JURNAL TEKNIK INFORMATIKA DAN MULTIMEDIA Vol 6, No.1, Mei 2026, pp. 395 - 403
p-ISSN : 2808-909X (print)
e-ISSN : 2798-2505 (online)
http://journal.politeknik-pratama.ac.id/index.php/JTIM · page 395
DOI : https://doi.org/10.51903/informatika.v6i1.1516

ADAPTIVE CLASS WEIGHTING DAN AUGMENTATION UNTUK KLASIFIKASI BATIK KERATON

Witriyani[1*], Dian Ade Kurnia[2], Yudhistira Arie Wijaya[3], Mulyawan[4], Irfan Ali[5]

[1] STMIK IKMI Cirebon
Jl. Perjuangan No.10B, Karyamulya, Kec. Kesambi, Kota Cirebon, telp/fax: (0231) 490480, e-mail: yaniwitri63@gmail.com
[2] STMIK IKMI Cirebon
Jl. Perjuangan No.10B, Karyamulya, Kec. Kesambi, Kota Cirebon, telp/fax: (0231) 490480, e-mail: dianade2012@gmail.com
[3] STMIK IKMI Cirebon
Jl. Perjuangan No.10B, Karyamulya, Kec. Kesambi, Kota Cirebon, telp/fax: (0231) 490480, e-mail: yudhistira010471@gmail.com
[4] STMIK IKMI Cirebon
Jl. Perjuangan No.10B, Karyamulya, Kec. Kesambi, Kota Cirebon, telp/fax: (0231) 490480, e-mail: wm7488748@gmail.com
[5] STMIK IKMI Cirebon
Jl. Perjuangan No.10B, Karyamulya, Kec. Kesambi, Kota Cirebon, telp/fax: (0231) 490480, e-mail: irfanaali0.0@gmail.com
[*] coresspondence

ARTICLE INFO

Article history:

Received 10 December 2026
Received in revised form 24 January 2026
Accepted 8 Mei 2026
Available online 15 Mei 2026

ABSTRACT

This study aims to improve the performance of Batik Keraton motif classification on an imbalanced dataset through the integration of adaptive class weighting and data augmentation within a transfer learning framework. The dataset consists of 1,799 images across four classes (Kawung, Mega Mendung, Parang, Truntum), preprocessed to 224×224 pixels and split stratifiedly into training, validation, and test sets (80/10/10). Three transfer learning architectures—ResNet50V2, VGG16, and EfficientNetB0—were evaluated with adaptive class weighting and geometric augmentation to enhance minority-class representation. The results indicate that ResNet50V2 with pretrained weights achieved the best performance, reaching a test accuracy of 92.78%, macro precision of 93.13%, macro recall of 92.79%, and a macro F1-score of 92.83%. Adaptive class weighting improved sensitivity toward minority classes, while augmentation contributed to model stability and generalization. These findings demonstrate that combining adaptive weighting and augmentation effectively enhances Batik Keraton motif classification under imbalanced data conditions.

Received December 10, 2025; Accepted Mei 8, 2026; Available online Mei 15, 2026

p-ISSN : 2808-909X e-ISSN : 2798-2505

Keywords: *Batik Keraton, imbalanced dataset, adaptive class weighting, data augmentation, transfer learning, ResNet50V2.*

Abstrak

Penelitian ini bertujuan meningkatkan kinerja klasifikasi motif Batik Keraton pada dataset tidak seimbang melalui integrasi *adaptive class weighting* dan *data augmentation* dalam kerangka *transfer learning*. Dataset terdiri dari 1.799 citra empat kelas (Kawung, Mega Mendung, Parang, Truntum) yang dipraproses menjadi 224×224 piksel dan dibagi secara stratified (80/10/10). Tiga arsitektur *transfer learning* dievaluasi ResNet50V2, VGG16, dan EfficientNetB0 dengan penerapan pembobotan kelas adaptif serta augmentasi geometris untuk meningkatkan representasi kelas minoritas. Hasil menunjukkan bahwa ResNet50V2 dengan bobot pra-latih merupakan arsitektur terbaik, mencapai *test accuracy* 92,78%, *macro precision* 93,13%, *macro recall* 92,79%, dan *macro F1-score* 92,83%. Penerapan *adaptive class weighting* terbukti meningkatkan sensitivitas pada kelas minoritas, sementara augmentasi membantu stabilitas dan generalisasi model. Temuan ini menegaskan bahwa integrasi kedua teknik tersebut dapat meningkatkan performa klasifikasi motif Batik Keraton pada kondisi ketidakseimbangan data.

Kata kunci: Batik Keraton, imbalanced dataset, adaptive class weighting, data augmentation, transfer learning, ResNet50V2.

1. PENDAHULUAN

Motif Batik Keraton merupakan bagian penting dari warisan budaya Indonesia yang memiliki nilai historis dan filosofis tinggi. Namun, proses identifikasi motif hingga saat ini masih banyak dilakukan secara manual sehingga membutuhkan keahlian khusus dan rentan terhadap subjektivitas. Kompleksitas pola, kemiripan visual antar motif, serta variasi tekstur menjadikan klasifikasi citra batik sebagai tantangan signifikan dalam bidang pengolahan citra. Kemajuan teknologi kecerdasan buatan, khususnya deep learning dan transfer learning, telah membuka peluang baru untuk mengotomatisasi proses klasifikasi tersebut secara lebih akurat dan efisien [1], [2], [3]. Meski demikian, terdapat sejumlah hambatan teknis yang memengaruhi performa model, terutama terkait distribusi kelas yang tidak seimbang pada dataset Batik Keraton.

Ketidakseimbangan kelas merupakan salah satu permasalahan utama dalam klasifikasi citra batik karena model cenderung memprioritaskan kelas mayoritas, sehingga sensitivitas terhadap kelas minoritas menurun dan akurasi keseluruhan menjadi kurang representatif [4], [5], [6]. Upaya penanganan ketidakseimbangan seperti oversampling, data augmentation, class weighting, serta focal loss telah banyak dikembangkan, namun teknik-teknik tersebut memerlukan penyesuaian agar tidak menghasilkan sampel yang tidak realistis atau menyebabkan overfitting, khususnya pada dataset motif batik yang memiliki karakteristik pola rumit [7], [8]. Penelitian lain dalam klasifikasi batik dan tekstil tradisional masih menitikberatkan pada penentuan arsitektur CNN atau peningkatan akurasi melalui augmentasi data [9], [10], sementara aspek penanganan ketidakseimbangan data pada konteks motif Batik Keraton belum ditelaah secara menyeluruh.

Secara khusus, performa model CNN terbukti menurun ketika diterapkan pada dataset dengan distribusi kelas tidak seimbang, di mana model cenderung mempelajari pola kelas mayoritas sehingga menghasilkan bias prediksi terhadap kelas minoritas [11], [12]. Kompleksitas motif Batik Keraton serta keberadaan class overlap dan sampel bising turut menurunkan kemampuan generalisasi model [13]. Selain itu, teknik penanganan ketidakseimbangan seperti oversampling, augmentasi dasar, serta class weighting konvensional belum mampu meningkatkan representasi kelas minoritas secara optimal, dan belum terdapat kajian yang secara spesifik menilai efektivitas integrasi adaptive class weighting dengan augmentasi kontekstual dalam klasifikasi motif Batik Keraton [14], [15], [16], [17], [18]. Kondisi ini menunjukkan adanya kebutuhan untuk mengevaluasi kembali pendekatan penanganan ketidakseimbangan yang lebih adaptif, terutama ketika dipadukan dengan arsitektur transfer learning modern.

Dengan demikian, research gap utama terletak pada belum adanya studi yang secara sistematis membandingkan efektivitas adaptive class weighting dan data augmentation kontekstual pada berbagai arsitektur transfer learning dalam klasifikasi motif Batik Keraton. Penelitian terdahulu belum menjelaskan

arsitektur mana di antara ResNet50V2, VGG16, dan EfficientNetB0 yang memberikan performa paling optimal ketika diintegrasikan dengan metode penanganan ketidakseimbangan tersebut. Kekosongan ini penting untuk diisi mengingat karakteristik visual Batik Keraton yang unik dan kompleks memerlukan pendekatan komputasional yang lebih sensitif terhadap variasi antar kelas.

Berdasarkan kondisi tersebut, penelitian ini bertujuan untuk meningkatkan kinerja klasifikasi citra Batik Keraton melalui strategi penanganan ketidakseimbangan data dan pemanfaatan arsitektur transfer learning. Secara khusus, penelitian ini berfokus pada tiga tujuan utama: menganalisis pengaruh penerapan adaptive class weighting terhadap performa model transfer learning, menguji efektivitas kombinasi adaptive class weighting dan data augmentation kontekstual dalam meningkatkan akurasi dan kemampuan generalisasi model, serta membandingkan performa tiga arsitektur transfer learning ResNet50V2, VGG16, dan EfficientNetB0 pada skenario klasifikasi motif Batik Keraton dengan distribusi kelas yang tidak seimbang. Melalui pendekatan ini, penelitian ini diharapkan mampu memberikan kontribusi empiris dalam meningkatkan akurasi klasifikasi motif batik serta mendukung upaya pelestarian budaya melalui otomatisasi berbasis kecerdasan buatan.

2. TINJAUAN PUSTAKA

2.1. Landasan Teori

2.1.1 Teknik Penanganan Imbalanced Dataset

Ketidakseimbangan kelas dapat menyebabkan bias prediksi dan penurunan sensitivitas kelas minoritas [19]. Pendekatan seperti *resampling*, *class weighting*, dan augmentasi sintetis banyak diterapkan. Adaptive class weighting efektif untuk data bertekstur [12], sedangkan augmentasi kontekstual meningkatkan generalisasi [20], [21]. Belum banyak penelitian yang menerapkan teknik ini pada motif batik.

2.1.2. Transfer Learning untuk Tekstil dan Batik

Transfer learning memungkinkan pemanfaatan fitur pretrained yang kuat untuk pola tekstur kompleks [18], [22]. Pada klasifikasi batik, model seperti ResNet, VGG, EfficientNet, dan MobileNet terbukti efektif [9], [23]. Namun, sebagian besar studi belum mengintegrasikan teknik penyeimbangan kelas.

2.1.3. Evaluasi pada Dataset Tidak Seimbang

Akurasi saja tidak memadai untuk mengevaluasi distribusi kelas tidak seimbang . Metrik seperti *precision*, *recall*, *F1-score*, dan confusion matrix memberikan penilaian yang lebih representatif [24].

2.2. Penelitian Terdahulu

Penelitian mengenai klasifikasi tekstil dan batik menunjukkan bahwa model pra-latih mampu mengekstraksi pola visual bertekstur secara efektif. ResNet50 dan VGG16 terbukti akurat melalui fine-tuning [23], sedangkan EfficientNet dan MobileNetV2 menawarkan performa tinggi dengan kompleksitas rendah [9]. Augmentasi turut membantu menghadapi variasi pencahayaan dan orientasi [7], sementara transfer learning relevan untuk deteksi tekstur dan cacat visual [10]. Pendekatan berbasis fitur tekstur–warna juga meningkatkan akurasi [25]. Namun, sebagian besar penelitian tersebut belum mengintegrasikan teknik penyeimbangan kelas.

Dalam konteks imbalanced dataset, teknik oversampling, class weighting, cost-sensitive learning, dan hybrid resampling terbukti meningkatkan sensitivitas kelas minoritas [8], [26]. Kombinasi pembobotan kelas dan data sintetis mampu meningkatkan generalisasi [21]. Metode adaptif seperti dynamic loss reweighting [27] dan class-balanced loss berbasis effective number of samples [28] menawarkan pendekatan matematis yang lebih stabil, namun kebanyakan diterapkan pada domain medis atau objek umum, bukan motif batik.

Integrasi antara transfer learning dan penanganan ketidakseimbangan kelas masih jarang dilakukan. Pembobotan kelas adaptif dilaporkan meningkatkan stabilitas model pra-latih [25], [27], tetapi penelitian pada batik umumnya masih mengandalkan augmentasi dasar. Belum ada studi yang mengombinasikan adaptive class weighting, augmentasi kontekstual, dan evaluasi multi-metrik secara terpadu pada motif Batik Keraton sehingga menjadi celah penelitian yang ditangani pada studi ini.

3. METODOLOGI PENELITIAN

3.1. Desain Penelitian

Penelitian ini menggunakan pendekatan eksperimental kuantitatif dengan rancangan komparatif untuk mengevaluasi kinerja beberapa arsitektur *transfer learning* dalam klasifikasi citra Batik Keraton yang

p-ISSN : 2808-909X e-ISSN : 2798-2505

memiliki karakteristik *imbalanced dataset*. Desain penelitian disusun secara sistematis untuk memastikan reproduksibilitas, validitas eksperimen, dan interpretabilitas hasil.

3.2. Tahap 1 Data Collection

Dataset Batik Keraton dari Kaggle berisi 1.799 citra dalam empat kelas: Kawung (506), Mega Mendung (472), Parang (426), dan Truntum (395). Distribusi kelas menunjukkan ketidakseimbangan ringan (rasio 1.28:1) namun tetap berpotensi memengaruhi performa model. Citra memiliki variasi pencahayaan dan komposisi yang realistis sehingga mendukung generalisasi. Tahap ini mencakup akuisisi dataset, identifikasi struktur kelas, dan pemeriksaan awal distribusi data tanpa modifikasi citra. Dataset kemudian dipersiapkan untuk tahap preprocessing.

3.3. Tahap 2. Preprocessing

Dataset dibagi menggunakan stratified split menjadi 80% train (1.439 citra), 10% validation (180), dan 10% test (180), dengan random_state=42 untuk menjaga reproducibility. Seluruh citra diresize ke 224×224 piksel, dinormalisasi (rescale=1/255), dan label diubah menjadi one-hot encoding melalui ImageDataGenerator. Batch size 32 digunakan secara konsisten. Seluruh parameter dicatat untuk memastikan konsistensi eksperimen.

3.4. Tahap 3. Data Augmentation

Augmentasi dilakukan on-the-fly menggunakan ImageDataGenerator untuk meningkatkan generalisasi dan mengurangi overfitting. Transformasi yang digunakan meliputi rotasi 45°, shift 0.2, shear 0.2, zoom 0.2, serta horizontal/vertical flip. Transformasi dipilih karena tetap mempertahankan struktur pola batik yang simetris dan berulang, sehingga memperkaya variasi visual tanpa merusak karakteristik motif.

3.5. Tahap 4. Adaptive Class Weighting

Ketidakseimbangan kelas diatasi dengan adaptive class weighting menggunakan formula:

$$w_i = \frac{N}{K \cdot n_i} \qquad (1)$$

Bobot dihitung otomatis melalui compute_class_weight('balanced'), menghasilkan: Kawung 0.888, Mega Mendung 0.954, Parang 1.055, Truntum 1.138. Bobot diterapkan hanya pada tahap pelatihan melalui parameter class_weight untuk menyeimbangkan kontribusi tiap kelas tanpa mempengaruhi evaluasi validasi dan pengujian. Pendekatan ini meningkatkan sensitivitas model terhadap kelas minoritas.

3.6. Tahap 5. Model Implementation (Transfer Learning)

Tiga arsitektur pretrained digunakan: ResNet50V2, VGG16, dan EfficientNetB0. Seluruh base model dibekukan (fully frozen) dan ditambahkan classification head berupa GlobalAveragePooling2D, Dense 256-ReLU, Dropout 0.5, dan Dense Softmax empat kelas. Model dilatih menggunakan Adam (lr=1e-4), batch size 32, 50 epoch, dengan EarlyStopping dan ReduceLROnPlateau. Loss function menggunakan categorical crossentropy dikombinasikan dengan class_weight untuk mengatasi ketidakseimbangan data.

3.7. Evalaluation

Evaluasi dilakukan menggunakan metrik yang sesuai untuk dataset tidak seimbang:

a. Accuracy, gambaran umum performa.
b. Precision (Macro), rata-rata presisi tiap kelas.
c. Recall (Macro), mengukur kemampuan menangkap seluruh sampel tiap kelas.
d. F1-score (Macro), harmonisasi precision–recall.
e. Confusion Matrix, melihat pola misklasifikasi.

Macro averaging digunakan agar setiap kelas memiliki bobot evaluasi yang sama. Kurva training–validation digunakan untuk memantau konvergensi dan mendeteksi overfitting. Eksperimen dijalankan dengan satu seed (single-run), namun penelitian lanjutan disarankan melakukan multi-run untuk memperoleh estimasi performa yang lebih robust.

4. HASIL DAN PEMBAHASAN

4.1 Hasil

Perbandingan performa antar model dilakukan untuk menilai efektivitas masing-masing arsitektur CNN berbasis transfer learning dalam mengklasifikasikan citra motif Batik Keraton. Evaluasi ini mencakup metrik utama berupa *loss*, *accuracy*, *precision*, *recall*, dan *F1-score* yang diperoleh dari data uji. Pada Tabel 1 menyajikan performa empat skenario model transfer learning berdasarkan metrik test loss, akurasi, macro precision, macro recall, dan macro F1-score. Model ResNet50V2 dengan pretrained weights menunjukkan performa terbaik, diikuti variasinya tanpa pretrained weights, sementara VGG16 menempati urutan berikutnya dan EfficientNetB0 memperoleh hasil terendah.

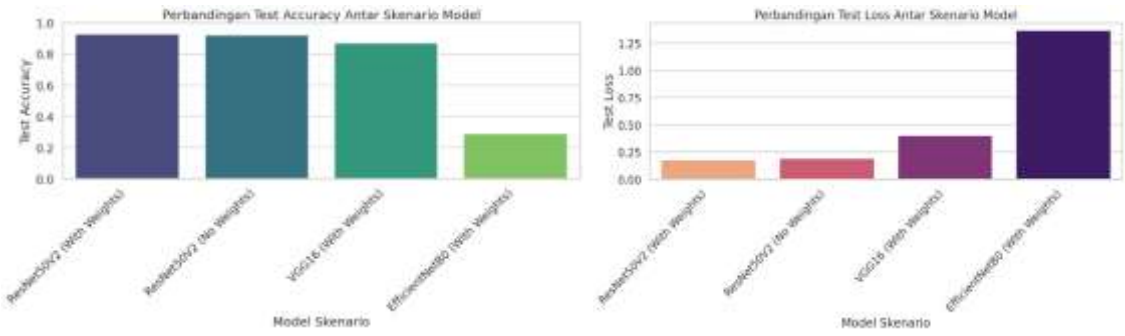
p-ISSN : 2808-909X e-ISSN : 2798-2505

Tabel 1. Perbandingan metrik evaluasi pada data uji (n_test=180)

Model Skenario	Test Loss	Test Accuracy	Macro Precision	Macro Recall	Macro F1-Score
ResNet50V2 (With Weights)	0.1761	0.9278	0.9313	0.9279	0.9283
ResNet50V2 (No Weights)	0.1897	0.9222	0.9239	0.9228	0.9221
VGG16 (With Weights)	0.3976	0.8722	0.8758	0.8679	0.8687
EfficientNetB0 (With Weights)	1.3651	0.2889	0.1976	0.2706	0.2162

Berdasarkan hasil pada Tabel 1, model ResNet50V2 dengan pretrained weights menunjukkan performa paling unggul dengan akurasi 92,78% serta nilai precision, recall, dan F1-score yang konsisten tinggi pada seluruh kelas. Penggunaan bobot pra-latih mempercepat konvergensi dan meningkatkan kemampuan representasi fitur spasial, sehingga model mampu menggeneralisasi variasi motif batik yang kompleks. ResNet50V2 tanpa pretrained weights tetap menunjukkan performa kompetitif (92,22%), meskipun memerlukan lebih banyak epoch untuk mencapai kestabilan. Model VGG16 dengan pretrained weights menghasilkan akurasi 87,22%, masih cukup baik namun menunjukkan kecenderungan overfitting pada fase akhir pelatihan. Hal ini mengindikasikan bahwa arsitektur konvolusional klasik seperti VGG16 kurang optimal dalam menangani keragaman pola dan gradasi visual Batik Keraton. Sebaliknya, EfficientNetB0 mencatat performa paling rendah dengan akurasi 28,89% dan test loss tertinggi (1,3651). Hasil ini menunjukkan bahwa arsitektur ini tidak mampu menangkap detail tekstur dan orientasi pola batik secara memadai. Kompleksitas model yang lebih rendah serta sensitivitas terhadap ukuran input menjadi faktor utama ketidaksesuaian arsitektur ini dengan karakter motif Batik Keraton yang kaya detail.

Untuk memperjelas perbandingan performa antar model, Gambar 1. menampilkan visualisasi perbandingan akurasi dan loss pada setiap arsitektur CNN berbasis transfer learning.



Gambar 1. Perbandingan Visual Akurasi dan Loss Antar Model

Dari Gambar 1. terlihat bahwa model ResNet50V2, baik dengan maupun tanpa pretrained weights, menunjukkan pola konvergensi yang lebih stabil dengan nilai loss yang rendah dan akurasi tinggi dibandingkan VGG16 maupun EfficientNetB0. Tren ini mengonfirmasi kemampuan ResNet dalam mempertahankan kestabilan pelatihan berkat mekanisme residual connection yang efektif mengurangi permasalahan vanishing gradient. Selain itu, visualisasi perbandingan performa berdasarkan nilai macro F1-

p-ISSN : 2808-909X e-ISSN : 2798-2505

score ditampilkan pada Gambar 2, yang menunjukkan dominasi ResNet50V2 dalam menghasilkan keseimbangan performa antar kelas.



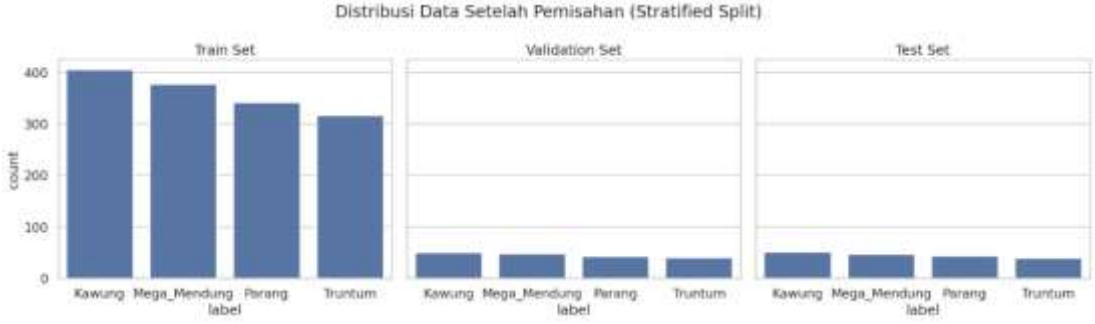
Gambar 2. Perbandingan Nilai Macro F1-Score Antar Model

Dari Gambar 2. dapat diamati bahwa ResNet50V2 dengan pretrained weights menempati posisi tertinggi pada nilai macro F1-score, diikuti oleh ResNet50V2 tanpa pretrained weights dan VGG16, sedangkan EfficientNetB0 tertinggal cukup jauh. Hasil ini memperkuat temuan bahwa ResNet50V2 memiliki kemampuan terbaik dalam mempertahankan keseimbangan performa klasifikasi di antara semua kelas motif. Secara keseluruhan, hasil eksperimen ini menunjukkan bahwa ResNet50V2 dengan pretrained weights merupakan konfigurasi paling optimal untuk tugas klasifikasi motif Batik Keraton. Model ini tidak hanya mencapai nilai evaluasi tertinggi pada seluruh metrik, tetapi juga menampilkan kestabilan konvergensi, ketahanan terhadap overfitting, serta generalisasi yang baik terhadap data validasi maupun data uji.

4.2 Pembahasan

Bagian ini membahas hasil proses pengolahan data dan eksperimen yang dilakukan untuk membangun model klasifikasi motif Batik Keraton menggunakan arsitektur CNN berbasis transfer learning. Seluruh tahapan yang dipaparkan berfokus pada bagaimana preprocessing, penanganan ketidakseimbangan kelas, serta strategi augmentasi data berkontribusi terhadap kualitas data masukan dan kinerja model. Pembahasan ini juga menelaah konsistensi, kelayakan, serta dampak dari setiap langkah terhadap kemampuan model dalam mengenali pola visual motif batik secara lebih baik.

Seluruh citra pada dataset berhasil diseragamkan ke ukuran 224 × 224 piksel dan dikonversi ke mode warna RGB. Nilai piksel dinormalisasi ke dalam rentang 0–1 untuk meningkatkan stabilitas pelatihan model CNN. Dataset kemudian dibagi secara stratified menjadi tiga subset, yaitu 1.439 citra untuk data latih (80%), 180 citra untuk validasi (10%), dan 180 citra untuk data uji (10%). Distribusi data setelah pembagian stratified memperlihatkan keseimbangan antar kelas pada setiap subset seperti yang terlihat pada Gambar 3.



Gambar 3. Distribusi data setelah pembagian (Stratified Split)

Proses penyeragaman ukuran citra tidak mengubah struktur pola motif batik. Contoh hasil penyeragaman ukuran citra dapat dilihat pada Gambar 4.

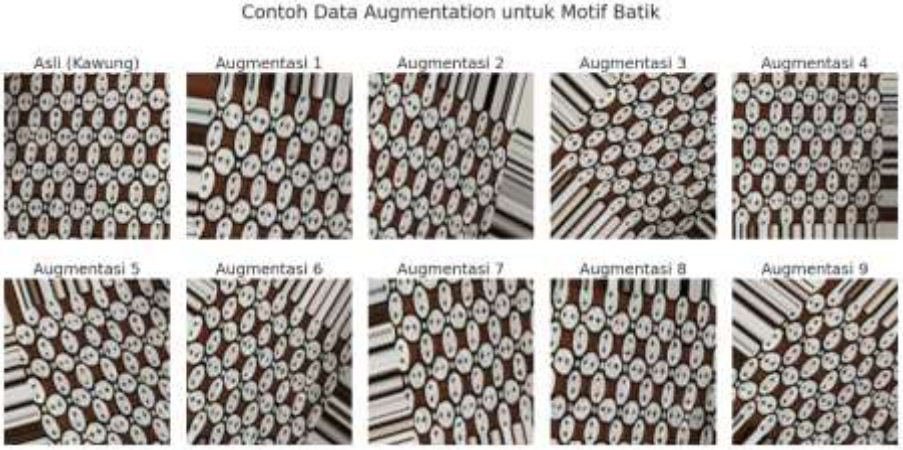
p-ISSN : 2808-909X e-ISSN : 2798-2505



Gambar 4. hasil praprocessing citra (resize 224×224)

Secara keseluruhan, hasil *preprocessing* menunjukkan bahwa dataset telah berada dalam format yang seragam, seimbang, dan siap digunakan untuk pelatihan model CNN. Proses ini memastikan konsistensi data sekaligus menjaga integritas visual motif Batik Keraton yang menjadi objek penelitian.

Hasil penerapan data augmentation memperlihatkan bahwa teknik augmentasi berhasil meningkatkan keragaman data pelatihan. Augmentasi yang diterapkan meliputi rotasi hingga 30°, pergeseran lebar dan tinggi sebesar 0,1, shear range sebesar 0,2, zoom range sebesar 0,2, serta flipping horizontal dan vertikal. Hasil augmentasi menunjukkan variasi orientasi dan pencahayaan tanpa mengubah karakteristik utama motif. Contoh hasil augmentasi ditampilkan pada Gambar 5.



Gambar 5. hasil data augmentation pada citra motif Batik Kawung

Dari Gambar 5. dapat dilihat bahwa hasil augmentasi berhasil menghasilkan variasi baru tanpa mengubah karakteristik utama pola batik. Rotasi dan flipping menambah variasi orientasi, sementara perubahan kecerahan meniru kondisi pencahayaan yang berbeda. Secara keseluruhan, strategi augmentasi ini memperkaya data pelatihan dan meningkatkan kemampuan generalisasi model.

Secara keseluruhan, pembahasan ini menegaskan bahwa keberhasilan klasifikasi motif Batik Keraton dipengaruhi oleh kombinasi berbagai faktor, terutama pemilihan arsitektur transfer learning yang sesuai, konsistensi preprocessing, strategi augmentasi yang memperluas keragaman visual, dan mekanisme penyeimbangan kelas yang mendukung performa pada kelas minor. Model terbaik—ResNet50V2 pretrained—mencapai akurasi 92,78% dan menunjukkan bahwa pendekatan ini sangat potensial untuk dikembangkan lebih lanjut sebagai sistem klasifikasi motif batik otomatis, baik untuk tujuan konservasi budaya maupun aplikasi industri.

5. KESIMPULAN DAN SARAN

5.1. Kesimpulan

Berdasarkan rangkaian eksperimen dan analisis yang dilakukan, penelitian ini menghasilkan beberapa kesimpulan utama yang secara langsung menjawab tujuan penelitian:

a. ResNet50V2 merupakan arsitektur paling optimal untuk klasifikasi motif Batik Keraton. Model ini mampu mengekstraksi pola tekstur yang kompleks secara lebih stabil dibandingkan VGG16 dan EfficientNetB0, sehingga menghasilkan performa keseluruhan yang paling konsisten.

p-ISSN : 2808-909X e-ISSN : 2798-2505

b. Adaptive class weighting terbukti efektif dalam mengurangi bias terhadap kelas mayoritas. Mekanisme pembobotan ini meningkatkan sensitivitas model terhadap kelas minoritas dan membantu pembentukan decision boundary yang lebih seimbang.
c. Kombinasi adaptive class weighting dan data augmentation kontekstual memberikan kontribusi penting dalam meningkatkan kemampuan generalisasi model. Augmentasi yang sesuai dengan karakteristik visual batik membantu memperluas variasi intra-kelas dan menstabilkan proses pelatihan.
d. Arsitektur lain seperti VGG16 dan EfficientNetB0 belum menunjukkan performa optimal pada dataset ini. VGG16 cenderung mengalami overfitting, sementara EfficientNetB0 kurang mampu menyesuaikan diri dengan kompleksitas tekstur batik.

Kesimpulan ini menegaskan bahwa integrasi strategi adaptif berbasis pembobotan kelas dan augmentasi bergaya tekstur, dipadukan dengan arsitektur residual, merupakan pendekatan yang menjanjikan untuk meningkatkan performa klasifikasi motif Batik Keraton pada dataset yang tidak seimbang.

5.2. Saran

Berdasarkan hasil penelitian serta keterbatasan yang telah diidentifikasi, beberapa saran dapat diberikan untuk pengembangan penelitian selanjutnya. Dari sisi akademis, disarankan untuk melakukan uji robustitas menggunakan k-fold cross-validation sehingga performa model dapat dievaluasi secara lebih stabil dan tidak hanya bergantung pada satu pembagian data. Selain itu, teknik loss reweighting yang lebih adaptif, seperti focal loss atau class-balanced loss, dapat dieksplorasi untuk memperkuat fokus model pada kelas minoritas. Penggunaan augmentasi sintetis berbasis GAN, misalnya StyleGAN atau CycleGAN, juga dapat diterapkan guna memperkaya variasi visual kelas minoritas secara lebih realistis. Selanjutnya, membandingkan performa model dengan arsitektur yang lebih mutakhir, seperti EfficientNetV2 atau Vision Transformer (ViT), akan membantu mengevaluasi potensi peningkatan representasi fitur.

Dari sisi aplikatif, penelitian selanjutnya dapat menguji model pada dataset batik dari daerah berbeda untuk menilai sejauh mana kemampuan generalisasi model terhadap motif di luar Batik Keraton. Selain itu, pengembangan prototipe aplikasi, misalnya katalog batik digital atau sistem identifikasi motif, perlu mempertimbangkan aspek kebutuhan komputasi, latency, dan optimisasi model. Terakhir, penambahan modul interpretabilitas seperti Grad-CAM akan membantu pengguna memahami pola visual yang menjadi dasar keputusan model, sehingga meningkatkan kepercayaan dalam penggunaan sistem.

DAFTAR PUSTAKA

[1] E. Winarno, A. Solichan, A. P. Ramdani, W. Hadikurniawati, and A. Septiarini, “Enhanced Semarang batik classification using deep learning: a comparative study of CNN architectures,” *Bulletin of Electrical Engineering and Informatics*, vol. 14, no. 5, p. 9347, 2023, doi: 10.11591/eei.v14i5.9347.

[2] D. Sinaga, C. Jatmoko, Suprayogi, and N. Hendriyanto, “Multi-Layer Convolutional Neural Networks for Batik Image Classification,” *Scientific Journal of Informatics*, vol. 11, no. 2, pp. 477–484, 2024, doi: 10.15294/sji.v11i2.3309.

[3] L. Fitriani, D. Tresnawati, and M. B. Sukriyansah, “Image Classification on Garutan Batik Using Convolutional Neural Network with Data Augmentation,” *JUITA: Jurnal Informatika*, vol. 11, no. 1, pp. 107–115, 2023, doi: 10.30595/juita.v11i1.16166.

[4] N. Liu, J. Wang, Y. Zhu, L. Wan, and Q. Li, “Improving imbalance classification via ensemble learning based on two-stage learning,” *Front Comput Neurosci*, vol. 17, p. 1296897, 2024, doi: 10.3389/fncom.2023.1296897.

[5] M.-A. Lavoie and S. Waslander, “Class instance balanced learning for long-tailed classification,” 2023. doi: 10.48550/arXiv.2307.05322.

[6] A. Galdran, G. Carneiro, and M. A. González Ballester, “Balanced-MixUp for highly imbalanced medical image classification,” 2021. doi: 10.48550/arXiv.2109.09850.

[7] F. Wulandari, A. Rahmawati, and L. E. Nugroho, “Enhancing Batik image classification through data augmentation and transfer learning,” *Journal of King Saud University – Computer and Information Sciences*, vol. 35, no. 8, p. 102547, 2023, doi: 10.1016/j.jksuci.2023.102547.

[8] M. Buda, A. Maki, and M. A. Mazurowski, “A systematic study of the class imbalance problem in convolutional neural networks,” *Neural Networks*, vol. 143, pp. 140–150, 2021, doi: 10.1016/j.neunet.2021.06.014.

[9] A. Setiawan, E. Prasetyo, and R. Hidayat, “Automated classification of Indonesian Batik motifs using EfficientNet and MobileNetV2 architectures,” *IEEE Access*, vol. 10, pp. 78901–78912, 2022, doi: 10.1109/ACCESS.2022.3189012.

[10] S. Huang, Z. Li, and H. Zhang, "Transfer learning-based textile defect classification using convolutional neural networks," *Comput Ind*, vol. 132, p. 103516, 2021, doi: 10.1016/j.compind.2021.103516.
[11] D. Dablain, K. N. Jacobson, C. Bellinger, M. Roberts, and N. V Chawla, "Understanding CNN fragility when learning with imbalanced data," *Mach Learn*, vol. 113, pp. 4785–4810, 2024, doi: 10.1007/s10994-023-06326-9.
[12] W. Chen, K. Yang, Z. Yu, Y. Shi, and C. L. P. Chen, "A survey on imbalanced learning: latest research, applications and future directions," *Artif Intell Rev*, vol. 57, p. 137, 2024, doi: 10.1007/s10462-024-10759-6.
[13] M. Carvalho, A. J. Pinho, and S. Brás, "Resampling approaches to handle class imbalance: a review from a data perspective," *J Big Data*, vol. 12, p. Article 71, 2025, doi: 10.1186/s40537-025-01119-4.
[14] C. Zhang, H. Li, and et al., "Multimodal framework for long-tailed recognition," *Applied Sciences*, vol. 14, no. 22, p. 10572, 2024, doi: 10.3390/app142210572.
[15] Y. Xiang and et al., "Enhancing robustness in long-tailed image classification with angular approaches and balanced learning," *Data Sci Eng*, vol. 10, pp. 480–494, 2025, doi: 10.1007/s41019-025-00286-x.
[16] E. Sala and et al., "A data augmentation methodology to reduce the class imbalance in histopathology images," *Journal of Imaging Informatics in Medicine*, vol. 37, pp. 1767–1782, 2024, doi: 10.1007/s10278-024-01018-9.
[17] M. Dorozynski and F. Rottensteiner, "Deep descriptor learning with auxiliary classification loss for retrieving images of silk fabrics in the context of preserving European silk heritage," *ISPRS Int J Geoinf*, vol. 11, no. 2, p. 82, 2022, doi: 10.3390/ijgi11020082.
[18] C. Dionysiou, P. Davnos, and et al., "From contemporary datasets to cultural heritage performance: Explainability and energy profiling of visual models towards textile identification," *Heritage*, vol. 8, no. 11, p. 447, 2024.
[19] I. Radosavovic, J. Johnson, S. Xie, and P. Dollár, "Design of Experiments for Deep Learning: Benchmarking and Analysis," *IEEE Trans Pattern Anal Mach Intell*, vol. 45, no. 2, pp. 1600–1615, 2022, doi: 10.1109/TPAMI.2022.3178449.
[20] A. Pala, A. Oleynik, I. Utseth, and N. O. Handegard, "Addressing class imbalance in deep learning for acoustic target classification," *ICES Journal of Marine Science*, 2023, doi: https://doi.org/10.1093/icesjms/fsad165.
[21] R. Walsh and M. Tardy, "A comparison of techniques for class imbalance in deep learning classification of breast cancer," *Diagnostics*, vol. 13, no. 1, p. 67, 2022, doi: https://doi.org/10.3390/diagnostics13010067.
[22] E. Çınar, "Comparative analysis of deep learning-based feature extraction and traditional classification approaches for tomato disease detection," *Agronomy*, vol. 15, no. 7, p. 1509, 2024, doi: https://doi.org/10.3390/agronomy15071509.
[23] D. Yuliani, A. Widodo, and A. Hidayanto, "Batik motif classification using transfer learning with ResNet50 and VGG16 models," *Applied Sciences*, vol. 13, no. 4, p. 2761, 2023, doi: 10.3390/app13042761.
[24] A. Tharwat, "Classification assessment methods applied on machine learning algorithms for medical diagnosis," *Comput Biol Med*, vol. 132, p. 104287, 2021, doi: 10.1016/j.compbiomed.2021.104287.
[25] T. H. Nguyen, D. H. Pham, and Q. H. Tran, "Deep transfer learning for textile fabric pattern classification based on multi-feature fusion," *J Imaging*, vol. 10, no. 3, p. 45, 2024, doi: 10.3390/jimaging10030045.
[26] J. M. Johnson and T. M. Khoshgoftaar, "Survey on deep learning with class imbalance," *J Big Data*, vol. 9, no. 1, p. 3, 2022, doi: 10.1186/s40537-021-00537-3.
[27] S. Wang, H. Xu, H. Liu, and X. Wang, "Adaptive loss reweighting and data augmentation for imbalanced image classification," *IEEE Access*, vol. 11, pp. 49213–49225, 2023, doi: 10.1109/ACCESS.2023.3268129.
[28] Y. Cui, M. Jia, T.-Y. Lin, Y. Song, and S. Belongie, "Class-balanced loss based on effective number of samples," *IEEE Trans Pattern Anal Mach Intell*, vol. 43, no. 6, pp. 2199–2212, 2021, doi: 10.1109/TPAMI.2020.3018749.