



Implementasi Sistem *Convolutional Neural Network* (CNN) Dengan Arsitektur Xception Untuk Klasifikasi Motif Citra Batik Berbasis Web Pada PT Jaya Batik

Abdullah Zarkasi¹, Nana Hermansyah²

^{1,2} Program Studi Teknik Informatika, Fakultas Ilmu Komputer, Universitas Pamulang

¹abdullzarka@gmail.com, ²Nanasscouting@gmail.com

Abstrak

Identifikasi motif batik di PT Jaya Batik masih dilakukan melalui pengamatan visual sehingga prosesnya bergantung pada pengalaman operator, membutuhkan waktu, dan berpotensi menghasilkan klasifikasi yang tidak konsisten. Penelitian ini bertujuan mengembangkan sistem klasifikasi motif citra batik otomatis menggunakan *Convolutional Neural Network* berarsitektur Xception dengan strategi transfer learning serta mengintegrasikannya ke dalam aplikasi web berbasis Flask. Dataset penelitian terdiri atas 3.009 citra yang mewakili tujuh kelas motif batik dan dibagi menjadi data latih, validasi, serta pengujian dengan rasio 80:10:10. Citra diproses menjadi ukuran 224×224 piksel dan dinormalisasi sebelum digunakan pada model Xception berbobot awal ImageNet. Lapisan dasar model dibekukan, sedangkan lapisan klasifikasi kustom dilatih selama 100 epoch menggunakan optimizer Adam. Hasil pengujian terhadap 301 citra menunjukkan akurasi 99,34% dan weighted average F1-score 0,99. Lima kelas mayoritas memperoleh F1-score 1,00, sedangkan Batik Cendrawasih dan Batik Betawi memperoleh F1-score 0,94 dan 0,83 akibat ketimpangan jumlah data. Sistem menerapkan confidence threshold 85% untuk menolak citra di luar domain pelatihan. Sebelas skenario blackbox dan enam skenario whitebox dinyatakan valid. Aplikasi web mendukung unggahan berkas dan kamera secara real-time serta menampilkan nama, asal daerah, dan filosofi motif. Temuan menunjukkan bahwa Xception dengan transfer learning mampu menghasilkan klasifikasi akurat dan solusi operasional yang praktis.

Kata Kunci: Klasifikasi Batik, *Convolutional Neural Network*, Xception, Transfer Learning, Aplikasi Web

Abstract

Batik motif identification at PT Jaya Batik is still performed through visual observation, making the process dependent on operator experience, time-consuming, and vulnerable to inconsistent classification. This study aims to develop an automatic batik image classification system using a *Convolutional Neural Network* with the Xception architecture and transfer learning, and to integrate the trained model into a Flask-based web application. The dataset consists of 3,009 images representing seven batik motif classes and is divided into training, validation, and testing subsets using an 80:10:10 ratio. Each image is resized to 224×224 pixels and normalized before being processed by an ImageNet-pretrained Xception model. The base layers are frozen, while custom classification layers are trained for 100 epochs using the Adam optimizer. Testing on 301 images produces an accuracy of 99.34% and a weighted average F1-score of 0.99. Five majority classes achieve an F1-score of 1.00, whereas Cendrawasih and Betawi batik obtain F1-scores of 0.94 and 0.83 because of class imbalance. An 85% confidence threshold is applied to reject images outside the training domain. All eleven black-box and six white-box testing scenarios are valid. The web application supports real-time classification through file upload and camera capture and displays the identified motif, regional origin, and cultural philosophy. The results demonstrate that Xception-based transfer learning provides highly accurate classification and a practical operational solution for PT Jaya Batik.

Keywords: Batik Classification, *Convolutional Neural Network*, Xception, Transfer Learning, Web Application

1. Pendahuluan

PT Jaya Batik mengelola koleksi motif batik Nusantara yang beragam, mencakup pola geometris hingga motif dengan makna filosofis dan kultural yang kompleks. UNESCO menetapkan batik sebagai *Intangible Cultural Heritage of Humanity* pada 2 Oktober 2009, yang menegaskan nilai sejarah dan kearifan lokal pada setiap corak batik Indonesia. Namun demikian, proses identifikasi motif batik pada perusahaan ini masih dilakukan secara manual melalui pengamatan visual oleh operator. Ketergantungan pada mata manusia membuat proses ini berjalan lambat dan rentan menghasilkan ketidakkonsistenan, terutama ketika berhadapan dengan motif-motif yang memiliki kemiripan pola atau warna. Kondisi ini menghambat efisiensi pendataan dan operasional perusahaan sehari-hari.

Beberapa penelitian terdahulu telah mengeksplorasi klasifikasi motif batik menggunakan pendekatan *Convolutional Neural Network* (CNN). Hakim et al. (2023) menerapkan CNN untuk mengklasifikasikan motif

batik Banyuwangi dan memperoleh akurasi yang masih terbatas pada kisaran 63%, sementara Haq et al. (2025) menjadikan VGG-16 sebagai baseline komparatif pada klasifikasi citra batik Nusantara dengan akurasi di kisaran 85%. Ariawan et al. (2025) dan Ardyani dan Sari (2024) turut membuktikan efektivitas CNN pada klasifikasi motif batik Indonesia dan Demak menggunakan pendekatan yang berbeda, sementara Prayoga et al. (2023), Anggoro et al. (2024), dan Susanti et al. (2024) menerapkan CNN pada motif batik Yogyakarta dan Solo. Octavianus dan Avianto (2025) memodifikasi arsitektur CNN untuk klasifikasi batik Lampung dan Yogyakarta, Salsabila (2023) mengklasifikasikan motif batik Karawang berbasis citra digital, dan Jumadi et al. (2021) menunjukkan pentingnya tahapan prapemrosesan citra digital sebelum proses identifikasi objek. Aisyah et al. (2024) mengkaji pengaruh dimensi citra terhadap akurasi klasifikasi motif, Sinaga et al. (2024) mengusulkan arsitektur CNN berlapis untuk klasifikasi citra batik, dan Aswan et al. (2025) secara khusus mengoptimalkan fungsi aktivasi pada arsitektur Xception untuk klasifikasi batik Sulawesi Selatan. Penerapan CNN juga terbukti efektif pada domain pengolahan citra lain, seperti identifikasi kendaraan bermotor (Ramadhani et al., 2025), yang menegaskan fleksibilitas arsitektur ini untuk berbagai tugas klasifikasi visual.

Meskipun penelitian-penelitian tersebut menunjukkan hasil yang menjanjikan, sebagian besar masih berfokus pada tahap pelatihan model di lingkungan eksperimen dan belum mengintegrasikan model ke dalam platform yang dapat diakses langsung oleh pengguna akhir secara *real-time*. Sebagian besar penelitian tersebut juga belum menerapkan mekanisme penolakan terhadap citra di luar domain (*out-of-distribution*) yang berisiko menghasilkan prediksi menyesatkan ketika sistem menerima gambar non-batik. Xception dipilih dalam penelitian ini karena penerapan *depthwise separable convolution* yang memisahkan ekstraksi fitur spasial dan fitur lintas-kanal, sehingga menghasilkan ekstraksi fitur yang lebih efisien tanpa mengorbankan akurasi (Chollet, 2017), suatu karakteristik yang relevan untuk memproses kompleksitas tekstur dan pola batik.

Berdasarkan uraian tersebut, penelitian ini mengembangkan sistem klasifikasi motif batik otomatis menggunakan CNN berarsitektur Xception dengan strategi *transfer learning*, yang diintegrasikan langsung ke dalam platform web berbasis Flask agar dapat diakses secara *real-time* oleh PT Jaya Batik. Penelitian ini bertujuan untuk (1) menerapkan arsitektur Xception guna meningkatkan akurasi klasifikasi citra motif batik, (2) merancang dan mengintegrasikan model tersebut ke dalam platform web yang mengotomatisasi proses identifikasi motif secara *real-time*, dan (3) mengevaluasi kinerja sistem berdasarkan tingkat akurasi model dan fungsionalitas antarmuka web.

2. Metode Penelitian

Penelitian ini menggunakan pendekatan eksperimental untuk membangun dan mengevaluasi model klasifikasi motif batik berbasis CNN Xception, kemudian mengintegrasikannya ke dalam aplikasi web.

2.1. Dataset dan Pembagian Data.

Dataset yang digunakan merupakan hasil pengumpulan mandiri berupa 3.009 citra motif batik dalam format .jpg dan .png, mencakup tujuh kelas motif sebagaimana disajikan pada Tabel 1. Distribusi kelas ini menunjukkan ketimpangan antara kelas mayoritas dan kelas minoritas, sebagaimana dijelaskan lebih lanjut pada bagian pembahasan. Seluruh citra dibagi menjadi tiga subset melalui teknik pembagian acak (*random split*, *random_state=123*): 80% data latih (2.407 citra), 10% data validasi (301 citra), dan 10% data uji (301 citra).

Tabel 1. Distribusi Dataset per Kelas Motif

No	Kelas Motif	Jumlah Citra
1	Parang	601
2	Kawung	560
3	Mega Mendung	560
4	Sidomukti	560
5	Truntum	560
6	Batik Cendrawasih	97
7	Batik Betawi	71
	Total	3.009

2.2. Prapemrosesan Citra

Setiap citra mengalami penyeragaman dimensi menjadi 224×224 piksel RGB agar sesuai dengan format *input* Xception, dilanjutkan dengan normalisasi skala intensitas piksel (*rescaling 1./255*) untuk meminimalkan hambatan komputasi dan mencegah *gradien* yang meledak (*exploding gradients*) selama pelatihan.

2.3. Arsitektur Model dan *Transfer learning*

Model menggunakan Xception sebagai *backbone* ekstraksi fitur dengan bobot pra-latih dari ImageNet yang dibekukan seluruhnya (*trainable=False*), sehingga hanya lapisan klasifikasi kustom yang dilatih. Bagian *fully*

```

graph LR
    Start([Mulai]) --> Input[/Input:  
Tersedia Citra Hasil Pengambilan/]
    Input --> Proses1[Proses 1:  
Masi Base Model  
Xception dan  
Pre-trained Weights  
ImageNet]
    Proses1 --> Proses2[Proses 2:  
Hapus Top Layer  
bantuan Xception/  
include_top=False]
    Proses2 --> Proses3[Proses 3:  
Tambahkan Global  
Average Pooling &  
Dense Layer Baru]
    Proses3 --> Proses4[Proses 4:  
Tambahkan Layer  
Output Softmax  
untuk 5 Kelas  
Motif Batik]
    Proses4 --> Proses5[Proses 5:  
Kompilasi Model  
dengan Optimizer  
Adam &  
Loss Function]
    Proses5 --> Proses6[Proses 6:  
Ekskusi Pelatihan/  
Training  
per Epoch]
    Proses6 --> Proses7[Proses 7:  
Evaluasi Memik Akurasi &  
Simpun Model JS]
    Proses7 --> End([Selesai])
  
```

2.4. Alur Kerja Sistem

```

graph TD
    subgraph Pengguna
        A((Pengguna)) --> B[Namailah nama user citra]
        B --> C[Namailah "Input Kamera"]
        B --> D[Namailah "Input Galeri"]
        C --> E[Mengupload citra (JPG/PNG)]
        D --> F[Mengupload citra (JPG/PNG)]
        E --> G[Mengupload citra (JPG/PNG)]
        F --> H[Mengupload citra (JPG/PNG)]
        G --> I[Mengupload citra (JPG/PNG)]
        H --> J[Mengupload citra (JPG/PNG)]
        I --> K[Mengupload citra (JPG/PNG)]
        J --> L[Mengupload citra (JPG/PNG)]
        K --> M[Mengupload citra (JPG/PNG)]
        L --> N[Mengupload citra (JPG/PNG)]
        M --> O[Mengupload citra (JPG/PNG)]
        N --> P[Mengupload citra (JPG/PNG)]
        O --> Q[Mengupload citra (JPG/PNG)]
        P --> R[Mengupload citra (JPG/PNG)]
        Q --> S[Mengupload citra (JPG/PNG)]
        R --> T[Mengupload citra (JPG/PNG)]
        S --> U[Mengupload citra (JPG/PNG)]
        T --> V[Mengupload citra (JPG/PNG)]
        U --> W[Mengupload citra (JPG/PNG)]
        V --> X[Mengupload citra (JPG/PNG)]
        W --> Y[Mengupload citra (JPG/PNG)]
        X --> Z[Mengupload citra (JPG/PNG)]
        Y --> AA[Mengupload citra (JPG/PNG)]
        Z --> AB[Mengupload citra (JPG/PNG)]
        AA --> AC[Mengupload citra (JPG/PNG)]
        AB --> AD[Mengupload citra (JPG/PNG)]
        AC --> AE[Mengupload citra (JPG/PNG)]
        AD --> AF[Mengupload citra (JPG/PNG)]
        AE --> AG[Mengupload citra (JPG/PNG)]
        AF --> AH[Mengupload citra (JPG/PNG)]
        AG --> AI[Mengupload citra (JPG/PNG)]
        AH --> AJ[Mengupload citra (JPG/PNG)]
        AI --> AK[Mengupload citra (JPG/PNG)]
        AJ --> AL[Mengupload citra (JPG/PNG)]
        AK --> AM[Mengupload citra (JPG/PNG)]
        AL --> AN[Mengupload citra (JPG/PNG)]
        AM --> AO[Mengupload citra (JPG/PNG)]
        AN --> AP[Mengupload citra (JPG/PNG)]
        AO --> AQ[Mengupload citra (JPG/PNG)]
        AP --> AR[Mengupload citra (JPG/PNG)]
        AQ --> AS[Mengupload citra (JPG/PNG)]
        AR --> AT[Mengupload citra (JPG/PNG)]
        AS --> AU[Mengupload citra (JPG/PNG)]
        AT --> AV[Mengupload citra (JPG/PNG)]
        AU --> AW[Mengupload citra (JPG/PNG)]
        AV --> AX[Mengupload citra (JPG/PNG)]
        AW --> AY[Mengupload citra (JPG/PNG)]
        AX --> AZ[Mengupload citra (JPG/PNG)]
        AY --> BA[Mengupload citra (JPG/PNG)]
        AZ --> BB[Mengupload citra (JPG/PNG)]
        BA --> BC[Mengupload citra (JPG/PNG)]
        BB --> BD[Mengupload citra (JPG/PNG)]
        BC --> BE[Mengupload citra (JPG/PNG)]
        BD --> BF[Mengupload citra (JPG/PNG)]
        BE --> BG[Mengupload citra (JPG/PNG)]
        BF --> BH[Mengupload citra (JPG/PNG)]
        BG --> BI[Mengupload citra (JPG/PNG)]
        BH --> BJ[Mengupload citra (JPG/PNG)]
        BI --> BK[Mengupload citra (JPG/PNG)]
        BJ --> BL[Mengupload citra (JPG/PNG)]
        BK --> BM[Mengupload citra (JPG/PNG)]
        BL --> BN[Mengupload citra (JPG/PNG)]
        BM --> BO[Mengupload citra (JPG/PNG)]
        BN --> BP[Mengupload citra (JPG/PNG)]
        BO --> BQ[Mengupload citra (JPG/PNG)]
        BP --> BR[Mengupload citra (JPG/PNG)]
        BQ --> BS[Mengupload citra (JPG/PNG)]
        BR --> BT[Mengupload citra (JPG/PNG)]
        BS --> BU[Mengupload citra (JPG/PNG)]
        BT --> BV[Mengupload citra (JPG/PNG)]
        BU --> BV
    end
    subgraph SistemWeb
        B --> C
        C --> E
        E --> G
        G --> I
        I --> K
        K --> M
        M --> O
        O --> Q
        Q --> S
        S --> U
        U --> W
        W --> Y
        Y --> AA
        AA --> AC
        AC --> AE
        AE --> AG
        AG --> AI
        AI --> AK
        AK --> AM
        AM --> AN
        AN --> AP
        AP --> AR
        AR --> AS
        AS --> AU
        AU --> AV
        AV --> AX
        AX --> AY
        AY --> AZ
        AZ --> BA
        BA --> BB
        BB --> BC
        BC --> BD
        BD --> BE
        BE --> BF
        BF --> BG
        BG --> BH
        BH --> BI
        BI --> BJ
        BJ --> BK
        BK --> BL
        BL --> BM
        BM --> BN
        BN --> BO
        BO --> BP
        BP --> BQ
        BQ --> BR
        BR --> BS
        BS --> BU
        BU --> BV
        BV --> BX
        BX --> BY
        BY --> BZ
        BZ --> CA
        CA --> CB
        CB --> CC
        CC --> CD
        CD --> CE
        CE --> CF
        CF --> CG
        CG --> CH
        CH --> CI
        CI --> CJ
        CJ --> CK
        CK --> CL
        CL --> CM
        CM --> CN
        CN --> CO
        CO --> CP
        CP --> CQ
        CQ --> CR
        CR --> CS
        CS --> CT
        CT --> CU
        CU --> CV
        CV --> CW
        CW --> CX
        CX --> CY
        CY --> CZ
        CZ --> DA
        DA --> DB
        DB --> DC
        DC --> DD
        DD --> DE
        DE --> DF
        DF --> DG
        DG --> DH
        DH --> DI
        DI --> DJ
        DJ --> DK
        DK --> DL
        DL --> DM
        DM --> DN
        DN --> DO
        DO --> DP
        DP --> DQ
        DQ --> DR
        DR --> DS
        DS --> DT
        DT --> DU
        DU --> DV
        DV --> DW
        DW --> DX
        DX --> DY
        DY --> DZ
        DZ --> EA
        EA --> EB
        EB --> EC
        EC --> ED
        ED --> EE
        EE --> EF
        EF --> EG
        EG --> EH
        EH --> EI
        EI --> EJ
        EJ --> EK
        EK --> EL
        EL --> EM
        EM --> EN
        EN --> EO
        EO --> EP
        EP --> EQ
        EQ --> ER
        ER --> ES
        ES --> ET
        ET --> EU
        EU --> EV
        EV --> EW
        EW --> EX
        EX --> EY
        EY --> EZ
        EZ --> FA
        FA --> FB
        FB --> FC
        FC --> FD
        FD --> FE
        FE --> FF
        FF --> FG
        FG --> FH
        FH --> FI
        FI --> FJ
        FJ --> FK
        FK --> FL
        FL --> FM
        FM --> FN
        FN --> FO
        FO --> FP
        FP --> FQ
        FQ --> FR
        FR --> FS
        FS --> FT
        FT --> FU
        FU --> FV
        FV --> FW
        FW --> FX
        FX --> FY
        FY --> FZ
        FZ --> GA
        GA --> GB
        GB --> GC
        GC --> GD
        GD --> GE
        GE --> GF
        GF --> GG
        GG --> GH
        GH --> GI
        GI --> GJ
        GJ --> GK
        GK --> GL
        GL --> GM
        GM --> GN
        GN --> GO
        GO --> GP
        GP --> GQ
        GQ --> GR
        GR --> GS
        GS --> GT
        GT --> GU
        GU --> GV
        GV --> GW
        GW --> GX
        GX --> GY
        GY --> GZ
        GZ --> HA
        HA --> HB
        HB --> HC
        HC --> HD
        HD --> HE
        HE --> HF
        HF --> HG
        HG --> HH
        HH --> HI
        HI --> HJ
        HJ --> HK
        HK --> HL
        HL --> HM
        HM --> HN
        HN --> HO
        HO --> HP
        HP --> HQ
        HQ --> HR
        HR --> HS
        HS --> HT
        HT --> HU
        HU --> HV
        HV --> HW
        HW --> HX
        HX --> HY
        HY --> HZ
        HZ --> IA
        IA --> IB
        IB --> IC
        IC --> ID
        ID --> IE
        IE --> IF
        IF --> IG
        IG --> IH
        IH --> II
        II --> IJ
        IJ --> IK
        IK --> IL
        IL --> IM
        IM --> IN
        IN --> IO
        IO --> IP
        IP --> IQ
        IQ --> IR
        IR --> IS
        IS --> IT
        IT --> IU
        IU --> IV
        IV --> IW
        IW --> IX
        IX --> IY
        IY --> IZ
        IZ --> JA
        JA --> JB
        JB --> JC
        JC --> JD
        JD --> JE
        JE --> JF
        JF --> JG
        JG --> JH
        JH --> JI
        JI --> JJ
        JJ --> JK
        JK --> JL
        JL --> JM
        JM --> JN
        JN --> JO
        JO --> JP
        JP --> JQ
        JQ --> JR
        JR --> JS
        JS --> JT
        JT --> JU
        JU --> JV
        JV --> JW
        JW --> JX
        JX --> JY
        JY --> JZ
        JZ --> KA
        KA --> KB
        KB --> KC
        KC --> KD
        KD --> KE
        KE --> KF
        KF --> KG
        KG --> KH
        KH --> KI
        KI --> KJ
        KJ --> KL
        KL --> KM
        KM --> KN
        KN --> KO
        KO --> KP
        KP --> KQ
        KQ --> KR
        KR --> KS
        KS --> KT
        KT --> KU
        KU --> KV
        KV --> KW
        KW --> KX
        KX --> KY
        KY --> KZ
        KZ --> LA
        LA --> LB
        LB --> LC
        LC --> LD
        LD --> LE
        LE --> LF
        LF --> LG
        LG --> LH
        LH --> LI
        LI --> LJ
        LJ --> LK
        LK --> LL
        LL --> LM
        LM --> LN
        LN --> LO
        LO --> LP
        LP --> LQ
        LQ --> LR
        LR --> LS
        LS --> LT
        LT --> LU
        LU --> LV
        LV --> LW
        LW --> LX
        LX --> LY
        LY --> LZ
        LZ --> MA
        MA --> MB
        MB --> MC
        MC --> MD
        MD --> ME
        ME --> MF
        MF --> MG
        MG --> MH
        MH --> MI
        MI --> MJ
        MJ --> MK
        MK --> ML
        ML --> MN
        MN --
```

2.5. Integrasi Platform Web

2.6. Pengujian Sistem

Evaluasi kinerja model dilakukan menggunakan metrik *accuracy*, *precision*, *recall*, dan F1-score berdasarkan confusion matrix pada data uji. Fungsionalitas sistem diverifikasi melalui blackbox testing (11 skenario) yang berfokus pada perilaku antarmuka dari sudut pandang pengguna akhir, serta whitebox testing (6 skenario) yang menelaah struktur logika internal kode program pada sisi *backend* dan *frontend*.

Memaparkan hasil pengujian eksperimental dan pembahasan komprehensif mengenai implementasi sistem klasifikasi motif batik berbasis web yang telah dikembangkan. Pemaparan dimulai dengan analisis performa pelatihan model *Convolutional Neural Network* (CNN) berarsitektur Xception yang mencakup laju konvergensi dan tingkat akurasi selama 100 epoch. Selanjutnya, dilakukan evaluasi mendalam pada sampel data uji menggunakan *confusion matrix* serta *classification report* untuk mengukur ketangguhan model dalam menangani ketimpangan jumlah data (*class imbalance*) pada beberapa kelas minoritas. Bagian akhir dari bab ini menguraikan

Lisensi: Creative Commons Attribution 4.0 International (CC BY 4.0)


integrasi model ke dalam antarmuka web berbasis Flask, hasil verifikasi fungsionalitas sistem melalui *blackbox* dan *whitebox testing*, serta komparasi performa dengan beberapa penelitian terdahulu guna membuktikan efektivitas solusi yang diusulkan bagi PT Jaya Batik.

3.1. Performa Pelatihan Model

Model menunjukkan laju konvergensi yang cepat berkat strategi *transfer learning*. Pada epoch pertama, akurasi validasi telah mencapai 97,34%, dan terus meningkat hingga mencapai titik loss validasi terendah sebesar 0,0028 pada epoch ke-37. Setelah epoch tersebut, model menunjukkan gejala *mild overfitting* yang ditandai naiknya *loss* validasi, namun mekanisme *Dropout* berhasil menjaga akurasi validasi tetap stabil pada kisaran 99,67% hingga epoch ke-100, sebagaimana dirangkum pada Tabel 2 dan divisualisasikan pada kurva pelatihan Gambar 3.

Tabel 2. Performa Model pada Epoch Signifikan

Epoch	Train Acc	Train Loss	Val Acc	Val Loss
1	84,04%	0,4790	97,34%	0,0802
3	98,05%	0,0540	99,34%	0,0169
4	99,09%	0,0336	99,67%	0,0236
10	99,46%	0,0124	99,34%	0,0148
37	99,71%	0,0070	99,67%	0,0028
50	100%	0,0004	99,67%	0,0210
100	99,92%	0,0055	99,67%	0,0988



Gambar 3. Kurva Pelatihan Loss dan Accuracy

3.2. Evaluasi pada Data Uji

Evaluasi buta (*blind test*) pada 301 sampel data uji menghasilkan akurasi sebesar 99,34%, dengan hanya 2 dari 301 citra yang gagal diklasifikasikan dengan benar. Tabel 3 menyajikan *classification report* lengkap untuk setiap kelas motif


Tabel 3. Classification Report Model CNN Xception pada Data Uji

Kelas	Precision	Recall	F1-Score	Support
Batik Betawi	0,83	0,83	0,83	6
Batik Cendrawasih	0,94	0,94	0,94	18
Kawung	1,00	1,00	1,00	51
Mega Mendung	1,00	1,00	1,00	56
Parang	1,00	1,00	1,00	55
Sidomukti	1,00	1,00	1,00	67
Truntum	1,00	1,00	1,00	48
Weighted Avg	0,99	0,99	0,99	301

Lima kelas mayoritas (Kawung, Mega Mendung, Parang, Sidomukti, dan Truntum) mencatatkan F1-score sempurna sebesar 1,00, sementara dua kelas minoritas menunjukkan performa yang sedikit lebih rendah, yaitu Batik Cendrawasih (F1-score 0,94; 97 citra latih) dan Batik Betawi (F1-score 0,83; 71 citra latih). Penurunan performa pada kedua kelas ini konsisten dengan fenomena *class imbalance*, di mana jumlah sampel latih yang jauh lebih sedikit dibandingkan kelas mayoritas (560–601 citra) membatasi kemampuan model dalam mempelajari variasi visual kedua motif tersebut secara menyeluruh. Filia et al. (2023) melaporkan temuan serupa, bahwa performa CNN pada klasifikasi motif batik menurun signifikan pada kelas dengan representasi data yang tidak seimbang, dan augmentasi maupun oversampling data dapat membantu memitigasi masalah tersebut pada penelitian selanjutnya. Dengan agregat weighted average F1-score sebesar 0,99, model tetap menunjukkan ketangguhan yang solid untuk lingkungan produksi.

3.3. Uji Implementasi Antarmuka Web

Model yang telah dilatih diintegrasikan ke dalam antarmuka web yang dibangun menggunakan Flask, HTML5, CSS3, dan JavaScript murni, sebagaimana ditunjukkan pada Gambar 4. Halaman utama menampilkan ringkasan performa model (tujuh motif dengan akurasi 99,33%) beserta panel unggah citra yang mendukung dua modalitas masukan, yaitu unggah berkas lokal melalui mekanisme *drag-and-drop* dan tangkapan langsung dari kamera perangkat menggunakan WebRTC API. Setelah proses klasifikasi selesai, sistem merender panel laporan yang memuat nama motif, diagram batang dinamis yang menunjukkan persentase keyakinan prediksi, serta narasi filosofi dan asal daerah dari motif yang teridentifikasi. Antarmuka juga menyediakan modul galeri yang memperkenalkan ketujuh motif batik beserta riwayat sesi klasifikasi yang tersimpan sementara pada penyimpanan sesi peramban (sessionStorage), sehingga pengguna dapat menelusuri kembali hasil identifikasi sebelumnya tanpa memerlukan basis data pada peladen.



Gambar 4. Antarmuka Hasil Identifikasi Motif Batik pada Platform Web

3.4. Perbandingan dengan Penelitian Terdahulu

Akurasi 99,34% yang dicapai penelitian ini melampaui performa penelitian klasifikasi batik terdahulu, seperti CNN pada motif Banyuwangi oleh Hakim et al. (2023) dengan akurasi 63% dan baseline VGG-16 pada klasifikasi batik Nusantara oleh Haq et al. (2025) dengan akurasi di kisaran 85%. Temuan ini memperkuat hasil optimasi arsitektur Xception oleh Aswan et al. (2025) pada klasifikasi batik Sulawesi Selatan, yang sama-sama menunjukkan bahwa strategi *transfer learning* pada arsitektur berbasis *depthwise separable convolution* mampu menghasilkan akurasi tinggi pada kompleksitas tekstur batik dibandingkan pendekatan CNN konvensional.

3.5. Pengujian Fungsionalitas Sistem

Seluruh 11 skenario blackbox testing dan 6 skenario whitebox testing menghasilkan status valid, mencakup navigasi antarmuka, mekanisme unggah berkas dan tangkapan kamera, respons visual hasil klasifikasi, serta validasi logika penolakan citra di luar domain (*confidence threshold* 85%). Tabel 4 merangkum aspek-aspek utama yang diuji beserta status kelulusannya.

Tabel 4. Ringkasan Skenario Pengujian Blackbox dan Whitebox

No	Aspek yang Diuji	Jenis Pengujian	Status
1	Navigasi antarmuka dan transisi tampilan	Blackbox	Valid
2	Input citra (unggah berkas dan kamera WebRTC)	Blackbox	Valid
3	Logika <i>confidence threshold</i> 85%	Blackbox & Whitebox	Valid
4	Render hasil klasifikasi, filosofi, dan asal daerah	Blackbox & Whitebox	Valid
5	Penyimpanan dan penghapusan riwayat sesi	Blackbox & Whitebox	Valid

Hasil pengujian pada Tabel 4 menunjukkan bahwa platform web yang dibangun dapat berfungsi sesuai spesifikasi rancangan, baik dari sisi pengalaman pengguna (blackbox) maupun struktur logika internal kode program pada sisi *backend* dan *frontend* (whitebox).

3.6. Analisis Kontribusi Transfer Learning dan Arsitektur Xception

Capaian akurasi pengujian sebesar 99,34% menunjukkan bahwa penggunaan transfer learning memberikan kontribusi penting terhadap kemampuan model dalam mengenali pola visual motif batik. Pemanfaatan bobot pra-latih ImageNet memungkinkan lapisan dasar Xception membawa representasi fitur umum, seperti garis, tepi, tekstur, gradasi warna, dan bentuk berulang, sebelum disesuaikan dengan karakteristik tujuh kelas batik dalam penelitian. Kondisi ini relevan karena motif batik tersusun atas kombinasi elemen visual yang kompleks dan sering memiliki kemiripan antarkelas. Dengan membekukan lapisan dasar, proses pelatihan lebih difokuskan pada lapisan klasifikasi kustom sehingga model tidak harus mempelajari seluruh representasi visual dari awal. Strategi tersebut

DOI: <https://doi.org/10.69693/ijmst.v4i2.12444>

Lisensi: Creative Commons Attribution 4.0 International (CC BY 4.0)

juga menekan risiko perubahan besar pada bobot yang telah terbentuk dan membantu model mencapai akurasi validasi tinggi sejak epoch awal. Hasil ini memperkuat temuan Aswan et al. (2025) bahwa arsitektur Xception memiliki kemampuan yang baik dalam mengekstraksi tekstur batik, khususnya ketika dikombinasikan dengan pengaturan fungsi aktivasi dan pembelajaran berbasis citra yang tepat. Pada penelitian ini, keunggulan tersebut diperluas melalui penerapan model pada tujuh motif dan integrasi langsung ke aplikasi web untuk kebutuhan operasional.

Karakteristik depthwise separable convolution pada Xception juga membantu memisahkan proses pembelajaran fitur spasial dan hubungan antarkanal warna. Pada citra batik, mekanisme tersebut bermanfaat untuk mendeteksi susunan ornamen, pengulangan pola, kontur utama, serta variasi warna tanpa menggunakan operasi konvolusi penuh pada setiap tahap. Walaupun total parameter model mencapai lebih dari 21 juta, hanya 591.879 parameter yang dilatih karena sebagian besar bobot Xception dibekukan. Komposisi ini memperlihatkan bahwa model tetap memiliki kapasitas representasi yang besar, tetapi kebutuhan penyesuaian terhadap dataset penelitian dapat dibatasi pada lapisan akhir. Secara metodologis, pendekatan tersebut sesuai untuk dataset berukuran menengah karena dapat mengurangi kebutuhan komputasi dibandingkan pelatihan model dari awal. Namun, pembekuan seluruh lapisan dasar juga berarti bahwa model masih sangat bergantung pada representasi umum ImageNet. Pada penelitian berikutnya, fine-tuning terbatas terhadap beberapa blok akhir Xception dapat diuji setelah model utama stabil. Fine-tuning tersebut perlu dilakukan menggunakan learning rate yang lebih kecil agar fitur spesifik batik dapat dipelajari tanpa merusak bobot umum yang telah terbentuk.

3.7. Interpretasi Kurva Pelatihan dan Kemampuan Generalisasi Model

Kurva pelatihan menunjukkan bahwa model mencapai akurasi validasi 97,34% sejak epoch pertama dan meningkat hingga 99,67% pada beberapa epoch berikutnya. Pola tersebut menggambarkan bahwa fitur pra-latih yang dibawa Xception telah cukup relevan untuk membedakan sebagian besar motif batik. Nilai validation loss terendah sebesar 0,0028 pada epoch ke-37 dapat dipandang sebagai titik ketika keseimbangan antara kemampuan belajar dan generalisasi berada pada kondisi terbaik. Setelah titik tersebut, training accuracy tetap meningkat, sedangkan validation loss mulai menunjukkan kenaikan. Perbedaan arah tersebut mengindikasikan mild overfitting, yaitu model semakin menyesuaikan diri terhadap variasi data latih tanpa memberikan peningkatan yang sebanding pada data validasi. Meskipun demikian, akurasi validasi tetap berada pada kisaran tinggi hingga epoch ke-100. Keberadaan lapisan Dropout 0,5 berperan dalam membatasi ketergantungan model terhadap neuron tertentu dan membantu mempertahankan kestabilan performa. Berdasarkan pola ini, model telah memiliki kemampuan generalisasi yang baik terhadap data uji, tetapi pemilihan bobot model terbaik seharusnya tetap mengacu pada validation loss terendah, bukan hanya epoch terakhir.

Analisis kurva pelatihan juga menunjukkan pentingnya penggunaan mekanisme early stopping dan model checkpoint pada pengembangan lanjutan. Apabila pelatihan dihentikan saat validation loss tidak lagi membaik, waktu komputasi dapat dikurangi dan risiko overfitting dapat ditekan. Dalam penelitian ini, pelatihan selama 100 epoch tetap memberikan gambaran lengkap mengenai perilaku konvergensi model dan membuktikan bahwa akurasi validasi tidak mengalami penurunan drastis. Namun, untuk implementasi produksi yang berulang, proses pemilihan epoch optimal perlu dibuat lebih otomatis. Evaluasi juga dapat dilengkapi dengan k-fold cross-validation atau repeated hold-out untuk menilai konsistensi model pada pembagian data yang berbeda. Random split dengan random_state tertentu memberikan hasil yang dapat direproduksi, tetapi satu pembagian data belum sepenuhnya menggambarkan variasi performa apabila komposisi citra berubah. Dengan demikian, capaian 99,34% merupakan indikator performa yang sangat kuat pada dataset pengujian saat ini, sedangkan validasi tambahan tetap diperlukan sebelum model digunakan pada koleksi batik yang jauh lebih luas dan beragam.

3.8. Dampak Ketimpangan Kelas terhadap Hasil Klasifikasi

Perbedaan F1-score antara kelas mayoritas dan minoritas memperlihatkan bahwa jumlah citra memiliki pengaruh langsung terhadap kelengkapan pola yang dipelajari model. Lima kelas mayoritas memiliki 560 hingga 601 citra dan seluruhnya mencapai F1-score 1,00 pada data uji. Sebaliknya, Batik Cendrawasih dan Batik Betawi hanya memiliki 97 dan 71 citra sehingga dukungan data ujinya juga terbatas. F1-score 0,94 dan 0,83 pada kedua kelas tersebut tidak menunjukkan bahwa model gagal mengenali motif, melainkan menandakan bahwa variasi visual yang tersedia belum sebanyak kelas lain. Motif batik dapat mengalami perubahan pada warna kain, skala ornamen, sudut pengambilan gambar, pencahayaan, lipatan, dan kombinasi elemen dekoratif. Ketika jumlah contoh terlalu sedikit, model berpotensi hanya mengenali pola yang dominan dan belum sepenuhnya mempelajari variasi yang muncul di kondisi nyata. Temuan ini sejalan dengan Filia et al. (2023), yang menjelaskan bahwa ketimpangan kelas dapat menurunkan performa CNN pada kelas yang kurang terwakili.

Upaya perbaikan pada kelas minoritas perlu diprioritaskan melalui penambahan data asli dan augmentasi yang tetap mempertahankan karakter motif. Augmentasi dapat berupa rotasi terbatas, perubahan pencahayaan, zoom, pergeseran, dan crop yang tidak menghilangkan struktur utama. Teknik oversampling juga dapat digunakan, tetapi harus dikendalikan agar model tidak sekadar menghafal citra yang sama. Alternatif lain adalah menerapkan class weight pada fungsi loss sehingga kesalahan pada kelas minoritas memperoleh penalti lebih besar. Evaluasi

selanjutnya sebaiknya tidak hanya menggunakan weighted average karena metrik tersebut dapat didominasi kelas dengan jumlah data besar. Macro average, balanced accuracy, dan analisis confusion matrix per kelas dapat memberikan gambaran yang lebih adil. Penambahan data Batik Betawi dan Batik Cendrawasih diharapkan bukan hanya meningkatkan nilai akurasi, tetapi juga memperkuat konsistensi model ketika menghadapi variasi kain yang belum pernah terlihat pada tahap pelatihan.

3.9. Evaluasi Confidence Threshold dan Penolakan Citra di Luar Domain

Penerapan confidence threshold 85% merupakan komponen penting karena model klasifikasi Softmax selalu menghasilkan probabilitas untuk salah satu kelas, bahkan ketika citra masukan bukan batik. Tanpa mekanisme penolakan, gambar objek lain dapat dipaksa masuk ke kelas motif dengan probabilitas tertinggi dan menghasilkan informasi yang menyesatkan. Ambang 85% membentuk lapisan pengamanan awal dengan memastikan bahwa hasil hanya ditampilkan ketika keyakinan model berada pada tingkat yang dianggap memadai. Pada konteks PT Jaya Batik, mekanisme ini meningkatkan kehati-hatian sistem karena pengguna tidak langsung menerima nama dan filosofi motif apabila karakter visual citra tidak cukup dekat dengan data pelatihan. Pengujian blackbox dan whitebox yang dinyatakan valid menunjukkan bahwa logika tersebut telah berjalan sesuai rancangan pada skenario yang diuji.

Walaupun demikian, confidence threshold tidak sepenuhnya sama dengan metode deteksi out-of-distribution yang khusus. Probabilitas Softmax dapat bersifat terlalu percaya diri pada citra tertentu, sehingga nilai tinggi belum selalu menjamin bahwa gambar benar-benar berasal dari domain batik. Oleh karena itu, nilai 85% perlu dievaluasi lebih lanjut menggunakan kumpulan citra negatif yang beragam, seperti kain polos, tekstur bukan batik, gambar benda, foto manusia, dan motif tekstil dari budaya lain. Pengujian tersebut dapat menghasilkan kurva penerimaan dan penolakan untuk menentukan ambang yang paling seimbang antara false acceptance dan false rejection. Pengembangan lanjutan juga dapat menerapkan temperature scaling, entropy threshold, distance-based confidence, atau model dua tahap yang terlebih dahulu membedakan citra batik dan non-batik sebelum mengklasifikasikan motif. Dengan cara ini, sistem tidak hanya akurat pada tujuh kelas yang dikenal, tetapi juga lebih aman ketika digunakan pada masukan yang tidak terkontrol.

3.10. Kesiapan Implementasi Web dan Pengalaman Pengguna

Integrasi model ke dalam Flask menjadikan hasil penelitian tidak berhenti pada tahap eksperimen, tetapi dapat digunakan melalui antarmuka yang mudah diakses. Pengguna dapat memilih citra dari penyimpanan perangkat atau mengambil gambar langsung menggunakan kamera melalui WebRTC API. Dua modalitas ini sesuai dengan kebutuhan operasional karena identifikasi dapat dilakukan terhadap katalog digital maupun produk fisik yang sedang diperiksa. Setelah inferensi selesai, sistem menampilkan nama motif, persentase keyakinan, asal daerah, dan filosofi. Penyajian tersebut mengubah model klasifikasi menjadi media informasi yang dapat membantu operator, pelanggan, maupun pengguna lain memahami konteks budaya dari motif yang dikenali. Riwayat klasifikasi pada sessionStorage juga memberikan kemudahan untuk meninjau hasil selama sesi penggunaan tanpa menambah kebutuhan basis data pada peladen.

Dari sudut pandang pengalaman pengguna, kecepatan respons dan kejelasan informasi menjadi faktor penting. Meskipun penelitian membuktikan seluruh fungsi utama berjalan valid, pengujian lanjutan perlu mengukur waktu inferensi, waktu unggah, kompatibilitas peramban, dan kualitas tampilan pada berbagai ukuran layar. Foto dari kamera perangkat dapat memiliki resolusi tinggi, orientasi berbeda, atau pencahayaan tidak seragam. Oleh karena itu, antarmuka sebaiknya memberi panduan pengambilan gambar, indikator proses, validasi ukuran berkas, serta pesan kesalahan yang mudah dipahami. Aspek aksesibilitas juga dapat ditingkatkan melalui kontras yang baik, teks alternatif, navigasi keyboard, dan desain responsif. Dengan penyempurnaan tersebut, sistem akan lebih mudah digunakan oleh operator dengan tingkat literasi digital yang berbeda dan dapat mengurangi ketergantungan pada petunjuk teknis tambahan.

3.11. Implikasi Operasional dan Pelestarian Informasi Budaya

Bagi PT Jaya Batik, sistem klasifikasi dapat mendukung proses pendataan produk, penyusunan katalog, pemeriksaan awal motif, serta pelayanan informasi kepada pelanggan. Proses identifikasi manual tetap memiliki nilai karena pengetahuan ahli diperlukan untuk menilai sejarah, teknik pembuatan, dan variasi lokal. Namun, sistem dapat berfungsi sebagai alat bantu yang mempercepat penyaringan awal dan menyamakan hasil identifikasi pada kondisi operasional rutin. Ketika citra memperoleh tingkat keyakinan tinggi, operator dapat menggunakan hasil sebagai referensi awal. Ketika keyakinan rendah, sistem memberi sinyal bahwa verifikasi manual diperlukan. Pembagian peran tersebut menempatkan teknologi sebagai pendukung keputusan, bukan pengganti mutlak keahlian manusia.

Penyertaan narasi filosofi dan asal daerah memberikan kontribusi tambahan terhadap pelestarian informasi budaya. Setiap hasil klasifikasi tidak hanya menampilkan label teknis, tetapi juga menghubungkan motif dengan makna simbolisnya. Pendekatan ini dapat membantu edukasi pelanggan dan memperkuat nilai cerita pada produk batik. Namun, informasi budaya harus dikurasi bersama sumber yang kompeten agar tidak terjadi penyederhanaan atau kesalahan atribusi. Variasi motif dapat memiliki makna berbeda menurut daerah, periode, dan konteks

DOI: <https://doi.org/10.69693/ijmst.v4i2.12444>

Lisensi: Creative Commons Attribution 4.0 International (CC BY 4.0)

penggunaan. Oleh sebab itu, pengembangan basis pengetahuan perlu dilengkapi sumber rujukan, proses validasi oleh ahli batik, serta mekanisme pembaruan konten. Dengan tata kelola yang baik, aplikasi dapat berkembang dari alat klasifikasi menjadi media dokumentasi digital yang mendukung promosi, pembelajaran, dan pelestarian motif batik Nusantara.

3.12. Skalabilitas, Keamanan, Keterbatasan, dan Arah Pengembangan

Kesiapan sistem untuk penggunaan lebih luas dipengaruhi oleh kapasitas peladen, ukuran model, jumlah pengguna, dan pola akses kamera atau unggahan berkas. Model Xception memiliki ukuran komputasi yang relatif besar sehingga deployment perlu mempertimbangkan memori, CPU atau GPU, serta waktu pemuatan model. Optimalisasi dapat dilakukan melalui model caching, batch processing, quantization, pruning, atau konversi ke format yang lebih ringan. Apabila jumlah permintaan meningkat, aplikasi Flask dapat ditempatkan di belakang application server dan reverse proxy serta dilengkapi pembatasan ukuran berkas. Pengujian beban diperlukan untuk mengetahui jumlah permintaan serentak yang dapat dilayani tanpa penurunan kinerja. Selain itu, setiap berkas yang diunggah harus divalidasi berdasarkan tipe, ukuran, dan konten untuk mencegah penyalahgunaan.

Aspek privasi juga perlu diperhatikan karena fitur kamera berpotensi menangkap objek lain di sekitar kain. Sistem sebaiknya memproses citra hanya untuk klasifikasi, menghindari penyimpanan permanen tanpa persetujuan, dan menyediakan informasi yang jelas mengenai penggunaan data. Pada sisi penelitian, keterbatasan utama meliputi jumlah kelas yang baru tujuh, ketimpangan dataset, pembagian data tunggal, dan belum adanya pengujian lapangan jangka panjang. Penelitian selanjutnya dapat memperluas koleksi motif, menyeimbangkan data, menerapkan validasi silang, serta membandingkan Xception dengan EfficientNetV2, MobileNet, dan Vision Transformer. Pengukuran waktu inferensi, konsumsi sumber daya, dan usability juga diperlukan agar evaluasi tidak hanya berfokus pada akurasi. Dengan pengembangan bertahap, sistem dapat menjadi platform yang lebih kuat, aman, mudah dipelihara, dan relevan untuk kebutuhan identifikasi batik dalam skala organisasi.

3.13. Validitas Penggunaan dan Rencana Implementasi Bertahap

Validitas penggunaan sistem dalam lingkungan PT Jaya Batik perlu dinilai melalui uji lapangan yang melibatkan operator dengan latar belakang pengalaman berbeda. Pengujian laboratorium membuktikan bahwa fungsi model dan antarmuka berjalan sesuai rancangan, tetapi kondisi operasional dapat menghadirkan variasi citra yang lebih luas, seperti kain terlipat, motif tertutup sebagian, pencahayaan redup, latar belakang ramai, sudut kamera miring, atau produk yang memadukan lebih dari satu motif. Uji lapangan dapat membandingkan hasil klasifikasi sistem dengan penilaian ahli, mengukur waktu penyelesaian tugas, serta mencatat jenis kesalahan yang paling sering terjadi. Selain itu, penerimaan pengguna perlu dievaluasi melalui aspek kemudahan belajar, kejelasan informasi, kepercayaan terhadap hasil, dan manfaat bagi pekerjaan. Data tersebut akan memberikan gambaran apakah akurasi tinggi pada data uji benar-benar menghasilkan peningkatan efisiensi pada proses bisnis. Apabila ditemukan perbedaan antara hasil model dan penilaian ahli, citra terkait dapat dimasukkan ke dalam proses kurasi dan pelatihan ulang sehingga sistem berkembang berdasarkan pengalaman penggunaan nyata.

Implementasi sebaiknya dilakukan secara bertahap. Tahap awal dapat berupa penggunaan terbatas sebagai alat bantu internal untuk tujuh motif yang telah tersedia. Pada tahap ini, seluruh hasil dengan confidence rendah atau hasil yang diragukan operator dicatat untuk evaluasi. Tahap berikutnya dapat memperluas jumlah pengguna, menambahkan kelas motif, dan mengintegrasikan hasil klasifikasi dengan katalog produk atau sistem inventaris. Setiap penambahan kelas harus disertai standar pengumpulan citra, pemeriksaan label oleh ahli, dokumentasi versi dataset, dan pengujian ulang model agar kualitas tidak menurun. Pengelolaan versi model juga penting supaya perubahan akurasi dapat ditelusuri dan sistem dapat dikembalikan ke versi sebelumnya apabila terjadi masalah. Dengan penerapan bertahap, PT Jaya Batik dapat memperoleh manfaat otomatisasi tanpa mengabaikan kontrol kualitas, pengetahuan ahli, dan perlindungan informasi budaya. Pendekatan ini sekaligus menyediakan dasar yang lebih kuat untuk mengembangkan sistem menjadi layanan klasifikasi batik yang berkelanjutan, terukur, dan dapat dipertanggungjawabkan.

4. Kesimpulan

Penelitian ini berhasil membangun sistem klasifikasi motif batik otomatis menggunakan CNN berarsitektur Xception dengan strategi *transfer learning*, yang terintegrasi ke dalam platform web berbasis Flask. Model mencapai akurasi 99,34% pada data uji, dengan lima kelas motif mayoritas mencatatkan F1-score sempurna, sementara dua kelas minoritas menunjukkan performa sedikit lebih rendah akibat ketimpangan jumlah data latih. Mekanisme *confidence threshold* sebesar 85% terbukti efektif menolak citra di luar domain motif batik untuk mencegah prediksi yang menyesatkan. Seluruh skenario pengujian blackbox dan whitebox mengonfirmasi bahwa fungsionalitas sistem berjalan sesuai rancangan, baik dari sisi antarmuka pengguna maupun struktur logika program. Hasil ini membuktikan bahwa arsitektur Xception dengan *transfer learning* mampu meningkatkan akurasi klasifikasi citra batik secara signifikan dan menghasilkan solusi praktis yang siap diterapkan pada operasional PT Jaya Batik. Penelitian selanjutnya disarankan untuk menyeimbangkan distribusi data pada kelas minoritas, memperluas cakupan kelas motif batik Nusantara lainnya, serta menguji arsitektur alternatif seperti

Reference

- ADDIN Mendeley Bibliography CSL_BIBLIOGRAPHY Aisyah, S., Astuti, R., Basysyar, F. M., Nurdian, O., & Ali, I. (2024). *Convolutional Neural Networks For Classification Motives And The Effect Of Image Dimensions*. Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi), 8(1), 181–188. <https://doi.org/10.29207/Resti.V8i1.5623>
- Anggoro, D. A., Marzuki, A. A. T., & Supriyanti, W. (2024). Classification Of Solo Batik Patterns Using Deep Learning *Convolutional Neural Networks* Algorithm. TELKOMNIKA (Telecommunication Computing Electronics And Control), 22(1), 232–240. <https://doi.org/10.12928/TELKOMNIKA.V22i1.24598>
- Ardyani, S. S. F., & Sari, C. A. (2024). A Web-Based For Demak Batik Classification Using VGG16 *Convolutional Neural Network*. Advance Sustainable Science, Engineering And Technology, 6(4), 0240406. <https://doi.org/10.26877/Asset.V6i4.771>
- Ariawan, D., Budimansyah, E., Yudha, W. R., Maulana, R. D., & Munsarif, M. (2025). Klasifikasi Motif Batik Indonesia Menggunakan *Convolutional Neural Network* (CNN). Jurnal Komputer Dan Teknologi Informasi, 3(2), 45–53. [DOI Belum Ditemukan – Mohon Diverifikasi]
- Aswan, Puspaningrum, E. Y., & Asrul, B. E. W. (2025). Optimization Of CNN Activation Functions Using Xception For South Sulawesi Batik Classification. Sistemasi: Jurnal Sistem Informasi, 14(5), 2382–2394. <https://doi.org/10.32520/Stmsi.V14i5.5281>
- Chollet, F. (2017). Xception: Deep Learning With *Depthwise Separable Convolutions*. Proceedings Of The IEEE Conference On Computer Vision And Pattern Recognition (CVPR), 1251–1258. <https://doi.org/10.1109/CVPR.2017.195>
- Filia, B. J., Et Al. (2023). Improving Batik Pattern Classification Using CNN With Advanced Augmentation And Oversampling On Imbalanced Dataset. Procedia Computer Science, 227, 508–517. <https://doi.org/10.1016/J.Procs.2023.10.552>
- Hakim, L., Rahmanto, H. R., Kristanto, S. P., & Yusuf, D. (2023). Klasifikasi Citra Motif Batik Banyuwangi Menggunakan *Convolutional Neural Network*. Jurnal Teknoinfo, 17(1), 203–211. <https://doi.org/10.33365/Jti.V17i1.2342>
- Haq, Z. F., Bianto, M. A., Agustin, A., & Nurfebrianto, M. R. (2025). Implementasi *Convolutional Neural Network* (CNN) Untuk Klasifikasi Citra Batik Nusantara. Jurnal Teknik Informatika Dan Teknologi Informasi, 5(1), 456–471. <https://doi.org/10.55606/Jutiti.V5i1.5421>
- Hasyim, F., Malik, K., Rizal, F., & Yudistira, R. (2022). Implementasi Algoritma *Convolutional Neural Networks* (CNN) Untuk Klasifikasi Batik. COREAI: Jurnal Kecerdasan Buatan, Komputasi Dan Teknologi Informasi, 2(2), 40–47. <https://doi.org/10.33650/Coreai.V2i2.3365>
- Jumadi, J., Yudianti, Y., & Sartika, D. (2021). Pengolahan Citra Digital Untuk Identifikasi Objek Menggunakan Metode Hierarchical Agglomerative Clustering. Jurnal Sains Dan Teknologi, 10(2), 148–156. [DOI Belum Ditemukan – Mohon Diverifikasi]
- Octavianus, Y., & Avianto, D. (2025). Modifikasi Arsitektur Dalam *Convolutional Neural Network* Untuk Klasifikasi Batik Lampung Dan Batik Yogyakarta. Jurnal Indonesia: Manajemen Informatika Dan Komunikasi (JIMIK), 6(1), 522–535. [DOI Belum Ditemukan – Mohon Diverifikasi]
- Prayoga, A., Maimunah, Sukmasetya, P., Yudianto, M. R. A., & Hasani, R. A. (2023). Arsitektur *Convolutional Neural Network* Untuk Model Klasifikasi Citra Batik Yogyakarta. Journal Of Applied Computer Science And Technology, 4(2), 82–89. <https://doi.org/10.52158/Jacost.V4i2.486>
- Ramadhani, F. K., Hsb, M. F. H., Alfaruqy, O. M. F., Nurzanah, L., & Gibran, M. K. (2025). Implementasi Pengolahan Citra Untuk Identifikasi Motor Menggunakan Algoritma *Convolutional Neural Network* (CNN). Jurnal Citrakara, 7(2), 122–128. [DOI Belum Ditemukan – Mohon Diverifikasi]
- Salsabila, A. P. B. (2023). Klasifikasi Motif Batik Karawang Berbasis Citra Digital. Jurnal Sistem Dan Teknologi Informasi, 8(1). [DOI Belum Ditemukan – Mohon Diverifikasi]
- Sinaga, D., Jatmoko, C., Suprayogi, S., & Hedriyanto, N. (2024). Multi-Layer *Convolutional Neural Networks* For Batik Image Classification. Scientific Journal Of Informatics, 11(2), 477–484. <https://doi.org/10.15294/Sji.V11i2.3309>
- Susanti, I. D., Winarno, S., & Zeniarja, J. (2024). Yogyakarta Batik Image Classification Based On *Convolutional Neural Network*. Advance Sustainable Science, Engineering And Technology, 6(1). <https://doi.org/10.26877/Asset.V6i1.18002>