

Image-Based Classification of Indonesian Traditional Houses Using a Hybrid CNN-SVM Algorithm

M. Ikhsan ^{1*}, Majid Rahardi ^{2*}

* Informatika, Universitas Amikom Yogyakarta

m.ikhsan@students.amikom.ac.id¹, majid@amikom.ac.id²

Article Info

Article history:

Received 2025-08-21

Revised 2025-09-09

Accepted 2025-09-19

Keyword:

*Image Classification,
Hybrid Model,
CNN-SVM,
Traditional House,
Machine Learning.*

ABSTRACT

The diversity of Indonesian traditional houses represents a cultural heritage that must be preserved. However, the lack of interest among younger generations and the difficulty in recognizing the distinctive architectural characteristics of traditional houses present challenges to preservation efforts. This study aims to develop an image classification model for Indonesian traditional houses using a hybrid CNN-SVM approach to improve recognition accuracy. The dataset consists of 3,919 images from five classes of traditional houses, namely gadang, joglo, panjang, tongkonan, and honai, with an 80% training split, 10% validation, and 10% testing. The data were processed through resizing, augmentation, and normalization before being trained using a CNN architecture with five convolutional layers as a feature extractor and an SVM serving as a multi-class classifier. The experimental results show that the hybrid CNN-SVM model achieved an accuracy of 96.68%, with consistently high precision, recall, and F1-score across all classes. These findings demonstrate that integrating CNN as a feature extractor and SVM as the final classifier can enhance the model's generalization capability in distinguishing images of Indonesian traditional houses.



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

I. PENDAHULUAN

Indonesia adalah negara dengan populasi yang cukup besar. Negara ini memiliki populasi keempat terbesar di dunia setelah Cina, India, dan Amerika Serikat (Data Bank Dunia, 2011). Jumlah penduduk Indonesia adalah 270.203.917 jiwa, menurut Sensus Penduduk 2020 (BPS, 2020), dengan 16.766 pulau di seluruh Indonesia (BPS, 2021). Keberanekaragaman budaya yang mencakup aspek keagamaan, politik, tradisi, bahasa, perlengkapan, busana, arsitektur, hingga seni, dihasilkan oleh penyebaran penduduk di setiap wilayah Kepulauan Indonesia atau wilayah nusantara ini. Keragaman budaya ini unik untuk setiap wilayah Kepulauan Indonesia, dan salah satu karakteristik ini dapat ditemukan pada rumah adat yang ada di Indonesia. Rumah adat merupakan rumah yang menonjol keunikan dari suatu wilayah di Indonesia yang menggambarkan budaya dan karakteristik masyarakat lokal [1][2][3].

Namun, pengetahuan tentang rumah adat menghadapi tantangan serius. UNESCO menegaskan bahwa proses

globalisasi dan transformasi sosial menimbulkan ancaman serius berupa kerusakan hingga hilangnya warisan budaya takbenda, termasuk pengetahuan dan keterampilan tradisional yang diwariskan antar generasi [4]. Hal ini diperkuat oleh laporan International Research Centre for Intangible Cultural Heritage in the Asia-Pacific Region (IRCI, 2024), yang menekankan bahwa berbagai elemen warisan budaya takbenda di kawasan Asia Pasifik rentan hilang akibat bencana alam sehingga diperlukan strategi pelestarian yang lebih sistematis [5]. Kondisi ini juga relevan dengan pengetahuan rumah adat, yang mencakup teknik konstruksi tradisional serta simbolisme budaya yang melekat dan kini semakin rentan tergerus oleh arus perkembangan zaman.

Selain tantangan pelestarian, minat generasi muda terhadap budaya tradisional cenderung menurun, sementara ketertarikan terhadap budaya asing semakin meningkat. Kondisi ini berdampak pada berkurangnya kesadaran dan pemahaman terhadap warisan budaya nasional [6]. Tidak hanya kurangnya minat yang menimbulkan masalah, tetapi juga kesulitan untuk mengidentifikasi dan memahami rumah

adat, terutama terkait ciri khas arsitektur serta desain yang unik, yang berakar pada adat istiadat setempat dan mengandung nilai filosofis, fungsi, serta makna tersendiri [7]. Oleh karena itu, klasifikasi rumah adat menjadi penting, bukan hanya untuk mendukung pelestarian budaya, tetapi juga untuk mempermudah proses pembelajaran di lembaga pendidikan agar warisan budaya dapat terus dipahami lintas generasi. Salah satu solusi yang potensial adalah penerapan teknologi digital yang dapat mengidentifikasi dan mengklasifikasikan rumah adat, sehingga dapat membantu mendokumentasikan sekaligus memperluas akses pengetahuan mengenai rumah adat.

Jenis metode yang dipakai untuk melakukan klasifikasi citra adalah Support Vector Machine (SVM), yang merupakan salah satu algoritma dalam bidang machine learning. SVM termasuk teknik yang dapat dimanfaatkan untuk melakukan prediksi, baik dalam kasus regresi maupun klasifikasi. Secara prinsip, SVM bekerja sebagai linear classifier yang memungkinkan pemisahan data secara linear. Selain itu, SVM dikembangkan untuk menangani masalah non-linear dengan menemukan hyperplane pada ruang kerja dengan konsep kernel [8]. Convolutional Neural Network (CNN) merupakan salah satu arsitektur populer di bidang deep learning yang digunakan dalam pengolahan data visual. Desain arsitektur CNN umumnya terdiri atas dua komponen utama, yaitu feature learning layer dan fully connected layer. Pada tahap feature learning layer, CNN memanfaatkan beberapa lapisan inti seperti lapisan konvolusi, fungsi aktivasi ReLU, max pooling, serta teknik dropout regularization untuk mencegah overfitting. Mekanisme kerja CNN bersifat bertingkat, di mana hasil output dari lapisan konvolusi pertama akan diteruskan sebagai input pada lapisan konvolusi berikutnya [9].

Salah satu penelitian relevan yang menjadi acuan dalam penelitian ini berjudul “Transfer Learning Implementation on Image Recognition of Indonesian Traditional Houses” bertujuan untuk membangun model image recognition yang mampu mengklasifikasikan jenis rumah adat dari berbagai wilayah di Indonesia dengan akurasi tinggi, memanfaatkan pendekatan transfer learning dalam kondisi keterbatasan dataset. Dalam penelitian ini, model deep learning dikembangkan menggunakan empat arsitektur pretrained CNN, yaitu MobileNetV2, VGG16, ResNet50, dan Xception. Untuk proses pembangunan sistem, penulis menerapkan metodologi CRISP-DM dari pengumpulan data hingga deployment, serta menggunakan teknik web scraping untuk membentuk dataset sebanyak 3.919 gambar yang direpresentasikan dalam lima kelas rumah adat. Hasil akurasi menunjukkan bahwa model terbaik adalah MobileNetV2, yang mencapai akurasi training sebesar 96.09%, dengan akurasi validasi mencapai 94.98%. Sementara ResNet50 mencatatkan akurasi validasi lebih tinggi, yakni 97.16%, namun performa MobileNetV2 dinilai lebih stabil karena menunjukkan prediksi yang konsisten pada semua sampel uji [10].

Penelitian lain dengan judul “Implementasi Model Hybrid CNN-SVM pada Klasifikasi Kondisi Kesegaran Daging Ayam” berfokus pada pengembangan sistem klasifikasi otomatis untuk membedakan daging ayam dalam kondisi segar maupun tidak segar. Pendekatan yang digunakan adalah metode hybrid yang mengombinasikan Convolutional Neural Network (CNN) sebagai ekstraktor fitur dengan Support Vector Machine (SVM) sebagai pengklasifikasi akhir. Dataset penelitian terdiri atas 2.755 citra dada ayam yang terbagi ke dalam dua kategori, yaitu segar dan busuk. Arsitektur CNN yang dirancang mencakup lima lapisan konvolusi dan pooling, kemudian dilanjutkan proses flattening dan fully connected layer. Selanjutnya, fitur yang dihasilkan diklasifikasikan menggunakan SVM dengan kernel linear, loss function hinge, dan regularisasi L2. Hasil pengujian menunjukkan bahwa learning rate sebesar 0,000001 memberikan performa terbaik dengan akurasi dan presisi yang sama yaitu sebesar 95%, recall 94,8%, dan F1-score 94,9%. Sementara itu, model dengan learning rate 0,000001 menghasilkan kinerja yang lebih seimbang, yaitu akurasi 90%, presisi dan recall yang sama sebesar 90,1%, meskipun performa klasifikasinya sedikit lebih rendah [11].

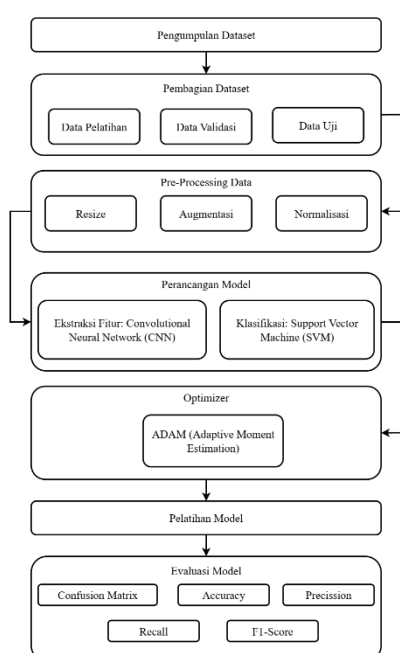
Selanjutnya penelitian dengan judul “Klasifikasi Lukisan Karya Van Gogh Menggunakan Convolutional Neural Network–Support Vector Machine”, dengan fokus pada pengenalan otomatis terhadap ciri khas lukisan Van Gogh melalui teknik deep learning yang memanfaatkan ekstraksi fitur dari CNN dan klasifikasi akhir menggunakan SVM. Arsitektur CNN yang digunakan adalah VGG-19 dan ResNet-50, yang diuji dengan teknik optimasi kernel linear menggunakan dua metode: random optimization dan grid optimization. Dataset yang digunakan terdiri dari 124 lukisan Van Gogh dan 207 lukisan pelukis lain, dengan citra yang telah diresize ke ukuran 224x224 piksel dan dinormalisasi sehingga menghasilkan 59.948 citra yang digunakan dalam pelatihan dan pengujian. Hasil penelitian menunjukkan bahwa model VGG-19 dengan grid optimization menghasilkan klasifikasi terbaik dengan akurasi 93,28%, sedikit lebih tinggi dibandingkan dengan random optimization yang memperoleh akurasi 92,89%. Sementara itu, ResNet-50 menghasilkan akurasi 90,28% dengan grid optimization dan 90,15% dengan random optimization [12].

Berdasarkan penelitian terdahulu, baik CNN murni maupun metode hybrid CNN-SVM telah menunjukkan performa yang menjanjikan dalam berbagai domain klasifikasi citra. Pada penelitian [10] memanfaatkan pendekatan transfer learning dengan arsitektur pretrained CNN seperti MobileNetV2, VGG16, ResNet50, dan Xception, yang mampu mencapai akurasi tinggi pada data latih dan validasi. Namun, penelitian tersebut belum menyertakan hasil akurasi pada data uji, sehingga kemampuan generalisasi model belum terukur secara menyeluruh. Selain itu, proses klasifikasi masih menggunakan pendekatan CNN murni dengan Softmax sebagai lapisan akhir, tanpa eksplorasi metode alternatif yang mungkin lebih efektif untuk dataset terbatas. Hingga saat ini,

belum ada penelitian yang secara khusus mengintegrasikan CNN-SVM dalam klasifikasi rumah adat Indonesia. Oleh karena itu, penelitian ini bertujuan mengisi gap tersebut dengan menggunakan pendekatan hybrid CNN-SVM, dimana SVM digunakan sebagai pengganti lapisan akhir pada arsitektur CNN. Dengan menggunakan metode hybrid CNN-SVM, diharapkan model mampu memberikan klasifikasi citra rumah adat Indonesia dengan akurasi tinggi dan bermanfaat dalam mendukung pelestarian budaya serta pembelajaran di lembaga pendidikan.

II. METODE

Untuk mengklasifikasikan rumah adat Indonesia menggunakan pendekatan hybrid CNN-SVM, ada beberapa tahapan yang harus dilakukan, seperti yang ditunjukkan pada Gambar 1.



Gambar 1 Alur Penelitian

A. Pengumpulan Dataset

Dataset yang dimanfaatkan pada penelitian ini terdiri atas citra rumah adat. Dataset tersebut bersumber dari platform Kaggle dan sebelumnya telah digunakan dalam penelitian oleh peneliti [10][13]. Secara keseluruhan, dataset ini berjumlah 3.919 citra dengan format PNG.

B. Pembagian Data

Pembagian data adalah tahapan memisahkan dataset menjadi dua atau lebih subset yang berbeda untuk keperluan pelatihan dan pengujian pada model machine learning. Tujuan utama dari pembagian data adalah untuk mengevaluasi performa model terhadap data baru yang belum pernah ditemui selama proses pelatihan [14]. Dalam penelitian ini, pembagian data dilakukan dengan sekali split

menggunakan proporsi 80:10:10, 80% sebagai data pelatihan, 10% sebagai data validasi, dan 10% sebagai data uji. Data pelatihan berfungsi sebagai dasar pembelajaran bagi model, data validasi berfungsi mengevaluasi hasil pembelajaran selama proses pelatihan, sementara itu data uji berfungsi sebagai pengukur kinerja model yang telah selesai melakukan proses pelatihan. Jumlah data pada masing-masing subset adalah 3.135 citra pada pelatihan, 392 citra pada validasi, dan 392 citra pada pengujian.

C. Pre-Processing Data

Preprocessing data merupakan tahapan krusial untuk memastikan data dalam kondisi siap pakai sebelum dimasukkan ke dalam model klasifikasi. Data yang telah melalui proses pembersihan dan penataan secara sistematis umumnya menghasilkan kinerja yang lebih optimal [15]. Dalam penelitian ini, tahapan preprocessing meliputi proses resize, augmentasi, dan normalisasi.

Resize adalah proses mengubah dimensi suatu citra, baik dengan memperbesar maupun memperkecil ukurannya dari dimensi asli [16]. Proses ini penting dilakukan karena citra pada dataset umumnya memiliki variasi ukuran dan resolusi yang berbeda. Untuk memastikan model memproses citra dengan dimensi yang seragam, seluruh citra pada penelitian ini disesuaikan menjadi ukuran 224×224 piksel.

Augmentasi merupakan metode untuk memperbanyak jumlah citra dengan menerapkan berbagai variasi, seperti membalik sudut pandang (flip), memutar citra (rotation), dan memperbesar area tertentu (zoom). Langkah ini bertujuan membantu model mengenali citra dari berbagai orientasi dan posisi yang berbeda [17]. Pada penelitian ini, augmentasi diterapkan untuk meningkatkan keragaman data pelatihan sekaligus meminimalkan potensi terjadinya overfitting. Melalui pendekatan ini, dihasilkan citra-citra baru dari data yang sudah ada tanpa perlu menambah data secara fisik, sehingga model dapat mempelajari beragam bentuk visual. Penerapan augmentasi membuat data pelatihan menjadi lebih bervariasi, memungkinkan model memahami berbagai kondisi dan tampilan citra, serta beradaptasi dengan data yang sebelumnya belum pernah ditemui, sehingga meningkatkan akurasi prediksi pada data nyata. Pengaturan augmentasi pada penelitian ini meliputi rotasi=10, horizontal flip=True, zoom=0.1, dan brightness=(0.8, 1.2). Konfigurasi ini dipilih agar variasi citra yang dihasilkan tetap realistis, namun mampu meningkatkan keragaman pada data pelatihan.

Setelah proses resize dan augmentasi dilakukan, setiap nilai piksel pada gambar dibagi dengan 255 untuk menormalkan nilainya sehingga berada pada kisaran [0,1]. Normalisasi ini bertujuan mengubah skala piksel dari rentang awal [0,255] menjadi lebih kecil dan seragam. Rentang [0,1] dipilih karena lebih sesuai untuk proses pelatihan model neural, yang sensitif terhadap skala data yang dimasukkan, sehingga proses pembelajaran menjadi lebih cepat. Normalisasi juga membantu mengurangi dominasi nilai piksel yang tinggi, sehingga model dapat lebih terfokus dalam mengenali pola dan fitur penting pada gambar. Dalam

penelitian ini, normalisasi dilakukan secara global dengan membagi seluruh nilai piksel dengan 255 untuk memastikan keseragaman skala antar citra.

D. Perancangan Arsitektur Model Hybrid CNN-SVM

Model klasifikasi citra rumah adat Indonesia dalam penelitian ini dirancang menggunakan arsitektur Sequential dengan pendekatan hybrid CNN-SVM. CNN digunakan sebagai ekstraktor fitur karena kemampuannya mengenali pola visual secara efektif, sedangkan SVM digunakan sebagai klasifikator untuk mengoptimalkan margin antar kelas. Model menerima input gambar berukuran 224×224 piksel dengan tiga saluran warna (RGB). Arsitektur CNN terdiri dari lima lapisan konvolusi bertingkat dengan jumlah filter 32, 64, 128, 256, dan 512, masing-masing menggunakan kernel 3×3 , padding “same”, aktivasi ReLU, diikuti oleh MaxPooling2D dan BatchNormalization. BatchNormalization ditempatkan setelah pooling untuk menstabilkan distribusi fitur hasil downsampling, sehingga representasi yang dihasilkan lebih konsisten dan aliran informasi ke lapisan berikutnya tetap stabil. Output dari CNN diratakan melalui Flatten, kemudian diproses oleh dua lapisan Dense berturut-turut dengan 256 dan 128 unit, keduanya menggunakan aktivasi ReLU dan dropout 0.3 untuk mencegah overfitting. Lapisan output menggunakan aktivasi linear dengan jumlah unit sesuai jumlah kelas dan regularisasi L2 sebesar 0.01, sebagai implementasi SVM. Model dikompilasi dengan fungsi loss categorical hinge yang dirancang untuk mendukung klasifikasi multi-kelas berbasis margin, serta dioptimalkan dengan optimizer Adam menggunakan learning rate sebesar 0.001.

E. Pelatihan Model Hybrid CNN-SVM

Untuk meningkatkan efisiensi, kestabilan, dan performa selama pelatihan model, penelitian ini menerapkan empat jenis callback dalam proses training. Pertama, CSVLogger digunakan untuk merekam seluruh riwayat pelatihan, termasuk nilai akurasi, loss, akurasi validasi, dan loss validasi pada setiap epoch, ke dalam file CSV yang berguna untuk analisis performa model. Kedua, ReduceLROnPlateau dimanfaatkan untuk menyesuaikan learning rate secara dinamis. Callback ini memantau metrik akurasi validasi dan menurunkan learning rate sebesar 0.3 apabila tidak terjadi peningkatan selama dua epoch berturut-turut, sehingga membantu model keluar dari stagnasi dan meningkatkan konvergensi. Ketiga, EarlyStopping digunakan untuk menghentikan proses pelatihan lebih cepat jika tidak terjadi peningkatan kinerja pada loss validasi dalam 10 epoch, dengan tujuan menghindari overfitting dan penggunaan sumber daya yang tidak efisien. Keempat, ModelCheckpoint diaktifkan untuk menyimpan bobot model terbaik selama pelatihan berdasarkan peningkatan akurasi validasi, dengan parameter `save_best_only=True`. Kombinasi keempat callback ini memastikan proses pelatihan berlangsung secara optimal dan menghasilkan model klasifikasi citra rumah adat Indonesia yang lebih baik.

F. Evaluasi Model


Model yang sudah melalui proses pelatihan kemudian diuji menggunakan data pengujian yang sepenuhnya terpisah dari data pelatihan. Penilaian terhadap kemampuan model dalam mengklasifikasikan rumah adat gadang, joglo, panjang, tongkonan, dan honai dilakukan dengan menghitung metrik evaluasi seperti akurasi, presisi, recall, dan f1-score, dengan perhitungan dilakukan pada masing-masing kelas. Sebagai pelengkap, visualisasi prediksi dilakukan melalui confusion matrix guna memberikan gambaran detail terhadap hasil klasifikasi.

III. HASIL DAN PEMBAHASAN

Hasil dari penelitian ini adalah proses klasifikasi citra rumah adat Indonesia, menggunakan algoritma hybrid CNN-SVM yang memiliki lima kelas, yaitu gadang, joglo, panjang, tongkonan, dan honai.

A. Pengumpulan Dataset

Sumber data pada penelitian ini diperoleh dari platform Kaggle, yang terdiri atas lima kategori rumah adat, yaitu gadang, joglo, panjang, tongkonan, dan honai. Secara keseluruhan, jumlah citra yang tersedia sebanyak 3.919 citra, yang terbagi menjadi 962 citra rumah adat gadang, 720 citra rumah adat joglo, 624 citra rumah adat panjang, 1.000 citra rumah adat tongkonan, dan 613 citra rumah adat honai. Gambar 2 menampilkan contoh hasil pengumpulan data.



Gambar 2 Contoh Dataset Citra Rumah Adat

B. Pembagian Data

Sebelum melalui tahap preprocessing, dataset dibagi ke dalam tiga subset, yaitu data pelatihan, data validasi, dan data pengujian. Komposisi pembagian tersebut adalah 80% untuk data pelatihan, 10% untuk validasi, dan 10% untuk pengujian. Dari total 3.919 citra yang tersedia, sebanyak 3.135 digunakan sebagai data pelatihan, 392 sebagai data validasi, dan 392 sebagai data pengujian, sebagaimana ditampilkan pada Tabel 1.

TABEL 1
JUMLAH DATA PELATIHAN, VALIDASI DAN UJI

Kelas	Data Pelatihan	Data Validasi	Data Uji
Tongkonan	800	100	100
Gadang	770	96	96
Joglo	576	72	72
Panjang	499	63	62
Honai	490	61	62
Total	3.135	392	392

C. Pre-Processing Data

Tahap preprocessing dilakukan sebelum proses pelatihan model, dengan tujuan menyiapkan data agar memiliki struktur dan skala yang seragam. Ukuran semua citra pada penelitian ini diseragamkan menjadi 224×224 piksel. Kemudian data pelatihan mengalami proses augmentasi menggunakan ImageDataGenerator yang telah diatur dengan beberapa kombinasi transformasi, meliputi rotasi, horizontal flip, zoom, dan penyesuaian kecerahan. Visualisasi hasil dari augmentasi menunjukkan bahwa variasi yang dihasilkan tetap mempertahankan struktur dan kelas dari objek asli, namun dengan sudut pandang, proporsi, dan intensitas cahaya. Selain augmentasi, dilakukan juga normalisasi piksel supaya distribusi nilai piksel menjadi lebih merata, tanpa dominasi nilai tinggi yang berpotensi mengganggu kestabilan model. Contoh hasil preprocessing dataset ditampilkan pada Gambar 3.

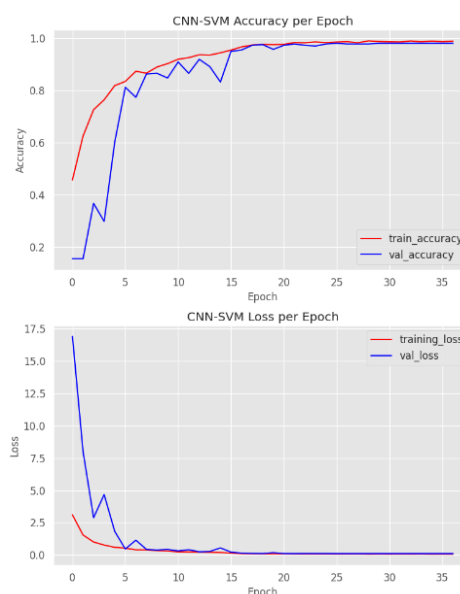


Gambar 3 Hasil Preprocessing Dataset

D. Pelatihan Model Hybrid CNN-SVM

Pelatihan model hybrid CNN-SVM memperlihatkan perbaikan performa yang signifikan dan stabil sepanjang proses pelatihan. Pada fase awal, tingkat akurasi pada data pelatihan berada di kisaran 45.74% dengan akurasi validasi sekitar 15.56%, sementara loss masih cukup tinggi, yakni

3.1045 pada data pelatihan dan 16.9068 pada data validasi. Seiring bertambahnya jumlah epoch, kinerja model meningkat secara bertahap. Misalnya, di epoch ke-5, akurasi validasi mencapai 60.20% dan terus meningkat hingga 97.96% pada epoch ke-26, dengan nilai loss validasi turun menjadi 0.1080. Peningkatan ini menunjukkan bahwa model memiliki kemampuan mempelajari fitur-fitur penting secara efektif serta kemampuan generalisasi yang baik terhadap data validasi. Model terbaik diperoleh melalui ModelCheckpoint yang digunakan untuk menyimpan bobot model berdasarkan nilai akurasi validasi tertinggi selama pelatihan. Nilai optimal tersebut dicapai pada epoch ke-26, dengan akurasi validasi sebesar 97.96%, yang kemudian digunakan dalam proses evaluasi. Pemilihan epoch ini didasarkan pada pertimbangan bahwa model dengan performa validasi terbaik umumnya memiliki daya generalisasi yang kuat terhadap data baru yang belum pernah dilatih sebelumnya. Selain itu, EarlyStopping digunakan untuk memantau loss validasi dengan batas toleransi 10 epoch tanpa perbaikan. Proses pelatihan otomatis dihentikan pada epoch ke-37, sebelum mencapai batas maksimum pelatihan yang direncanakan dengan 50 epoch, sehingga pelatihan berlangsung efisien dan terhindar dari overfitting maupun pemborosan sumber daya komputasi. Hasil grafik pelatihan secara keseluruhan, seperti pada Gambar 4, menunjukkan pola peningkatan akurasi disertai dengan penurunan loss baik pada data pelatihan maupun validasi.

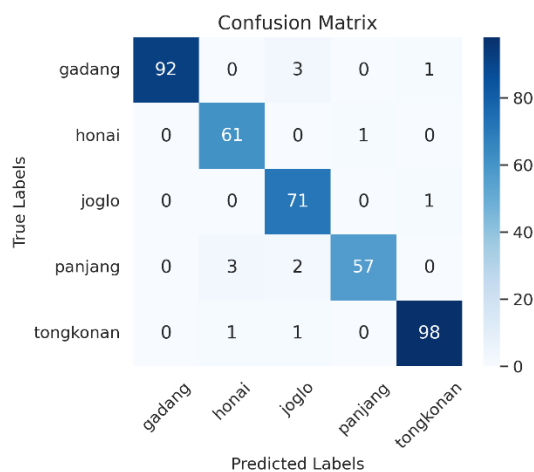


Gambar 4 Visualisasi Grafik Hasil Pelatihan

E. Evaluasi Model

Proses evaluasi model dilakukan dengan menganalisis kinerja pada data uji menggunakan confusion matrix untuk mengamati distribusi hasil prediksi benar maupun salah untuk setiap kategori kelas. Confusion matrix yang ditampilkan

pada Gambar 5 memperlihatkan bahwa model mencapai tingkat akurasi klasifikasi yang tinggi pada hampir seluruh kelas. Untuk kelas gadang, model mampu mengklasifikasikan 92 sampel secara benar dari total 96, dengan hanya terdapat tiga kesalahan klasifikasi ke kelas joglo dan satu kesalahan ke kelas tongkonan. Pada kelas honai, semua 61 sampel terklasifikasi dengan benar kecuali satu sampel yang keliru dikenali sebagai kelas panjang. Untuk kelas joglo, terdapat 71 prediksi benar dari 72 sampel, dengan satu kesalahan yang teridentifikasi sebagai kelas tongkonan. Kelas panjang memiliki 57 prediksi benar dari 62 sampel, sementara lima sisanya salah diklasifikasi menjadi kelas honai tiga sampel dan joglo dua sampel. Kelas tongkonan menunjukkan tingkat akurasi tertinggi, yaitu 98 prediksi benar dari total 100 sampel, dengan satu kesalahan menuju kelas gadang dan satu ke kelas joglo. Berdasarkan confusion matrix, kesalahan klasifikasi paling sering terjadi pada kelas panjang yang salah dikenali sebagai honai maupun joglo. Hal ini kemungkinan dipengaruhi oleh kemiripan fitur visual pada citra, khususnya terkait sudut pengambilan gambar dan kondisi pencahayaan. Kesalahan lain juga ditemukan pada kelas gadang yang terkadang terklasifikasi sebagai joglo maupun tongkonan, hal ini kemungkinan disebabkan oleh kemiripan bentuk atap, warna atap, tekstur material, maupun sudut pengambilan gambar. Secara keseluruhan, temuan ini mengindikasikan bahwa model mampu melakukan generalisasi dengan sangat baik dalam mengenali setiap kelas, meskipun masih terdapat sedikit kesalahan pada kelas dengan kemiripan visual tertentu.



Gambar 5 Confusion Matrix

Kemudian hasil evaluasi model juga dilakukan dengan matriks evaluasi yang mencakup akurasi, presisi, recall, dan F1-score. Berdasarkan classification report yang ditampilkan pada Gambar 6.

	precision	recall	f1-score	support
gado	1.0000	0.9583	0.9787	96
honai	0.9385	0.9839	0.9606	62
joglo	0.9221	0.9861	0.9530	72
panjang	0.9828	0.9194	0.9500	62
tongkonan	0.9800	0.9800	0.9800	100
accuracy			0.9668	392
macro avg	0.9647	0.9655	0.9645	392
weighted avg	0.9681	0.9668	0.9669	392

Gambar 6 Classification Report

Pada hasil classification report menunjukkan performa model klasifikasi citra rumah adat Indonesia pada lima kelas, yaitu gadang, honai, joglo, panjang, dan tongkonan. Pada kelas gadang, nilai presisi yang diperoleh sebesar 1.000, mengindikasikan bahwa 100% dari prediksi yang menyatakan sebagai kelas gadang adalah benar. Recall sebesar 0.9583 berarti bahwa model mampu mengidentifikasi 95.83% dari seluruh instansi kelas gadang yang sebenarnya ada. F1-Score sebesar 97.87% mengindikasikan bahwa presisi dan recall pada kelas ini berada dalam kondisi yang sangat seimbang. Untuk kelas honai, nilai presisi yang didapatkan sebesar 0.9385 mengindikasikan bahwa 93.85% dari prediksi yang menyatakan sebagai kelas honai adalah benar. Recall sebesar 0.9839 berarti bahwa model mampu mengidentifikasi 98.39% dari seluruh instansi kelas honai yang sebenarnya ada. F1-Score sebesar 96.06% menegaskan konsistensi performa model pada kelas ini. Untuk kelas joglo, nilai presisi yang diperoleh sebesar 0.9221, mengindikasikan bahwa 92.21% dari prediksi yang menyatakan sebagai kelas joglo adalah benar. Recall sebesar 0.9861, berarti bahwa model mampu mengidentifikasi 98.61% dari seluruh instansi kelas joglo yang sebenarnya ada. F1-Score sebesar 95.30% mengindikasikan bahwa model mampu menjaga keseimbangan optimal antara presisi dan recall meskipun presisi sedikit lebih rendah dibandingkan recall. Untuk kelas panjang memiliki presisi tertinggi kedua yaitu sebesar 98.28% namun recall relatif lebih rendah 91.94%, yang berarti terdapat kelas panjang yang terklasifikasi sebagai kelas lain. Nilai f1-score sebesar 95.00% tetap menunjukkan kinerja yang baik. Kelas tongkonan menunjukkan keseimbangan optimal dengan precision dan recall yang sama yaitu sebesar 98.00%, menghasilkan f1-score 98.00% yang menjadi salah satu kinerja terbaik di antara seluruh kelas. Secara keseluruhan, model memperoleh akurasi sebesar 96.68%, dengan akurasi validasi tertinggi mencapai 97.96%. Sebagai pembandingan, penelitian [10] yang menggunakan transfer learning melaporkan akurasi training tertinggi sebesar 96.09% untuk MobileNetV2 dan akurasi validasi tertinggi sebesar 97.16% untuk ResNet50. Meskipun penelitian tersebut tidak menampilkan hasil akurasi pada data uji, perbandingan ini menunjukkan bahwa akurasi 96.68% yang diperoleh pada penelitian ini dapat diinterpretasikan sebagai hasil yang signifikan dan kompetitif, sekaligus menunjukkan konsistensi kinerja pada seluruh kelas.

Pencapaian ini tidak terlepas dari kombinasi peran CNN dan SVM, di mana CNN berfungsi mengekstraksi fitur visual hierarkis yang kompleks, sementara SVM sebagai pengklasifikasi akhir mampu memaksimalkan margin antar kelas. Kolaborasi keduanya membuat model lebih stabil dibanding CNN murni dengan Softmax, terutama pada dataset yang relatif terbatas. Hasil ini menunjukkan bahwa model hybrid CNN-SVM yang diterapkan mampu memberikan performa klasifikasi yang sangat baik pada pengenalan citra rumah adat Indonesia, dengan konsistensi tinggi di seluruh kelas dan kesalahan prediksi yang relatif rendah.

IV. KESIMPULAN

Penelitian ini berhasil merancang dan membangun model klasifikasi citra rumah adat Indonesia menggunakan pendekatan hybrid CNN-SVM yang mampu mengenali lima kelas rumah adat, yaitu gadang, joglo, panjang, tongkonan, dan honai. Hasil pengujian pada data uji menunjukkan bahwa model mencapai akurasi keseluruhan sebesar 96,68%, dengan nilai precision, recall, dan F1-score yang konsisten tinggi pada setiap kelas. Temuan ini menegaskan bahwa integrasi CNN sebagai ekstraktor fitur dengan SVM sebagai klasifikator akhir dapat meningkatkan kemampuan generalisasi model dalam membedakan citra dengan kemiripan visual yang tinggi. Dengan demikian, model yang dibangun berpotensi menjadi solusi otomatis untuk mendukung pelestarian budaya dan pembelajaran rumah adat Indonesia. Meskipun demikian, penelitian ini memiliki keterbatasan pada jumlah dan keberagaman dataset yang masih terbatas pada lima kelas rumah adat, sehingga generalisasi terhadap seluruh tipe rumah adat Indonesia belum sepenuhnya teruji. Selain itu, robustness model terhadap kondisi non-ideal, seperti variasi pencahayaan, sudut pengambilan gambar, noise, maupun latar belakang kompleks, belum diuji secara eksplisit. Untuk penelitian selanjutnya, disarankan memperluas jumlah kelas dan jumlah citra pada dataset, melakukan pengujian robustness secara sistematis, serta mengeksplorasi arsitektur deep learning lain atau teknik ensemble learning untuk meningkatkan akurasi dan ketahanan model terhadap data nyata di lapangan.

DAFTAR PUSTAKA

- [1] F. A. Damastuti *et al.*, "Pengenalan Rumah Adat Nusantara Berbasis Mobile AR di SDN Banjarmendalan Lamongan," *SOROT J. Pengabd. Kpd. Masy.*, vol. 2, no. 2, pp. 68–72, 2023, doi: 10.32699/sorot.v2i2.4755.
- [2] F. L. Fitri Lintang and F. Ulfatun Najicha, "Nilai-Nilai Sila Persatuan Indonesia Dalam Keberagaman Kebudayaan Indonesia," *J. Glob. Citiz. J. Ilm. Kaji. Pendidik. Kewarganegaraan*, vol. 11, no. 1, pp. 79–85, 2022, doi: 10.33061/jgz.v11i1.7469.
- [3] T. Abdulghani and B. P. Sati, "Pengenalan Rumah Adat Indonesia Menggunakan Teknologi Augmented Reality Dengan Metode Marker Based Tracking Sebagai Media Pembelajaran," *Media J. Inform.*, vol. 11, no. 1, p. 43, 2020, doi: 10.35194/mji.v11i1.770.
- [4] UNESCO, *Basic Texts of the 2003 Convention for the Safeguarding of the Intangible Cultural Heritage*, 2024 ed. Paris, France: UNESCO, 2024. [Online]. Available: https://ich.unesco.org/doc/src/2003_Convention_Basic_Texts_2024_version_EN.pdf
- [5] D. Machida, Y. Nojima, and C. Kizaki, Eds., *Natural Hazards and the Safeguarding of Intangible Cultural Heritage: Experiences from the Asia-Pacific Region. Report of the Research on ICH Safeguarding and Disaster Risk Management (FY 2020–2023)*. Osaka, Japan: International Research Centre for Intangible Cultural Heritage in the Asia-Pacific Region (IRCI), 2024. [Online]. Available: https://www.irci.jp/wp_files/wp-content/uploads/2024/07/IRCI_Report_Research-on-ICH-Safeguarding-and-DRM-in-the-Asia-Pacific-Region_FY2020-23-1.pdf
- [6] Aisya Putri Handayani, Jap Tji Beng, Febynola Tiara Salsabilla, Stefania Morin, Thalia Syahrinia Suci Ardhia, and Valensia Audrey Rusli, "Hilangnya Budaya Lokal di Era Modern dan Upaya Pelestariannya dalam Perspektif Pancasila," *Dewantara J. Pendidik. Sos. Hum.*, vol. 3, no. 4, pp. 178–188, 2024, doi: 10.30640/dewantara.v3i4.3452.
- [7] M. Louis, "Fungsi Dan Makna Ruang Pada Rumah Adat Mbaru Niang Wae Rebo," *Intra*, vol. 3, no. 2, pp. 580–585, 2015.
- [8] P. A. Octaviani, Yuciana Wilandari, and D. Ispriyanti, "Penerapan Metode Klasifikasi Support Vector Machine (SVM) pada Data Akreditasi Sekolah Dasar (SD) di Kabupaten Magelang," *J. Gaussian*, vol. 3, no. 8, pp. 811–820, 2014.
- [9] I. K. Trisiawan and Y. Yuliza, "Penerapan Multi-Label Image Classification Menggunakan Metode Convolutional Neural Network (CNN) Untuk Sortir Botol Minuman," *J. Teknol. Elektro*, vol. 13, no. 1, p. 48, 2022, doi: 10.22441/jte.2022.v13i1.009.
- [10] R. A. Firmansah, H. Santoso, and A. Anwar, "Transfer Learning Implementation on Image Recognition of Indonesian Traditional Houses," *J. Tek. Inform.*, vol. 4, no. 6, pp. 1469–1478, 2023, doi: 10.52436/1.jutif.2023.4.6.767.
- [11] A. Agung Mujiono, K. Kartini, and E. Yulia Puspaningrum, "Implementasi Model Hybrid Cnn-Svm Pada Klasifikasi Kondisi Kesegaran Daging Ayam," *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 8, no. 1, pp. 756–763, 2024, doi: 10.36040/jati.v8i1.8855.
- [12] Y. Yohannes, D. Udjulawa, and F. Febbiola, "Klasifikasi Lukisan Karya Van Gogh Menggunakan Convolutional Neural Network-Support Vector Machine," *J. Tek. Inform. dan Sist. Inf.*, vol. 7, no. 1, pp. 192–205, 2021, doi: 10.28932/jutisi.v7i1.3399.
- [13] R. A. Firmansah, "rumah_adat," Kaggle. [Online]. Available: <https://www.kaggle.com/datasets/rariffirmansah/rumah-adat>
- [14] G. S. K. Ranjan, A. Kumar Verma, and S. Radhika, "K-Nearest Neighbors and Grid Search CV Based Real Time Fault Monitoring System for Industries," *2019 IEEE 5th Int. Conf. Converg. Technol. I2CT 2019*, vol. 4, no. January, pp. 273–281, 2019, doi: 10.1109/I2CT45611.2019.9033691.
- [15] M. Iksan Maulana, M. Martanto, and U. Hayati, "Perbandingan Algoritma Naïve Bayes Dan K-Nearest Neighbors Untuk Klasifikasi Topik Berita Pada Situs Detik.Com," *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 8, no. 3, pp. 3733–3742, 2024, doi: 10.36040/jati.v8i3.9779.
- [16] F. M. Qotrunnada and P. H. Utomo, "Metode Convolutional Neural Network untuk Klasifikasi Wajah Bermasker," *Prisma*, vol. 5, pp. 799–807, 2022.
- [17] A. H. P. Sitohang, T. I. Hermanto, and C. D. Lestari, "Klasifikasi Jenis Penyakit Pada Daun Tumbuhan Stroberi Menggunakan Metode Convolutional Neural Network Arsitektur Inceptionv3," *J. Inform. dan Tek. Elektro Terap.*, vol. 12, no. 3S1, 2024, doi: 10.23960/jitet.v12i3s1.5274.