

Klasifikasi Motif Kain Jumputan Palembang Menggunakan Metode CNN dengan Arsitektur Resnet-50

Muhammad Mauladi¹, Dedy Hermanto²

¹Program Studi Informatika, Universitas Multi Data Palembang, Palembang, Indonesia

²Program Studi Teknik Elektro, Universitas Multi Data Palembang, Palembang, Indonesia

Email : muhammadmauladi@mhs.mdp.ac.id, dedy@mdp.ac.id

Article Information

Article history:

Received 31 October 2025

Revised 25 November 2025

Accepted 31 November 2025

Available 30 December 2025

Keywords

CNN
ResNet-50
transfer learning
Image Classification
Palembang Tie-dye Fabric
Traditional textile Motifs

Corresponding Author:

Muhammad Mauladi,
Universitas Multi Data Palembang,
Email :
muhammadmauladi@mdp.ac.id

Abstract

This study develops an automated classification system for Palembang jumputan textile motifs based on computer vision to address inter-motif pattern similarities that often challenge non-expert users and hinder the digital documentation of textile cultural heritage. Unlike traditional textile studies that typically employ generic Convolutional Neural Networks (CNNs), this research applies transfer learning using the ResNet-50 architecture on a primary dataset consisting of five motif classes: lilin, titik 7, titik 9, bunga tabur, and akoprin daun. The dataset is divided into training, validation, and testing sets, followed by preprocessing and image augmentation to enhance data variability. The model is trained with learning rate tuning, and the best configuration achieves a training accuracy of 95.57%, a validation accuracy of 87.33%, and a testing accuracy of 88%. Evaluation using a classification report and confusion matrix indicates excellent performance for the titik 9 and bunga tabur motifs, with precision and recall values approaching 1.00, while misclassifications still occur in the lilin motif due to visual similarity. These results confirm the effectiveness of ResNet-50 for jumputan motif classification and support cultural preservation through faster and more consistent motif identification.

Keywords : ResNet-50; transfer learning; image classification; Palembang jumputan; traditional textile motifs.

Abstrak

Penelitian ini mengembangkan sistem klasifikasi otomatis motif kain jumputan Palembang berbasis computer vision untuk mengatasi kemiripan pola antarmotif yang menyulitkan pengguna awam dan menghambat dokumentasi digital warisan tekstil. Berbeda dari studi tekstil tradisional yang umumnya memakai CNN generik, penelitian ini menerapkan transfer learning menggunakan arsitektur ResNet-50 pada dataset primer lima kelas motif (lilin, titik 7, titik 9, bunga tabur, dan akoprin daun). Data dibagi menjadi pelatihan, validasi, dan pengujian, kemudian dilakukan pra-pemrosesan serta augmentasi untuk meningkatkan variasi citra. Model dilatih dengan penilaian learning rate dan konfigurasi terbaik menghasilkan akurasi pelatihan 95,57%, akurasi validasi 87,33%, dan akurasi pengujian 88%. Evaluasi menggunakan classification report dan confusion matrix menunjukkan performa sangat baik pada motif titik 9 dan bunga tabur (presisi dan recall mendekati 1,00), sementara kesalahan masih terjadi pada motif lilin akibat kemiripan karakter visual. Hasil ini menegaskan efektivitas ResNet-50 untuk klasifikasi motif jumputan serta mendukung pelestarian budaya melalui identifikasi motif yang lebih cepat dan konsisten.

Kata Kunci : CNN, ResNet-50; transfer learning; klasifikasi citra; jumputan Palembang; motif tekstil tradisional.

Copyright@2025 Muhammad Mauladi, Dedy Hermanto
This is an open access article under the CC-BY-NC-SA license.



1. Pendahuluan

Indonesia merupakan salah satu negara yang memiliki kekayaan budaya yang sangat beragam, salah satunya tercermin dalam kerajinan kain tradisional. Setiap daerah memiliki corak dan teknik pembuatan kain yang khas, yang tidak hanya berfungsi sebagai busana, tetapi juga mengandung makna filosofis dan identitas budaya masyarakatnya. Salah satu warisan budaya yang masih lestari hingga kini adalah kain jumputan khas Palembang, Sumatera Selatan. Kain ini dibuat dengan teknik *tie-dye* yang menghasilkan pola dan motif unik, di mana setiap motif memiliki nilai simbolis yang merepresentasikan kehidupan sosial, alam, maupun kepercayaan masyarakat setempat (Irwan, 2020).

Seiring perkembangan zaman, motif kain jumputan terus mengalami inovasi. Para pengrajin berupaya menghadirkan variasi baru untuk menyesuaikan dengan kebutuhan pasar dan tren mode yang dinamis. Akibat semakin beragamnya motif yang tersedia justru menghadirkan tantangan tersendiri, baik bagi konsumen maupun penjual. Banyak motif memiliki kesamaan pola secara visual, sehingga sulit dibedakan tanpa pengetahuan khusus. Hal ini dapat menyulitkan konsumen dalam memilih motif yang sesuai dengan preferensi atau kebutuhan, sekaligus membebani penjual untuk menjelaskan variasi secara rinci (Rustiana Dewi et al., 2022).

Dalam konteks ini, teknologi computer vision menawarkan alternatif yang menjanjikan. *Convolutional Neural Network* (CNN) merupakan salah satu metode deep learning yang terbukti efektif dalam mendekripsi, mengekstraksi, dan mengklasifikasikan fitur visual dari citra. CNN bekerja dengan meniru cara kerja sistem visual manusia, di mana pola sederhana seperti tepi atau garis dikenali terlebih dahulu, kemudian digabungkan menjadi pola yang lebih kompleks. Hal ini memungkinkan CNN digunakan secara luas dalam tugas klasifikasi gambar, termasuk dalam pengenalan pola tekstil (Chen et al., 2025).

Lebih lanjut, perkembangan arsitektur CNN telah menghasilkan model yang semakin efisien dan akurat. Salah satu arsitektur yang menonjol adalah *Residual Network* atau *ResNet*, khususnya *ResNet-50*. Keunggulan utama dari *ResNet-50* adalah kemampuannya mengatasi masalah *vanishing gradient* pada jaringan yang sangat dalam dengan memanfaatkan *shortcut connection* atau *residual block*. Dengan struktur yang terdiri atas 50 lapisan, *ResNet-50* mampu mengekstraksi fitur citra secara mendalam tanpa mengorbankan akurasi, sehingga sangat sesuai digunakan untuk klasifikasi citra motif kain yang kompleks (Taye, 2023).

Kajian yang secara spesifik menargetkan klasifikasi motif Kain Jumputan Palembang dengan arsitektur modern (misalnya *ResNet-50*) masih relatif terbatas dan seringkali belum menekankan perumusan *research gap* yang jelas terkait variasi kondisi citra, potensi overfitting, serta pembandingan yang memadai terhadap pendekatan lain. Oleh karena itu, penelitian ini diarahkan untuk mengisi celah tersebut dengan menyusun

dan mengevaluasi model klasifikasi motif Jumputan Palembang berbasis CNN ResNet-50 secara terukur.

Berdasarkan latar belakang yang telah dituliskan sebelumnya, yaitu tentang variasi motif yang dimiliki tiap kain cukup banyak, sehingga mempersulit untuk pengguna awam memahami motif yang ada, penelitian ini bertujuan untuk menerapkan model klasifikasi motif kain jumputan Palembang menggunakan metode CNN dengan arsitektur ResNet-50 berbasis *transfer learning*. Sistem ini diharapkan dapat mempermudah proses pengenalan motif secara otomatis dengan tingkat akurasi yang tinggi. Selain memberikan kontribusi pada bidang teknologi *computer vision* dan *deep learning*, penelitian ini juga berperan penting dalam mendukung pelestarian budaya lokal, khususnya kain jumputan Palembang, melalui pemanfaatan teknologi kecerdasan buatan dalam konteks warisan budaya tradisional.

2. Kajian Terdahulu

Penelitian terkait klasifikasi motif tekstil tradisional menggunakan pendekatan *computer vision* dan *deep learning* telah berkembang pesat dalam beberapa tahun terakhir. Berbagai studi menunjukkan bahwa metode *Convolutional Neural Network* (CNN) mampu mengenali pola visual kompleks pada kain tradisional, seperti batik, songket, dan tenun, dengan tingkat akurasi yang relatif tinggi. Namun demikian, karakteristik dataset, jumlah kelas motif, arsitektur jaringan, serta strategi pelatihan yang digunakan sangat bervariasi, sehingga berdampak langsung pada kemampuan generalisasi model. Pada klasifikasi motif batik menggunakan CNN konvensional melaporkan hasil yang cukup baik dalam mengenali pola visual dasar. Beberapa studi menunjukkan bahwa CNN mampu mencapai akurasi di atas 85% pada klasifikasi motif batik multi kelas. Kelebihan utama pendekatan ini terletak pada kemampuannya mengekstraksi fitur tekstur dan pola tanpa perancangan fitur manual. Namun, keterbatasan penelitian tersebut terletak pada penggunaan arsitektur CNN yang relatif dangkal serta ukuran dataset yang terbatas, sehingga performa model cenderung menurun ketika dihadapkan pada motif dengan tingkat kemiripan visual yang tinggi. Selain itu, sebagian besar studi batik belum mengevaluasi kemampuan generalisasi model secara komprehensif menggunakan data uji terpisah atau teknik validasi silang, sehingga potensi bias pelatihan masih cukup besar (Whisnu Wiratama, 2023).

Penelitian lain mengombinasikan CNN dengan teknik ekstraksi fitur tradisional, seperti *Gray Level Co-occurrence Matrix* (GLCM), untuk meningkatkan akurasi klasifikasi motif tekstil. Pendekatan ini mampu meningkatkan performa pada dataset berukuran kecil, namun memiliki keterbatasan dari sisi skalabilitas dan ketergantungan pada fitur buatan (*hand-crafted features*). Selain itu, metode ini kurang efektif ketika diaplikasikan pada motif tekstil dengan variasi bentuk dan distribusi pola yang kompleks, seperti kain jumputan yang memiliki karakter ikat celup tidak beraturan. Seiring perkembangan deep

learning, beberapa penelitian mulai mengadopsi arsitektur CNN yang lebih dalam melalui pendekatan transfer learning. Studi yang telah dilakukan sebelumnya menunjukkan bahwa penggunaan model pralatin seperti *ResNet-50* dan *VGG-16* mampu meningkatkan akurasi klasifikasi citra dibandingkan CNN konvensional, terutama pada dataset dengan jumlah data terbatas. Keunggulan utama pendekatan ini adalah stabilitas pelatihan dan kemampuan mengekstraksi fitur hierarkis secara lebih mendalam. Namun, sebagian besar penelitian tersebut diterapkan pada domain medis atau objek umum, bukan pada motif tekstil tradisional yang memiliki kemiripan pola antar kelas (Berliani et al., 2023).

Dalam konteks *fine-grained image classification*, di mana perbedaan antar kelas bersifat halus dan sering kali hanya dibedakan oleh detail tekstur, distribusi titik, atau variasi intensitas warna, pemilihan arsitektur jaringan menjadi faktor yang sangat krusial. Motif kain jumputan Palembang memiliki karakteristik *fine-grained*, ditandai oleh kemiripan pola antar motif, variasi pencahayaan akibat proses ikat celup, serta perbedaan tekstur yang tidak selalu konsisten antar sampel. Kondisi ini diperparah oleh keterbatasan dataset primer yang diperoleh melalui dokumentasi lapangan, sehingga memerlukan model yang mampu mengekstraksi fitur diskriminatif secara stabil dan mendalam. Arsitektur *deep residual network* seperti *ResNet-50* dirancang untuk mengatasi permasalahan tersebut melalui mekanisme *residual learning* dan *skip connection*, yang memungkinkan jaringan mempertahankan informasi fitur tingkat rendah sekaligus mempelajari fitur tingkat tinggi secara efektif. Sejumlah penelitian menegaskan bahwa *ResNet-50* memiliki keunggulan dalam menangani tugas klasifikasi citra *fine-grained*, terutama ketika dikombinasikan dengan pendekatan *transfer learning* dan augmentasi data. *Transfer learning* memungkinkan pemanfaatan bobot pralatin dari dataset berskala besar seperti *ImageNet*, sehingga meningkatkan kemampuan generalisasi model pada domain baru dengan data terbatas. Sementara itu, augmentasi data berperan penting dalam meningkatkan ketahanan model terhadap variasi pencahayaan, orientasi, dan tekstur permukaan kain (Yang et al., 2023).

Dalam konteks tekstil tradisional Palembang, penelitian sebelumnya menerapkan CNN berbasis *ResNet-50* untuk pengenalan motif songket Palembang. Hasil penelitian tersebut menunjukkan bahwa arsitektur *deep residual network* mampu mengenali motif songket dengan akurasi tinggi. Meskipun demikian, songket memiliki karakteristik visual yang berbeda dengan kain jumputan, terutama dari segi struktur pola yang lebih simetris dan repetitif. Dengan demikian, hasil tersebut belum dapat digeneralisasi secara langsung pada klasifikasi motif kain jumputan yang memiliki pola lebih acak dan kemiripan antar kelas yang tinggi (Dwinora Cahyati & Devella, 2024).

Berdasarkan pemetaan literatur tersebut, dapat disimpulkan bahwa *state of the art* penelitian klasifikasi motif tekstil tradisional didominasi oleh studi pada batik dan songket, dengan variasi metode mulai dari CNN konvensional, CNN berbasis fitur

tekstur, hingga *transfer learning* menggunakan arsitektur *deep residual*. Namun, masih terdapat keterbatasan utama, yaitu (1) minimnya penelitian yang secara spesifik membahas motif kain jumputan Palembang, (2) belum adanya kajian mendalam mengenai kemampuan ResNet-50 dalam membedakan motif jumputan yang memiliki kemiripan pola tinggi, serta (3) keterbatasan dataset primer yang terdokumentasi secara sistematis. Oleh karena itu, penelitian ini mengisi celah penelitian tersebut dengan menyusun dataset primer motif kain jumputan Palembang yang terdiri dari lima kelas utama dan menerapkan CNN berbasis ResNet-50 dengan pendekatan *transfer learning*. Berbeda dengan penelitian sebelumnya, studi ini secara khusus mengevaluasi kemampuan model dalam menangani kemiripan pola antar motif serta menganalisis pengaruh parameter pelatihan terhadap stabilitas dan generalisasi model. Dengan demikian, penelitian ini tidak hanya melanjutkan arah riset sebelumnya, tetapi juga memperluas penerapan *deep learning* pada domain tekstil tradisional yang masih jarang dieksplorasi, khususnya kain jumputan Palembang.

Motif Kain Jumputan

Motif kain jumputan Palembang yang digunakan sebagai dataset penelitian. Setiap motif memiliki karakteristik visual yang berbeda, mulai dari pola organik seperti Bunga Tabur dan Akoprin Daun, hingga pola repetitif berbasis titik seperti Titik 7 dan Titik 9. Motif Lilin menampilkan pola bergelombang yang lebih dinamis dan tidak simetris. Keragaman visual ini dipilih untuk memastikan model mampu mengenali perbedaan pola yang halus maupun kompleks dalam proses klasifikasi citra. Motif kain jumputan Palembang tersaji pada Gambar 1.



Gambar 1. Motif Kain Jumputaan

Pengembangan motif kain jumputan Palembang telah banyak dilakukan sebagai upaya pelestarian sekaligus inovasi warisan budaya lokal. Salah satu penelitian memanfaatkan konsep matematika, di mana motif jumputan yang memiliki pola berulang dikaji menggunakan pendekatan fraktal. Dengan menerapkan teori himpunan Julia dan kurva Sierpinski, penelitian tersebut berhasil menghasilkan motif baru yang disebut motif fraktal “lupis” dan “titik tujuh”, yang tetap mempertahankan estetika khas kain jumputan (Rustiana Dewi et al., 2022).

Selain itu, penelitian lain mengusulkan pemanfaatan perangkat lunak matematika GeoGebra untuk mendesain ulang motif jumputan melalui pendekatan geometri. Hasil penelitian menunjukkan bahwa pola dasar motif jumputan dapat dikembangkan secara presisi melalui konstruksi matematis, sehingga diperoleh variasi motif baru tanpa kehilangan identitas tradisional Palembang (Azzahra et al., 2025).

Berbeda dengan penelitian sebelumnya yang berfokus pada inovasi desain motif, penelitian ini menekankan pada klasifikasi motif kain jumputan Palembang menggunakan *deep learning*. Dataset yang digunakan bersifat primer, diperoleh melalui dokumentasi langsung di lapangan, mencakup lima jenis motif utama: lilin, titik 7, titik 9, bunga tabur, dan akoprin daun. Setiap kelas terdiri dari ±200 citra, dengan total sekitar 1000 citra. Dataset disusun dalam format folder terpisah untuk tiap kelas dan dapat diakses melalui tautan yang ada pada sintasi berikut (Muhammad Mauladi, 2025).

Sebagai contoh, jenis kain yang digunakan sebagai dataset penelitian ini, yang menampilkan motif lilin dan motif titik 7. Dataset ini kemudian digunakan sebagai data latih, validasi, dan uji untuk membangun serta mengevaluasi model klasifikasi CNN dengan arsitektur ResNet-50.

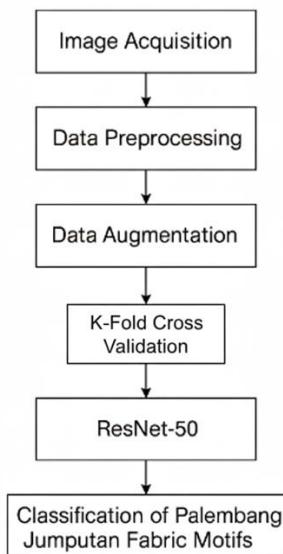
Akuisisi Data

Akuisisi data pada penelitian ini dilakukan melalui pengumpulan citra kain jumputan Palembang secara langsung di sentra produksinya untuk memastikan keaslian dan keragaman data yang digunakan. Proses dokumentasi dilakukan di lokasi produksi aktif yang beralamat di Jl. Aiptu A. Wahab, Gang Pisang No. 28, Kelurahan Tuan Kentang, Kecamatan Seberang Ulu I, Kota Palembang. Melalui wawancara informal dengan pemilik usaha, diperoleh informasi mengenai berbagai motif yang diproduksi, dan penelitian ini kemudian memfokuskan akuisisi pada lima motif yang paling umum dan memiliki karakter visual yang konsisten, yaitu motif lilin, titik 7, titik 9, bunga tabur, dan akoprin daun.

Citra motif diperoleh menggunakan kamera iPhone 15 Pro dengan sensor 48 MP, yang dipilih untuk menangkap detail tekstur dan warna secara optimal. Pemotretan dilakukan dalam kondisi pencahayaan alami tanpa flash guna menjaga ketepatan warna, dengan posisi kamera tegak lurus terhadap kain pada jarak 50–70 cm untuk mengurangi distorsi perspektif. Kain diletakkan pada latar polos agar fokus penangkapan citra tetap

pada motif. Seluruh citra yang diperoleh kemudian menjalani pra-pemrosesan awal berupa *cropping* ke ukuran 224×224 piksel untuk menyesuaikan kebutuhan arsitektur ResNet-50, serta pelabelan manual sesuai kategori masing-masing motif. Setiap kelas motif terdiri dari sekitar 200 citra.

Untuk meningkatkan keragaman dan kualitas dataset sekaligus mengurangi risiko *overfitting*, diterapkan teknik augmentasi data seperti rotasi acak, *horizontal flipping*, *zooming*, *shear transformation*, dan penyesuaian kecerahan. Proses augmentasi ini memungkinkan model mempelajari variasi pola motif secara lebih komprehensif, sehingga meningkatkan kemampuan generalisasi terhadap data uji. Dengan demikian, keseluruhan tahapan akuisisi data menghasilkan dataset yang autentik, representatif, dan siap digunakan untuk pelatihan model CNN berbasis ResNet-50. Untuk *Flowchart* bisa dilihat pada Gambar 2.



Gambar 2. *Flowchart* Arsitektur ResNet-50

Data Preprocessing

Tahap *data preprocessing* merupakan langkah penting untuk memastikan bahwa citra yang digunakan dalam pelatihan model memiliki kualitas dan format yang konsisten. Seluruh citra kain jumputan yang diperoleh melalui proses akuisisi data terlebih dahulu diubah ukurannya menjadi 224×224 piksel, menyesuaikan persyaratan input arsitektur ResNet-50. Proses normalisasi juga dilakukan dengan mengonversi nilai intensitas piksel ke dalam rentang tertentu sehingga distribusi data menjadi lebih stabil dan mempermudah proses pembelajaran model.

Selain itu, citra yang telah dikumpulkan melalui kamera lapangan sering kali mengandung variasi pencahayaan, orientasi, dan latar belakang. Oleh karena itu, langkah pra-pemrosesan juga meliputi penyelarasan (*alignment*) pengambilan area motif melalui *cropping* untuk memastikan bagian motif menjadi fokus utama analisis. Setiap citra

kemudian diberi label secara manual sesuai kategori motif yang telah ditentukan, guna menjamin ketepatan selama proses pelatihan model klasifikasi.

Secara keseluruhan, tahap *preprocessing* ini bertujuan meningkatkan homogenitas, kualitas, dan relevansi data sebelum masuk ke proses augmentasi dan pelatihan model CNN, sehingga performa prediksi akhir dapat dicapai secara lebih optimal.

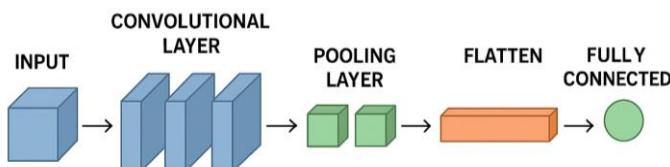
Augmentasi Data

Augmentasi data merupakan salah satu teknik penting dalam pemrosesan citra digital yang bertujuan untuk memperluas jumlah dan variasi dataset tanpa harus melakukan pengumpulan data baru. Teknik ini dilakukan dengan cara menghasilkan citra baru dari citra asli melalui transformasi tertentu, seperti rotasi, *flipping*, *zooming*, perubahan pencahayaan, hingga pergeseran posisi (*shifting*). Pada penelitian berbasis *deep learning*, khususnya *Convolutional Neural Network* (CNN), augmentasi data berperan penting dalam meningkatkan kemampuan generalisasi model. Hal ini disebabkan model tidak hanya belajar dari pola statis, tetapi juga dari variasi baru hasil augmentasi, sehingga risiko *overfitting* dapat dikurangi (Yang et al., 2023).

Klasifikasi motif kain jumputan Palembang, augmentasi data sangat bermanfaat karena motif kain sering kali memiliki pola yang mirip, dan variasi pencahayaan atau sudut pengambilan gambar dapat memengaruhi hasil klasifikasi. Dengan augmentasi, sistem dapat lebih adaptif dalam mengenali motif meskipun terdapat perubahan kondisi visual pada gambar input. Oleh karena itu, augmentasi data menjadi langkah krusial untuk memastikan model *ResNet-50* yang digunakan mampu mencapai akurasi tinggi dan tetap robust terhadap variasi citra.

Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) merupakan salah satu arsitektur yang paling dominan dalam bidang *computer vision*. CNN dirancang untuk secara otomatis mengekstraksi fitur-fitur hierarkis dari data citra mulai dari tepi dan tekstur hingga pola visual kompleks tanpa memerlukan proses ekstraksi fitur manual. Ini dimungkinkan oleh struktur bertingkat yang terdiri dari lapisan konvolusi (*convolutional layers*), aktivasi non-linear (seperti *ReLU*), lapisan pooling untuk mereduksi dimensi, dan lapisan fully connected untuk klasifikasi (Li et al., 2022). Arsitektur *Convolutional Neural Network* (CNN) bisa dilihat pada gambar 3.



Gambar 3. Arsitektur *Convolutional Neural Network* (CNN)

Keunggulan utama CNN terletak pada kemampuannya melakukan pembelajaran *end-to-end* secara langsung dari citra mentah, menjadikannya efektif untuk berbagai tugas seperti klasifikasi gambar, deteksi objek, dan segmentasi citra.

K-Fold Cross Validation

K-Fold Cross Validation adalah teknik validasi model di mana dataset dibagi menjadi K bagian (*fold*) yang serupa ukurannya. Model kemudian dilatih sebanyak K kali, setiap kali menggunakan satu *fold* sebagai data validasi (ujì) dan sisanya sebagai data latih. Nilai performa model yang diperoleh dari tiap *fold* dirata-rata untuk memperkirakan kemampuan generalisasi model secara lebih andal. Metode ini membantu memperkecil bias dan varians dalam evaluasi, terutama saat dataset terbatas atau beragam (Gorriz et al., 2024).

ResNet-50

ResNet-50 merupakan salah satu varian dari arsitektur *Residual Network* (ResNet). Arsitektur ini terdiri dari 50 lapisan yang memanfaatkan mekanisme *residual learning* melalui *shortcut connection* atau *skip connection*. Mekanisme tersebut memungkinkan informasi dari lapisan sebelumnya dialirkan langsung ke lapisan lebih dalam, sehingga mampu mengatasi permasalahan *vanishing gradient* yang umum terjadi pada jaringan dengan kedalaman tinggi. Dengan demikian, ResNet-50 dapat melakukan pelatihan pada model yang jauh lebih dalam tanpa mengalami degradasi performa (Cao et al., 2021).

Dalam bidang *computer vision*, ResNet-50 terbukti unggul dalam mengekstraksi fitur hierarkis dari data citra beresolusi tinggi, serta banyak digunakan pada tugas klasifikasi, deteksi objek, dan pengenalan pola visual. ResNet-50 menunjukkan akurasi tinggi dan

stabilitas pelatihan yang lebih baik dibandingkan arsitektur CNN konvensional, terutama pada dataset yang kompleks dan berskala besar. Kajian terkini juga menegaskan bahwa penggunaan transfer learning berbasis ResNet-50 mampu meningkatkan efisiensi pelatihan sekaligus mempercepat konvergensi model pada domain aplikasi baru, termasuk pada pengenalan pola budaya dan citra medis (Khan et al., 2022).

Klasifikasi Motif Kain Jumputan Palembang

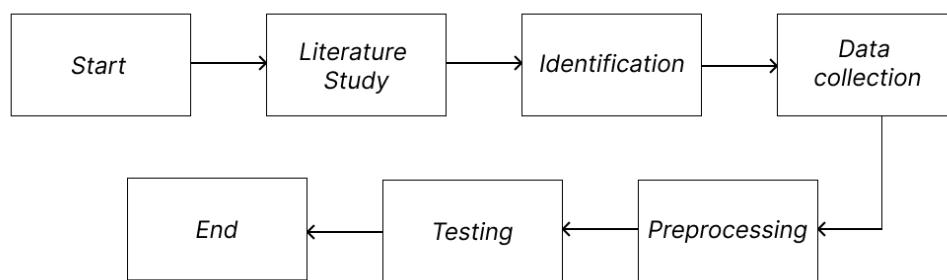
Tahap klasifikasi merupakan bagian akhir dari keseluruhan proses pengolahan citra pada penelitian ini. Setelah citra melalui tahapan ekstraksi fitur menggunakan arsitektur CNN dan ResNet-50, representasi fitur yang dihasilkan kemudian digunakan oleh lapisan klasifikasi untuk mengidentifikasi jenis motif kain jumputan Palembang. Pada tahap ini, fitur-fitur visual yang telah dipelajari model dipetakan ke dalam lima kategori motif, yaitu lilin, titik 7, titik 9, bunga tabur, dan akoprin daun. Setiap kategori

motif memiliki karakteristik pola dan tekstur yang berbeda sehingga efektivitas klasifikasi sangat bergantung pada kemampuan model dalam menangkap perbedaan visual tersebut secara akurat.

Proses pelatihan model dalam tahap klasifikasi dilakukan dengan memanfaatkan *optimizer Adam (Adaptive Moment Estimation)*. Adam dipilih karena kemampuannya dalam mempercepat konvergensi sekaligus menangani ketidakstabilan gradien melalui pemanfaatan momentum dan estimasi varians adaptif. Penggunaan Adam memungkinkan pembaruan bobot yang lebih efisien pada setiap iterasi pelatihan, sehingga model dapat belajar pola motif secara lebih stabil dan efektif dibandingkan algoritma optimisasi standar seperti SGD. Melalui mekanisme adaptif ini, Adam berkontribusi dalam meningkatkan performa klasifikasi dan memperbaiki generalisasi model terhadap data uji.

Tahap klasifikasi menghasilkan output berupa probabilitas pada masing-masing kelas motif melalui fungsi aktivasi softmax, kemudian motif dengan probabilitas tertinggi ditetapkan sebagai hasil prediksi. Kinerja sistem dievaluasi menggunakan metrik akurasi, presisi, recall, dan F1-score untuk memastikan bahwa model tidak hanya mengenali pola secara umum, tetapi juga mampu mengidentifikasi motif secara konsisten di berbagai kondisi citra. Dengan demikian, tahap klasifikasi ini memberikan kontribusi signifikan dalam menghasilkan sistem identifikasi motif kain jumputan Palembang yang cepat, objektif, dan dapat digunakan sebagai dasar pengembangan aplikasi berbasis kecerdasan buatan untuk pelestarian serta digitalisasi warisan budaya tekstil Palembang.

3. Metodologi Penelitian



Gambar 4. Tahapan Metodologi

Studi Literatur

Studi literatur dilakukan untuk mengumpulkan informasi, teori, serta hasil penelitian terdahulu yang relevan berkaitan dengan penelitian kain jumputan. Tujuannya adalah memperoleh pemahaman mendalam terkait metode, model, maupun pendekatan yang dapat digunakan sebagai dasar penelitian.

Identifikasi Masalah

Identifikasi masalah merupakan tahap awal yang sangat penting dalam penelitian untuk merumuskan permasalahan utama yang akan diselesaikan. Pada penelitian ini, masalah yang diangkat berasal dari kesulitan konsumen dalam mengenali motif kain jumputan Palembang yang memiliki pola visual serupa, sehingga sering menimbulkan kebingungan dalam proses pemilihan dan pembelian. Proses identifikasi motif secara manual selama ini bergantung pada keterampilan penjual atau pengrajin, yang tidak selalu tersedia atau mampu menjelaskan secara rinci setiap motif kepada konsumen.

Permasalahan tersebut menimbulkan kebutuhan akan sistem otomatis yang mampu melakukan klasifikasi motif kain jumputan secara cepat, akurat, dan konsisten. Oleh karena itu, penelitian ini memanfaatkan pendekatan *deep learning*, khususnya arsitektur *Convolutional Neural Network* (CNN) dengan *ResNet-50*, untuk merancang perangkat lunak pendekripsi motif. Proses dimulai dari pengumpulan dataset citra motif kain melalui observasi dan dokumentasi lapangan, kemudian dilakukan tahapan *preprocessing*, pelabelan, serta augmentasi data *ImageDataGenerator* untuk meningkatkan keragaman citra. Selanjutnya, data digunakan untuk melatih model *ResNet-50* dengan bantuan teknik *transfer learning* agar model dapat mengekstraksi pola visual dengan lebih efektif.

Model yang telah dilatih kemudian divalidasi dan diuji menggunakan data terpisah untuk memastikan performanya dalam mengenali motif kain jumputan. Evaluasi dilakukan dengan mengukur akurasi, presisi, *recall*, dan *F1-score*, serta didukung oleh analisis *confusion matrix* untuk melihat detail keberhasilan klasifikasi. Dengan demikian, permasalahan awal mengenai sulitnya konsumen mengenali motif jumputan dapat diatasi melalui sistem klasifikasi otomatis ini, yang diharapkan berkontribusi terhadap pelestarian budaya lokal sekaligus mendukung digitalisasi produk tradisional. Perbandingan Penelitian Terkait yang sedang saya lakukan sudah tersaji pada Tabel 1.

Tabel 1. Perbandingan Penelitian Terkait

No.	Ref	<i>Convolutional Neural Network</i> (CNN)	<i>ResNet-50</i>	Fokus Motif	Augmentasi Data
		Kain Jumputan	Kain Jumputan	Kain Jumputan	
1	Klasifikasi Motif Batik Yogyakarta Menggunakan Metode GLCM Dan CNN		✓		
2	Implementasi Metode <i>Convolutional Neural Network</i> (CNN) Dalam Klasifikasi Motif Batik		✓		✓
3	Klasifikasi Motif Batik Menggunakan Metode <i>Convolutional Neural Network</i> (CNN) Dengan <i>Multi Class Clasification</i>		✓		

4	Pengenalan Motif Songket Palembang Menggunakan Convolutional Neural Network dengan Arsitektur ResNet-50	✓	✓		✓
5	Klasifikasi Pola Motif Kain Tenun Bumpak Desa Kampai Seluma Menggunakan Metode CNN	✓			
6	Perbandingan Arsitektur ResNet50 dan ResNet101 dalam Klasifikasi Kanker Serviks pada Citra Pap Smear	✓	✓		✓
7	KLASIFIKASI MOTIF KAIN JUMPUTAN PALEMBANG MENGGUNAKAN METODE CNN DENGAN ARSITEKTUR RESNET-50	✓	✓	✓	✓

Pengumpulan Dataset

Pada tahap ini dilakukan pemotretan dataset berupa citra motif kain jumputan Palembang melalui observasi lapangan dan dokumentasi langsung. Data penelitian dikumpulkan dalam bentuk citra digital berwarna (RGB) yang diperoleh menggunakan kamera utama iPhone 15 Pro dengan panjang fokus 24 mm dan bukaan lensa f/1.78. Citra yang dihasilkan memiliki resolusi tinggi sebesar 4284×5712 piksel atau setara dengan 24 megapiksel, sehingga mampu merepresentasikan detail visual dan ketajaman motif secara optimal. Format berkas yang digunakan adalah HEIF dengan ukuran rata-rata sekitar 4,5 MB per citra. Pengaturan sensitivitas cahaya (ISO) ditetapkan pada nilai 160 untuk meminimalkan noise, sedangkan kecepatan rana sebesar 1/121 detik digunakan guna mengurangi risiko blur akibat pergerakan selama proses pemotretan. Nilai *Exposure Value* (EV) sebesar 0 menunjukkan kondisi pencahayaan yang seimbang tanpa indikasi *overexposure* maupun *underexposure*. Selain itu, profil warna “Kontras Kaya” diterapkan untuk meningkatkan saturasi dan kontras warna, sehingga karakteristik visual dan pola motif kain jumputan dapat tampil lebih jelas. Secara keseluruhan, konfigurasi teknis ini menghasilkan citra dengan kualitas tinggi yang sesuai untuk keperluan ekstraksi fitur dan klasifikasi motif menggunakan model deep learning, seperti ResNet-50. Data yang diperoleh menjadi bahan utama dalam proses pengolahan dan pelatihan model.

Dataset ini berisikan 1000 file yang berformat jpg dengan ukuran 224x224. *Dataset* tersebut dibagi menjadi 5 jenis folder yakni 200 untuk lilin, 200 untuk akoprin daun, 200 untuk bunga tabur, 200 untuk titik7, dan 200 untuk titik9. Rincian lengkap mengenai komposisi dataset disajikan pada Tabel 2.

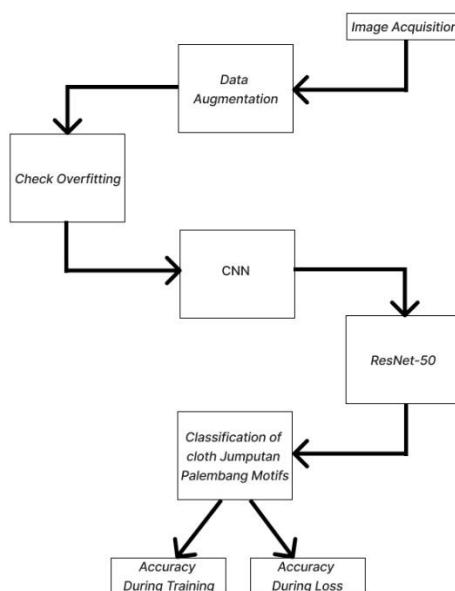
Tabel 2. Dataset Primer

Dataset	Sumber	Format	Ukuran	Jumlah Dataset
Motif Bunga Tabur				200
Motif Akoprin Daun				200
Motif Lilin	Primer	JPG	224x224	200
Motif Titik7				200
Motif Titik9				200
Total				1000

Proses pengambilan citra dilakukan pada jarak sekitar 50–70 cm dengan orientasi kamera tegak lurus terhadap permukaan kain. Kain diletakkan di atas latar belakang polos guna mengurangi gangguan visual dan menjaga fokus pada motif utama. Setiap jenis motif direkam dalam berbagai sudut dan posisi untuk meningkatkan keragaman data, yang diharapkan dapat memperkaya representasi visual serta mendukung proses augmentasi data dalam tahap pelatihan model.

Perancangan

Penelitian ini menggunakan pendekatan eksperimen kuantitatif dengan metode *supervised learning* untuk klasifikasi citra motif kain jumputan Palembang. Rancangan eksperimen disusun secara sistematis dan mengikuti alur pemrosesan sebagaimana ditunjukkan pada Gambar 5, yang mencakup tahap akuisisi citra, augmentasi data, pelatihan model CNN berbasis ResNet-50, proses klasifikasi, serta evaluasi kinerja dan pemantauan *overfitting*.



Gambar 5. Tahapan Pemrosesan Data

Akuisisi Data

Tahap awal penelitian dimulai dengan akuisisi citra kain jumputan Palembang melalui dokumentasi langsung menggunakan kamera digital. Dataset yang dikumpulkan merupakan dataset primer yang terdiri dari lima kelas motif utama. Seluruh citra disimpan dalam format warna RGB.

Kontrol kualitas data dilakukan sebelum pemrosesan lebih lanjut dengan mengeliminasi citra yang mengalami blur berlebih, pencahayaan ekstrem, distorsi sudut, atau kesalahan pelabelan. Langkah ini bertujuan untuk memastikan bahwa data yang digunakan merepresentasikan karakteristik visual motif secara konsisten dan mengurangi noise pada proses pelatihan.

Augmentasi Data

Setiap citra yang lolos kontrol kualitas kemudian melalui tahap prapemrosesan, meliputi *resize* ke ukuran 224×224 piksel agar sesuai dengan input arsitektur I. Normalisasi dilakukan menggunakan fungsi *preprocess_input* ResNet-50, yang menyesuaikan distribusi nilai piksel berdasarkan statistik dataset *ImageNet*.

Pada Penelitian ini, proses augmentasi data untuk memperluas variasi citra motif kain jumputan Palembang dan mengurangi risiko *overfitting* pada model. Augmentasi dilakukan secara *ImageDataGenerator*, yaitu transformasi citra diterapkan secara dinamis saat proses pelatihan tanpa menyimpan hasil citra baru, augmentasi yang digunakan meliputi beberapa transformasi, antara lain rotasi acak hingga $\pm 40^\circ$, pergeseran horizontal dan vertikal hingga 30%, serta menggeser secara acak (*shear*) sebesar 0.4 radian untuk menghasilkan distorsi kemiringan pada citra. Selain itu, dilakukan pula *zoom in* dan *zoom out* hingga 40%, serta penerapan *flipping* horizontal maupun vertikal agar model mampu mengenali pola motif meskipun berada dalam orientasi terbalik. Setiap hasil transformasi kemudian diproses dengan metode *fill mode nearest*, sehingga area kosong akibat transformasi diisi menggunakan nilai piksel terdekat. Penerapan kombinasi augmentasi ini bertujuan untuk memperbanyak keragaman data latih tanpa harus menambah jumlah citra asli, sekaligus meningkatkan kemampuan generalisasi model dalam mengenali pola motif pada kondisi yang bervariasi.

Untuk menjaga validitas eksperimen dan mencegah data *leakage*, pembagian dataset dilakukan sebelum proses augmentasi pada tingkat citra secara acak. Dataset dibagi menjadi 70% data pelatihan, 15% data validasi, dan 15% data pengujian. Data pengujian sepenuhnya dipisahkan dan tidak digunakan dalam proses pelatihan maupun penalaan parameter, sehingga hasil evaluasi mencerminkan kemampuan generalisasi model secara objektif.

Arsitektur Model CNN Berbasis ResNet-50

Model klasifikasi dibangun menggunakan *Convolutional Neural Network* (CNN) berbasis ResNet-50 sebagai *backbone* utama. Sebagai baseline, digunakan ResNet-50 pralatih (*pre-trained*) pada dataset *ImageNet* tanpa modifikasi bobot pada lapisan konvolusional. Lapisan *fully connected* terakhir digantikan dengan lapisan klasifikasi baru yang disesuaikan dengan jumlah kelas motif kain jumputan Palembang.

Pelatihan model dilakukan dalam dua tahap. Pada tahap pertama, seluruh lapisan konvolusional ResNet-50 dibekukan (*freeze*) dan hanya lapisan klasifikasi yang dilatih untuk menyesuaikan representasi fitur dengan domain jumputan. Pada tahap kedua, dilakukan fine-tuning dengan membuka (*unfreeze*) sebagian lapisan atas ResNet-50 secara bertahap untuk memungkinkan model mempelajari fitur tingkat tinggi yang lebih spesifik terhadap pola motif jumputan Palembang.

Setting Pelatihan dan Kontrol Overfitting

Pelatihan model menggunakan fungsi kerugian categorial *cross-entropy* untuk klasifikasi multi kelas. Optimizer yang digunakan adalah Adam dengan variasi *learning rate* sebesar 0.001, 0.001, 0.00001, dan 0.000001. Jumlah epoch yang digunakan adalah 50 dan 100 sesuai skenario eksperimen.

Untuk mengendalikan *overfitting*, diterapkan *early stopping* berdasarkan nilai validation loss serta learning rate scheduler bertipe *reduce-on-plateau*. Pemantauan *training accuracy* dan *training loss* dilakukan secara kontinu selama proses pelatihan, sebagaimana ditunjukkan pada blok *check overfitting* pada diagram.

Prosedur Pelatihan (Pseudocode)

Input : Dataset citra kain jumputan Palembang

Output : Model klasifikasi motif terlatih

1. Akuisisi dan pelabelan citra
2. Kontrol kualitas (hapus blur dan outlier)
3. Resize citra ke 224×224 dan normalisasi preprocess_input
4. Bagi dataset menjadi train, validation, dan test
5. Terapkan augmentasi pada data latih
6. Muat ResNet-50 pralatih ImageNet
7. Ganti lapisan klasifikasi sesuai jumlah kelas
8. Freeze lapisan konvolusional
9. Latih classifier head
10. Unfreeze lapisan atas dan lakukan fine-tuning
11. Pantau loss dan akurasi untuk deteksi overfitting
12. Evaluasi model menggunakan data uji

Evaluasi Model

Evaluasi performa model dilakukan menggunakan metrik akurasi, precision, recall, dan F1-score. Selain itu, *confusion matrix* digunakan untuk menganalisis pola kesalahan klasifikasi antar motif. Evaluasi akhir dilakukan pada data pengujian yang tidak terlibat dalam proses pelatihan

Pengujian

Setelah tahap evaluasi model, hasil evaluasi model akan dihitung dengan menggunakan *Confusion Matrix* dalam menghitung nilai *precision*, *recall*, *f1 score*, dan *accuracy* yang dapat dilihat pada persamaan (1),(2),(3), dan (4).

$$\text{Precision} = \frac{TP}{TP + FP} \times 100\% \quad (1)$$

$$\text{Recall} = \frac{TP}{TP + FN} \times 100\% \quad (2)$$

$$F1 Score = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (3)$$

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \quad (4)$$

Keterangan:

TP: Jumlah data positif yang diklasifikasikan dengan benar oleh sistem

TN: Jumlah data negatif yang diklasifikasikan dengan benar oleh sistem

FN: Jumlah data negatif yang diklasifikasikan dengan salah oleh sistem

FP: Jumlah data positif yang diklasifikasikan dengan salah oleh sistem

4. Hasil dan Pembahasan

Hasil pelatihan model *ResNet-50* menunjukkan bahwa proses klasifikasi motif kain jumputan mencapai performa yang baik pada seluruh tahap evaluasi. Model memperoleh akurasi pelatihan sebesar 95,57%, sementara akurasi validasi berada pada nilai 87,33%. Pada pengujian menggunakan data uji, model menghasilkan akurasi sebesar 88%, yang mengindikasikan kemampuan generalisasi model berada pada kategori kuat dan tidak mengalami penurunan performa signifikan antara data validasi dan data uji. Hasil akurasi *Train*, *Val*, dan *Test* bisa dilihat pada Gambar 6.

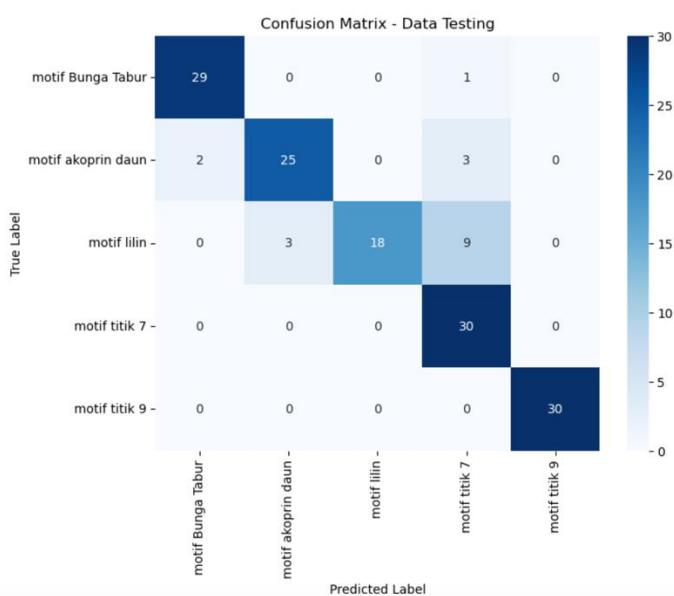
Akurasi Validasi: 87.33%
Akurasi Testing: 88.00%
Akurasi Train: 95.57%
5/5 ————— 7s 1s/step

Gambar 6. Tampilan Hasil Evaluasi Akhir

Hasil *classification report* memperlihatkan bahwa beberapa kelas motif memiliki performa yang sangat baik, khususnya motif titik 9 dan motif bunga tabur, yang masing-masing mencapai nilai precision dan recall mendekati 1,00. Kondisi ini menunjukkan bahwa model mampu mengenali pola visual kedua motif tersebut dengan tingkat konsistensi tinggi. Sebaliknya, motif lilin menunjukkan nilai recall yang lebih rendah (0,60), yang berarti beberapa sampel motif lilin masih diklasifikasikan secara keliru sebagai kelas lain. Hal ini kemungkinan disebabkan oleh kemiripan pola visual motif lilin dengan motif lain seperti titik 7, sehingga menantang proses ekstraksi fitur oleh model.

Tabel 3. Hasil Evaluasi Kinerja Model pada Data Uji

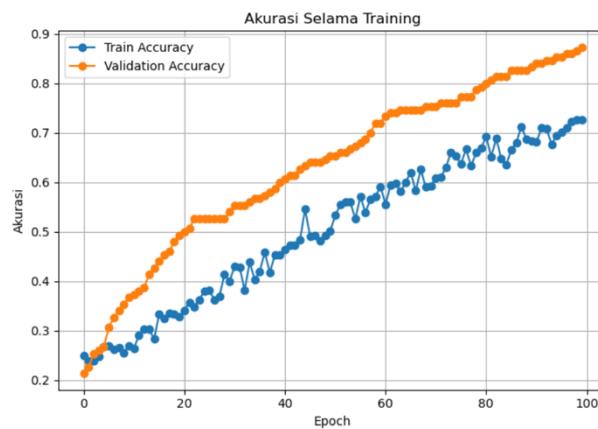
Kelas Motif	Precision	Recall	F1-Score	Support
Bunga Tabur	0.94	0.97	0.95	30
Akoprin Daun	0.89	0.83	0.86	30
Lilin	1.00	0.60	0.75	30
Titik 7	0.70	1.00	0.82	30
Titik 9	1.00	1.00	1.00	30
Akurasi			0.88	150
Macro Avg	0.91	0.88	0.88	150
Weighted Avg	0.91	0.88	0.88	150

Gambar 7. Tampilan *Confusion Matrix*

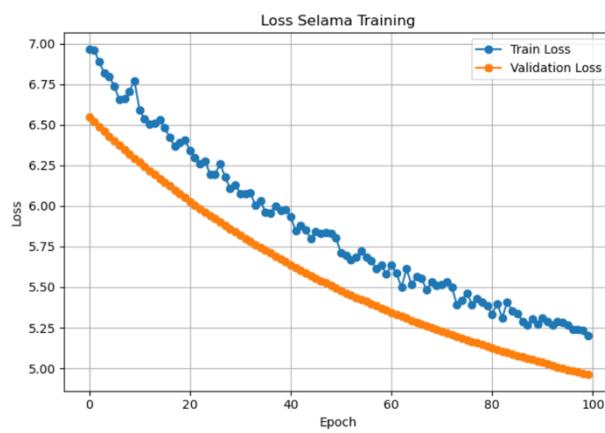
Analisis melalui *confusion matrix* bisa dilihat pada Gambar 7 memperjelas pola kesalahan pada klasifikasi. Kelas motif titik 7 dan motif titik 9 menunjukkan klasifikasi sempurna tanpa adanya salah prediksi. Namun, motif lilin masih menunjukkan tingkat kesalahan klasifikasi yang relatif lebih tinggi, dengan beberapa sampel terprediksi

sebagai motif titik 7. Kondisi ini mengindikasikan bahwa fitur visual pada beberapa sampel lilin memiliki kesamaan struktur dengan motif titik 7, sehingga perlu variasi data tambahan untuk meningkatkan akurasi antar kelas yang memiliki kedekatan pola.

Grafik *accuracy* dan *loss* selama pelatihan hingga 100 epoch menunjukkan pola pembelajaran yang stabil. Akurasi validasi terus meningkat sepanjang proses pelatihan dan mencapai kisaran 85–88% pada akhir epoch. Tren penurunan *loss* pada data pelatihan dan validasi juga berjalan konsisten. Meskipun demikian, terdapat perbedaan antara akurasi pelatihan dan akurasi validasi, yang menunjukkan adanya kecenderungan *overfitting* ringan. *Overfitting* ini dapat disebabkan oleh jumlah dataset yang terbatas serta homogenitas pola pada sebagian gambar, sehingga model cenderung lebih cepat menghafal pola pelatihan daripada belajar variasi secara menyeluruh.



Gambar 8. Grafik *Accuracy*



Gambar 9. Grafik *Loss*

Selain analisis performa model, penelitian ini juga menguji beberapa nilai *learning rate* untuk menentukan konfigurasi pelatihan yang paling optimal. Variasi *learning rate* yang diuji meliputi 0.001, 0.0001, 0.00001, dan 0.000001. Hasil pengujian menunjukkan bahwa *learning rate* yang lebih tinggi seperti 0.001 menyebabkan ketidakstabilan

pembelajaran. Model menunjukkan fluktuasi besar dalam akurasi dan *loss*, menandakan bahwa langkah pembaruan bobot terlalu besar sehingga melampaui titik minimum fungsi *loss*. Pada *learning rate* 0.0001, stabilitas model mulai meningkat tetapi masih terdapat inkonsistensi pada tahap awal pelatihan. Hasil Uji bisa dilihat pada Tabel 4.

Tabel 4. Hasil Uji ResNet-50

Learning Rate	Batch	Epoch	Train Accuracy	Validation Accuracy	Testing Accuracy
0.001	32	50	100%	100%	100%
0.001	32	100	100%	100%	100%
0.0001	32	50	100%	100%	100%
0.0001	32	100	100%	100%	100%
0.00001	32	50	99.71%	100%	100%
0.00001	32	100	99.71%	100%	100%
0.000001	32	50	75.57%	65.33%	66.67
0.000001	32	100	95.57%	87.33%	88%

Saat *learning rate* diturunkan menjadi 0.00001, performa model semakin membaik dengan tren konvergensi yang lebih stabil. Namun, nilai ini masih belum menghasilkan performa optimal dan menunjukkan kecenderungan *overfitting* pada akhir pelatihan. Nilai *learning rate* 0.000001 kemudian memberikan performa terbaik di antara seluruh percobaan. Model menunjukkan peningkatan akurasi yang stabil, penurunan *loss* yang konsisten, serta tidak mengalami fluktuasi berlebihan. Konfigurasi ini memungkinkan proses pembelajaran berlangsung lebih halus dan terkontrol sehingga model berhasil mencapai akurasi pelatihan 95,57%, akurasi validasi 87,33%, dan akurasi pengujian 88%. Temuan ini mengonfirmasi bahwa *learning rate* 0.000001 merupakan konfigurasi paling sesuai untuk penelitian ini karena memberikan kestabilan pembelajaran sekaligus kemampuan generalisasi yang optimal.

Secara keseluruhan, model ResNet-50 terbukti mampu melakukan klasifikasi lima motif kain jumputan Palembang dengan akurasi yang kompetitif. Temuan ini menegaskan bahwa penggunaan arsitektur deep learning dengan fine-tuning dan pemilihan *learning rate* yang tepat dapat memberikan hasil yang efektif dalam identifikasi motif kain tradisional. Untuk penelitian selanjutnya, peningkatan dataset dan variasi augmentasi dapat dilakukan guna mengurangi *overfitting* serta meningkatkan akurasi pada setiap kelas yang masih mengalami kesalahan prediksi.

Penelitian ini dirancang untuk menjawab tiga pertanyaan penelitian utama, yaitu: (1) bagaimana kinerja CNN berbasis ResNet-50 dalam mengklasifikasikan motif kain jumputan Palembang yang memiliki kemiripan pola visual, (2) sejauh mana pendekatan *transfer learning* meningkatkan performa klasifikasi, dan (3) bagaimana pengaruh parameter pelatihan terhadap stabilitas dan generalisasi model.

Menjawab pertanyaan penelitian pertama, hasil eksperimen menunjukkan bahwa CNN berbasis *ResNet-50* mampu mengklasifikasikan lima motif kain jumputan Palembang dengan tingkat akurasi pengujian sebesar 88%. Nilai ini menunjukkan bahwa arsitektur *ResNet-50* efektif dalam menangkap perbedaan pola *fine-grained* antar motif, meskipun terdapat kemiripan visual yang tinggi. Kinerja ini diperkuat oleh hasil *classification report* yang menunjukkan nilai precision dan recall mendekati 1,00 pada motif titik 9 dan bunga tabur, yang mengindikasikan kemampuan model dalam mengenali pola motif yang memiliki karakteristik visual konsisten.

Untuk menjawab pertanyaan penelitian kedua, penerapan *transfer learning* terbukti berperan penting dalam meningkatkan stabilitas dan akurasi pelatihan. Model yang memanfaatkan bobot pralatin *ResNet-50* dari *ImageNet* menunjukkan konvergensi yang lebih stabil dibandingkan pendekatan CNN konvensional yang dilatih dari awal. Hal ini terlihat dari tren peningkatan akurasi validasi yang konsisten serta penurunan *loss* yang relatif seimbang antara data pelatihan dan validasi. Temuan ini mengonfirmasi bahwa *transfer learning* sangat relevan digunakan pada klasifikasi motif tekstil tradisional dengan dataset primer yang terbatas.

Pertanyaan penelitian ketiga berkaitan dengan pengaruh parameter pelatihan, khususnya *learning rate* dan jumlah epoch. Hasil pengujian menunjukkan bahwa *learning rate* 0.000001 dengan 100 epoch memberikan performa paling stabil dan optimal dibandingkan konfigurasi lainnya. *Learning rate* yang lebih besar cenderung menghasilkan fluktuasi akurasi dan *loss*, sedangkan *learning rate* yang terlalu kecil pada epoch rendah menyebabkan konvergensi berjalan lambat. Dengan demikian, hasil ini menegaskan bahwa pemilihan parameter pelatihan yang tepat merupakan faktor krusial dalam meningkatkan kemampuan generalisasi model.

Jika dibandingkan dengan penelitian terdahulu pada klasifikasi motif batik menggunakan CNN konvensional, yang umumnya melaporkan akurasi di kisaran 80–85%, hasil penelitian ini menunjukkan performa yang sebanding bahkan lebih stabil, meskipun diaplikasikan pada motif jumputan yang memiliki tingkat kemiripan pola lebih tinggi. Studi sebelumnya banyak menggunakan arsitektur CNN dangkal atau mengombinasikan CNN dengan fitur tekstur seperti GLCM, yang cenderung kurang optimal dalam menangani pola ikat celup yang tidak teratur.

Dibandingkan dengan penelitian pengenalan motif songket Palembang menggunakan *ResNet-50*, hasil penelitian ini menunjukkan bahwa arsitektur deep residual network tetap efektif meskipun diterapkan pada kain jumputan yang memiliki struktur pola lebih acak dan tidak simetris. Hal ini memperluas temuan sebelumnya dengan menunjukkan bahwa *ResNet-50* tidak hanya cocok untuk motif tekstil yang repetitif seperti songket, tetapi juga untuk motif *fine-grained* dengan variasi tekstur dan pencahayaan yang tinggi.

Meskipun penelitian ini tidak secara langsung membandingkan ResNet-50 dengan arsitektur lain seperti MobileNet atau VGG dalam eksperimen yang sama, hasil yang diperoleh mendukung temuan literatur sebelumnya bahwa ResNet-50 unggul dalam mengekstraksi fitur hierarkis pada tugas klasifikasi *fine-grained*, khususnya ketika dikombinasikan dengan *transfer learning* dan augmentasi data. Dengan demikian, hasil penelitian ini memperkuat dan melengkapi temuan-temuan sebelumnya dalam domain klasifikasi motif tekstil tradisional.

Analisis *confusion matrix* menunjukkan bahwa kesalahan klasifikasi masih terjadi pada motif lilin, yang beberapa kali terprediksi sebagai motif titik 7. Kesalahan ini disebabkan oleh kemiripan distribusi pola titik dan tekstur visual antar kedua motif tersebut. Kondisi ini mengindikasikan bahwa meskipun ResNet-50 mampu mengekstraksi fitur visual tingkat tinggi, perbedaan pola yang sangat halus masih menjadi tantangan pada klasifikasi *fine-grained*. Temuan ini sejalan dengan literatur yang menyebutkan bahwa kesalahan klasifikasi umumnya terjadi pada kelas-kelas dengan kedekatan visual tinggi.

Secara teoretis, penelitian ini memperkuat bukti bahwa CNN berbasis deep residual network efektif digunakan untuk klasifikasi citra *fine-grained* pada domain tekstil tradisional. Temuan ini memperluas penerapan transfer learning dari domain medis dan objek umum ke konteks warisan budaya tekstil. Secara praktis, hasil penelitian ini berimplikasi pada pengembangan sistem otomasi identifikasi motif kain jumputan Palembang, yang dapat dimanfaatkan untuk digitalisasi arsip motif, inventaris produk UMKM tekstil, serta pengendalian mutu (*quality control*) pada proses produksi. Sistem klasifikasi otomatis ini juga berpotensi membantu pengrajin dan pelaku usaha dalam mendokumentasikan variasi motif secara konsisten dan efisien.

Dari perspektif kebijakan, penelitian ini dapat mendukung upaya pelestarian budaya berbasis teknologi dengan menyediakan pendekatan ilmiah untuk dokumentasi dan standardisasi motif tekstil tradisional. Hasil penelitian ini dapat dijadikan dasar pengembangan sistem informasi budaya berbasis kecerdasan buatan pada tingkat daerah maupun nasional.

Berdasarkan hasil analisis kesalahan, penelitian selanjutnya dapat difokuskan pada peningkatan akurasi klasifikasi motif yang memiliki kemiripan pola tinggi, khususnya motif lilin. Strategi yang dapat diterapkan antara lain penambahan dataset primer dengan variasi pencahayaan dan tekstur yang lebih beragam, penerapan fine-tuning lapisan ResNet-50 secara lebih mendalam, serta eksplorasi arsitektur lain yang dirancang khusus untuk *fine-grained classification*, seperti *EfficientNet* atau *Vision Transformer*.

Selain itu, penelitian lanjutan dapat mengintegrasikan pendekatan *attention mechanism* untuk menyoroti area motif yang paling diskriminatif, sehingga model lebih fokus pada bagian citra yang relevan. Pengembangan sistem klasifikasi berbasis *real-time*

dan pengujian pada kondisi lapangan yang lebih variatif juga menjadi arah riset potensial untuk meningkatkan kesiapan implementasi sistem dalam konteks nyata.

5. Kesimpulan

Penelitian ini bertujuan untuk mengkaji efektivitas *Convolutional Neural Network* berbasis *ResNet-50* dalam mengklasifikasikan motif kain jumputan Palembang yang memiliki tingkat kemiripan pola visual yang tinggi. Berdasarkan hasil eksperimen, dapat disimpulkan bahwa pendekatan *transfer learning* menggunakan *ResNet-50* mampu menghasilkan kinerja klasifikasi yang baik dan stabil pada lima kelas motif kain jumputan Palembang, sehingga menjawab tujuan penelitian dan menunjukkan bahwa arsitektur *ResNet-50* efektif untuk tugas klasifikasi motif tekstil *fine-grained* dengan dataset terbatas.

Selain itu, hasil penelitian menunjukkan bahwa pemilihan parameter pelatihan, khususnya learning rate dan jumlah epoch, berpengaruh signifikan terhadap stabilitas konvergensi dan kemampuan generalisasi model. Konfigurasi learning rate yang lebih kecil dengan jumlah epoch yang lebih besar terbukti menghasilkan performa yang lebih optimal dibandingkan konfigurasi pelatihan lainnya, sehingga menegaskan pentingnya proses penalaan (*hyperparameter tuning*) dalam penerapan *deep learning* pada klasifikasi motif tekstil tradisional.

Meskipun menunjukkan hasil yang menjanjikan, penelitian ini masih memiliki beberapa keterbatasan. Dataset yang digunakan terbatas pada lima kelas motif kain jumputan Palembang dengan jumlah citra yang relatif terbatas dan diperoleh pada kondisi pencahayaan tertentu, sehingga potensi variasi motif dan kondisi lingkungan belum sepenuhnya terwakili. Selain itu, penelitian ini hanya mengevaluasi satu arsitektur CNN berbasis *ResNet-50*, tanpa melakukan perbandingan langsung dengan arsitektur lain seperti *MobileNet*, *VGG*, atau *EfficientNet*.

Dengan mempertimbangkan keterbatasan tersebut, penelitian selanjutnya disarankan untuk memperluas jumlah kelas dan variasi dataset, melakukan perbandingan antararsitektur deep learning, serta mengeksplorasi pendekatan attention mechanism atau vision transformer untuk meningkatkan kemampuan model dalam membedakan motif dengan kemiripan visual yang tinggi. Upaya tersebut diharapkan dapat memperkuat generalisasi model dan memperluas penerapan sistem klasifikasi motif tekstil tradisional dalam konteks pelestarian budaya berbasis kecerdasan buatan.

6. Ucapan Terima Kasih

Penulis mengucapkan terima kasih yang sebesar-besarnya kepada Universitas Multi Data Palembang, khususnya Program Studi Informatika, yang telah memberikan dukungan akademis dan fasilitas dalam pelaksanaan penelitian ini. Penghargaan juga disampaikan kepada Bapak Mulyadi selaku pengrajin dan pemilik toko kain jumputan

Palembang, yang telah berkenan memberikan izin, informasi, serta akses dalam proses pengambilan data motif kain jumputan.

Ucapan terima kasih juga ditujukan kepada keluarga, rekan-rekan, serta semua pihak yang telah memberikan bantuan, motivasi, serta dukungan moral selama penelitian ini berlangsung. Tanpa dukungan dan kontribusi dari berbagai pihak, penelitian ini tidak dapat terlaksana dengan baik.

7. Pernyataan Penulis

Penulis menyatakan bahwa tidak terdapat konflik kepentingan dalam publikasi artikel ini. Penulis juga menyatakan bahwa seluruh data, gambar, dan isi artikel ini bebas dari unsur plagiarisme, dan merupakan hasil karya orisinal. Dengan ini, penulis bertanggung jawab sepenuhnya atas keaslian dan keabsahan isi artikel yang disampaikan dalam publikasi ini.

Bibliografi

- Azzahra, N. A., Fathinah, A., & Zahwa, D. N. (2025). *Pengembangan motif jumputan Palembang dengan pendekatan geometri menggunakan aplikasi GeoGebra*. <http://ejurnal.mipa.unsri.ac.id/index.php/jps/index>
- Agusniar, C., & Adelia, D. (2024). Penerapan Convolutional Neural Network pada Klasifikasi Jenis Ras Kucing Menggunakan ResNet50V2. In *Journal Information Engineering and Educational Technology* (Vol. 08).
- Akimova, E. N., Bersenev, A. Y., Deikov, A. A., Kobylkin, K. S., Konygin, A. V., Mezentsev, I. P., & Misilov, V. E. (2021). A survey on software defect prediction using deep learning. In *Mathematics* (Vol. 9, Issue 11). MDPI AG. <https://doi.org/10.3390/math9111180>
- Al-Majed, R., & Hussain, M. (2024). Entropy-Based Ensemble of Convolutional Neural Networks for Clothes Texture Pattern Recognition. *Applied Sciences (Switzerland)*, 14(22). <https://doi.org/10.3390/app142210730>
- Anastasya, D., Fahri, S., Situmorang, S., & Ramadhani, F. (2024). *Implementasi Metode Convolutional Neural Network (CNN) Dalam Klasifikasi Motif Batik* (Vol. 18, Issue 1). <https://journal.fkom.uniku.ac.id/ilkom>
- Arifin, S. (2024). Klasifikasi Motif Batik Menggunakan Metode Convolutional Neural Network (CNN) Dengan Multi Class Clasification. *Jurnal Ilmiah IT CIDA : Diseminasi Teknologi Informasi*, 10(1).
- Atif, M., Muthrofin, F., Erwanto, D., & Yanuartanti, I. (2024). Convolutional Neural Network untuk Klasifikasi Batik Tenun Ikat Bandar Berdasarkan Fitur Warna dan Tekstur. In *Journal homepage*. <https://ejurnal.unuja.ac.id/index.php/jecom>
- Berliani, T., Rahardja, E., & Septiana, L. (2023). Perbandingan Kemampuan Klasifikasi Citra X-ray Paru-paru menggunakan Transfer Learning ResNet-50 dan VGG-16.

- Journal of Medicine and Health*, 5(2), 123–135.
<https://doi.org/10.28932/jmh.v5i2.6116>
- Cao, Z., Sun, C., Wang, W., Zheng, X., Wu, J., & Gao, H. (2021). Multi-modality fusion learning for the automatic diagnosis of optic neuropathy. *Pattern Recognition Letters*, 142, 58–64. <https://doi.org/https://doi.org/10.1016/j.patrec.2020.12.009>
- Chen, C., Mat Isa, N. A., & Liu, X. (2025). A review of convolutional neural network based methods for medical image classification. *Computers in Biology and Medicine*, 185, 109507. <https://doi.org/10.1016/J.COMPBIOMED.2024.109507>
- Dwinora Cahyati, I., & Devella, S. (2024). Pengenalan Motif Songket Palembang Menggunakan Convolutional Neural Network dengan Arsitektur ResNet-50. *Jurnal Algoritme*, 5(1), 78–87. <https://doi.org/10.35957/algoritme.xxxx>
- Gorriiz, J. M., Clemente, R. M., Segovia, F., Ramirez, J., Ortiz, A., & Suckling, J. (2024). Is K-fold cross validation the best model selection method for Machine Learning? <http://arxiv.org/abs/2401.16407>
- Hussain, M. A. I., Khan, B., Wang, Z., & Ding, S. (2020). Woven fabric pattern recognition and classification based on deep convolutional neural networks. *Electronics (Switzerland)*, 9(6), 1–12. <https://doi.org/10.3390/electronics9061048>
- Irwan, M. (2020). *Identifikasi Motif Kain Jumputan Palembang Menggunakan Metode Jaringan Syaraf Tiruan*.
- Khan, S., Naseer, M., Hayat, M., Zamir, S. W., Khan, F. S., & Shah, M. (2022). Transformers in Vision: A Survey. *ACM Comput. Surv.*, 54(10s). <https://doi.org/10.1145/3505244>
- Li, Z., Liu, F., Yang, W., Peng, S., & Zhou, J. (2022). A Survey of Convolutional Neural Networks: Analysis, Applications, and Prospects. *IEEE Transactions on Neural Networks and Learning Systems*, 33(12), 6999–7019. <https://doi.org/10.1109/TNNLS.2021.3084827>
- Muhammad Mauladi. (2025). *DataSetJumputan*. Google Drive. <https://drive.google.com/drive/folders/1e0UuJdeLwoIVLJm7KpWO5QQhPEL52Qex?usp=sharing>
- Rustiana Dewi, N., Susanti, E., Hanum, H., Cahyawati, D., Alwine Zayanti, D., Sriwijaya, U., & Jurusan Matematika, F. (2022). Pengembangan motif fraktal pada usaha produksi kain jumputan palembang improved of fractal patterns in the production of jumputan palembang. In *integritas : Jurnal Pengabdian* (Vol. 6, Issue 1).
- Taye, M. M. (2023). Theoretical Understanding of Convolutional Neural Network: Concepts, Architectures, Applications, Future Directions. In *Computation* (Vol. 11, Issue 3). MDPI. <https://doi.org/10.3390/computation11030052>
- Whisnu Wiratama, R. (2023). *Implementasi dan Klasifikasi Jenis-Jenis Menggunakan Algoritma Convolutional Neural Network (CNN) Dengan Model Arsitektur ResNet*.
- Yang, S., Xiao, W., Zhang, M., Guo, S., Zhao, J., & Shen, F. (2023). *Image Data Augmentation for Deep Learning: A Survey*. <http://arxiv.org/abs/2204.08610>