I. Hogan, and F. Zulkernine, “Condition-CNN: A hierarchical multi-label *fashion* image classification model,” *Expert Syst. Appl.*, vol. 182, no. May, p. 115195, 2021, doi: 10.1016/j.eswa.2021.115195.
- [16] A. S. B. Reddy and D. S. Juliet, “Transfer Learning with *ResNet-50* for Malaria Cell-Image Classification,” no. August, 2020, doi: 10.1109/ICCSP.2019.8697909.
- [17] D. A. Hakim, A. Jamal, A. S. Nugroho, A. A. Septiandri, and B. Wiweko, “Embryo Grading after In Vitro Fertilization using YOLO,” *Lontar Komput. J. Ilm. Teknol. Inf.*, vol. 13, no. 3, p. 137, 2022, doi: 10.24843/lkjiti.2022.v13.i03.p01.
- [18] L. Qin, Y. Yang, D. Huang, N. Zhu, H. Yang, and Z. Xu, “Visual Tracking With Siamese Network Based on Fast Attention Network,” *IEEE Access*, vol. 10, pp. 35632–35642, 2022, doi: 10.1109/ACCESS.2022.3163717.
- [19] S. Iqbal and A. N. Qureshi, “A Heteromorphous Deep CNN Framework for Medical Image Segmentation Using Local Binary Pattern,” *IEEE Access*, vol. 10, pp. 63466–63480, 2022, doi: 10.1109/ACCESS.2022.3183331.
- [20] A. Ansari, S. Raees, and N. Rahman, “Tree-Based Convolutional Neural Networks for Image Classification,” in *Proceedings of the 3rd International Conference on ICT for Digital, Smart, and Sustainable Development, ICIDSSD 2022, 24-25 March 2022, New Delhi, India*, EAI, 2023. doi: 10.4108/eai.24-3-2022.2318997.
- [21] C. Shi, X. Zhao, and L. Wang, “A multi-branch feature fusion strategy based on an attention mechanism for remote sensing image scene classification,” *Remote Sens.*, vol. 13, no. 10, 2021, doi: 10.3390/rs13101950.
- [22] G. M. M. Alshmrani, Q. Ni, R. Jiang, H. Pervaiz, and N. M. Elshennawy, “A *deep learning* architecture for multi-class lung diseases classification using chest X-ray (CXR) images,” *Alexandria Eng. J.*, vol. 64, pp. 923–935, 2023, doi: 10.1016/j.aej.2022.10.053.
- [23] S. Farhadpour, T. A. Warner, and A. E. Maxwell, “Selecting and Interpreting Multiclass *Loss* and *Accuracy* Assessment Metrics for Classifications with Class Imbalance: Guidance and Best Practices,” *Remote Sens.*, vol. 16, no. 3, pp. 1–22, 2024, doi: 10.3390/rs16030533.
- [24] S. Sathyanarayanan and B. R. Tantri, “Confusion Matrix-Based Performance Evaluation Metrics,” vol. 27, no. 4, 2024.
- [25] R. Rani Saritha and R. Gunasundari, “ENHANCED TRANSFORMER-BASED DEEP KERNEL FUSED SELF ATTENTION MODEL FOR LUNG NODULE SEGMENTATION AND CLASSIFICATION,” *Arch. Tech. Sci.*, vol. 31, pp. 175–191, Oct. 2024, doi: 10.70102/afts.2024.1631.175.
- [26] B. Subramanian, B. Olimov, S. M. Naik, S. Kim, K. H. Park, and J. Kim, “An

-
- integrated mediapipe-optimized GRU model for Indian sign language recognition,” *Sci. Rep.*, vol. 12, no. 1, pp. 1–16, 2022, doi: 10.1038/s41598-022-15998-7.
- [27] J. T. Samudra, R. Rosnelly, and Z. Situmorang, “Comparative Analysis of SVM and Perceptron Algorithms in Classification of Work Programs,” *MATRIK J. Manajemen, Tek. Inform. dan Rekayasa Komput.*, vol. 22, pp. 285–298, Mar. 2023, doi: 10.30812/matrik.v22i2.2479.