

Rancangan Pengembangan Dataset Motif Sutra Bugis Untuk Klasifikasi Efficientnet-B0 Berbasis Explainable AI

Imran Djafar*, Suryani, Faizal, Marsa, Asrul Syam, Arham Arifin

Universitas Dipa Makassar, Jln. Perintis Kemerdekaan KM 9 Kota Makassar

e-mail: *¹imrandjafar@undipa.ac.id, ²suryani187@undipa.ac.id, ³f41241@undipa.ac.id,

⁴marshaarie@undipa.ac.id, ⁵asrulsyam12@undipa.ac.id, ⁶arhamarifin@undipa.ac.id

Abstrak

Kajian ini menyusun kerangka pembangunan korpus citra motif sutra Bugis yang terkendali, dapat ditelusuri, dan memperhatikan izin pemanfaatan data. Lima kategori yang direncanakan ialah Balo Tettong, Balo Makkalu, Balo Renni', Balo Cobo', dan Balo Bombang. Akuisisi ditargetkan menghasilkan 2.000 foto dari 200 kain, dengan komposisi 40 kain dan 400 foto untuk setiap kategori. Setiap rekaman akan dilengkapi fabric_id beserta informasi proses pemotretan. Dua orang ahli menilai label secara terpisah; perkara yang belum mencapai kesepakatan diteruskan kepada penilai ketiga. Pengujian dirancang melalui stratified group five-fold cross-validation dengan fabric_id sebagai kelompok, sehingga foto-foto dari kain yang sama tidak berpindah fold. EfficientNet-B0 menjadi model utama dan dibandingkan dengan CNN sederhana, MobileNetV3, serta ResNet50. F1-makro dipakai sebagai ukuran pokok, sementara interval kepercayaan dan metrik tiap kelas menjadi analisis pendukung. Penjelasan Grad-CAM dibuat untuk semua model dan ditelaah ahli berdasarkan ciri visual motif. Naskah ini berfokus pada desain prosedur; hasil numerik hanya dapat disampaikan sesudah pengumpulan data dan seluruh rangkaian eksperimen benar-benar selesai.

Kata kunci: Dataset Budaya, Efficientnet-B0, Explainable AI, Motif Sutra Bugis, Grad-CAM.

Abstract

This work defines a controlled and traceable protocol for constructing an image corpus of Bugis silk motifs while accounting for data-use permissions. The planned corpus covers Balo Tettong, Balo Makkalu, Balo Renni', Balo Cobo', and Balo Bombang. A total of 2,000 photographs will be acquired from 200 fabrics, with 40 fabrics and 400 photographs assigned to each category. Every image will be linked to a fabric_id and its acquisition record. Two experts will annotate each fabric independently, and a third expert will resolve cases that remain disputed. Model assessment is organized as stratified group five-fold cross-validation, treating fabric_id as the grouping variable so that views of the same fabric cannot enter different folds. EfficientNet-B0 is the principal classifier and will be evaluated against a simple CNN, MobileNetV3, and ResNet50. Macro F1 is the primary measure, complemented by confidence intervals and class-wise metrics. Grad-CAM explanations will be generated for every model and reviewed by experts against the visual definition of each motif. The present article reports the methodological design rather than numerical findings; such findings require completion of data acquisition and the full experimental study.

Keywords: Bugis Silk Motifs, Cultural Dataset, Efficientnet-B0, Explainable AI, Grad-CAM.

1. PENDAHULUAN

Lipa' sabbe tidak hanya berfungsi sebagai kain tradisional, tetapi juga merekam pengetahuan visual dan sosial masyarakat Bugis di Sulawesi Selatan, terutama di Wajo. Susunan geometris, warna, serta pemakaian motif diwariskan melalui praktik menenun lintas generasi. Literatur menyebut beberapa pola, antara lain Balo Tettong, Balo Makkalu, Balo Renni, Cobo, dan Bombang [1]. Aktivitas produksi sutra tersebut sekaligus menopang kegiatan ekonomi keluarga dan pengrajin di Kabupaten Wajo [1], [2]. Ketika selera konsumen berkembang dan ragam motif baru bermunculan, kebutuhan untuk mencatat bentuk visual beserta istilah lokalnya menjadi semakin mendesak [3].

Informasi mengenai motif saat ini umumnya tersebar dalam katalog, tulisan kebudayaan, dan dokumentasi koleksi pribadi. Sumber-sumber itu penting bagi pelestarian, namun belum tentu memiliki label, struktur berkas, dan metadata yang memadai untuk pembelajaran mesin. Mengambil gambar langsung dari internet juga berisiko karena asal-usul, hak pakai, kualitas resolusi, duplikasi, dan ketepatan labelnya

sering tidak pasti. Tanpa kurasi, pengklasifikasi dapat lebih banyak merespons watermark, latar penjualan, atau kebiasaan pemotretan daripada mempelajari pola tenun yang menjadi objek penelitian.

Teknologi computer vision memberi kemungkinan untuk mengarsipkan dan mengenali tekstil secara komputasional. Pengembangan Batik Nitik 960 memperlihatkan bahwa pemotretan terkendali, penentuan area motif, pelabelan, dan keseimbangan kelas perlu dirancang sebagai satu alur pengelolaan data [4]. Kurasi pada dataset tenun Sikka juga menunjukkan manfaat verifikasi kelas dan keberagaman kondisi visual bagi dokumentasi warisan tekstil [5]. Di bidang terkait, deep learning telah dimanfaatkan untuk membedakan motif batik [6], melakukan pencarian citra tekstil [7], serta memeriksa keaslian tenun tangan [8]. Pengalaman tersebut menegaskan bahwa kemampuan representasi mendalam tidak dapat dipisahkan dari kualitas koleksi dan ketepatan rancangan evaluasinya.

CNN membangun representasi bertingkat dari pola sederhana, seperti tepi dan tekstur, menuju bentuk yang lebih abstrak. Meskipun demikian, jaringan yang besar berpotensi boros komputasi dan mengalami overfitting ketika data yang tersedia sedikit. EfficientNet menggunakan compound scaling untuk mengatur resolusi, lebar, dan kedalaman jaringan secara bersamaan [9]. Varian B0 dipilih karena relatif ringan dan layak dijadikan dasar transfer learning pada koleksi baru. ResNet50 disertakan untuk mewakili arsitektur dengan residual connection [10], sedangkan MobileNetV3 menjadi pembandingan yang berorientasi pada efisiensi perangkat bergerak [11].


Nilai klasifikasi yang tinggi tidak dengan sendirinya membuktikan bahwa jaringan menggunakan bagian motif yang benar. Keputusan model mungkin terbentuk dari petunjuk yang tidak relevan, misalnya warna dominan, pinggiran meja, tulisan produk, atau latar foto. Grad-CAM memanfaatkan gradien untuk memperlihatkan area yang paling berpengaruh terhadap skor suatu kelas [12]. Dalam konteks budaya, peta tersebut digunakan sebagai bahan audit oleh pengrajin atau ahli motif: mereka memeriksa apakah sorotan model bertepatan dengan unsur visual yang lazim dikenali manusia. Peta Grad-CAM tetap merupakan penjelasan korelasional, bukan bukti sebab-akibat ataupun dasar penafsiran makna budaya.

Akuisisi multiview menimbulkan risiko evaluasi yang berbeda. Satu kain dapat menghasilkan sejumlah foto dari arah dan kondisi yang bervariasi. Apabila foto dari kain tersebut tersebar secara acak antara pelatihan dan pengujian, model mungkin hanya mengingat karakter kain yang sudah dilihat dan menghasilkan nilai yang terlalu tinggi. Kemiripan atau pengulangan contoh antara kedua bagian data merupakan bentuk kebocoran visual yang melemahkan keabsahan pengujian [13]. Karena itu, *fabric_id* dipakai sebagai kunci pengelompokan dan seluruh tampilan dari satu kain wajib mengikuti kelompok data yang sama.

Uraian tersebut menunjukkan celah berupa belum adanya protokol terpadu untuk membangun dataset motif sutra Bugis yang tervalidasi, memiliki metadata, dan dievaluasi tanpa kebocoran antarkain. Penelitian ini merumuskan empat sasaran: (1) menetapkan alur pembangunan dataset untuk lima motif; (2) menyiapkan perbandingan CNN sederhana, MobileNetV3, ResNet50, dan EfficientNet-B0; (3) merancang pengujian stratified group five-fold cross-validation beserta analisis statistiknya; serta (4) menyusun pemeriksaan Grad-CAM yang melibatkan ahli untuk setiap arsitektur. Nilai kebaruan yang ditawarkan berada pada penggunaan identitas kain sebagai unit evaluasi, tata kelola tolok ukur, dan prosedur interpretabilitas yang dapat diulang oleh peneliti lain.

2. METODOLOGI PENELITIAN

Studi ini dirancang sebagai penyusunan prosedur dataset dan eksperimen klasifikasi, bukan sebagai laporan hasil pelatihan yang telah selesai. Satu kain fisik diperlakukan sebagai unit bebas, sedangkan beberapa foto multiview dari kain itu merupakan pengamatan yang saling berkaitan. Pemisahan konsep tersebut mencegah banyaknya berkas foto dianggap sebagai banyaknya objek independen. Alur kerja meliputi perumusan kelas, pengambilan gambar, perekaman metadata, verifikasi label, kurasi mutu, pembentukan fold berdasarkan kelompok, transformasi citra, pelatihan, pengujian statistik, dan penelaahan Grad-CAM. Urutan kegiatan diringkas pada Gambar 1. Karena implementasi belum dilakukan, bagian ini tidak menyatakan capaian kinerja model.



Gambar 1. Alur penyusunan dataset dan evaluasi pengenalan motif sutra Bugis

2.1. Penetapan Kelas dan Validasi Ahli

Taksonomi kerja terdiri atas Balo Tettong, Balo Makkalu, Balo Rennin', Balo Cobo', dan Balo


Bombang, yang dirumuskan dari pustaka mengenai motif sutra tradisional Sulawesi Selatan [1], [3]. Nama-nama itu belum langsung diperlakukan sebagai label final. Sedikitnya dua orang yang memahami tenun Bugis akan menelaahnya terlebih dahulu. Setiap kelas dijabarkan melalui sebutan lokal dan variasi ejaan, geometri utama, arah garis, susunan bidang, contoh yang sesuai, serta bentuk lain yang berpotensi menimbulkan kekeliruan.

Dua validator memberikan label secara terpisah pada setiap kain. Ketika pilihan mereka tidak sama, kasus tersebut dikaji ulang dengan merujuk pada definisi kelas hingga diperoleh persetujuan bersama. Sengketa yang masih tersisa diputuskan oleh validator ketiga sebagai adjudikator dan dasar keputusannya didokumentasikan. Persentase agreement dan Cohen's kappa dihitung dari penilaian awal sebelum adjudikasi. Kain bermotif campuran atau yang identitas kelasnya belum meyakinkan dipindahkan ke kelompok karantina dan tidak ikut dalam benchmark utama.

Tabel 1. Rumusan operasional lima kelas motif sutra Bugis

Kelas motif	Ciri visual operasional
Balo Tettong	Garis vertikal atau tegak yang tersusun berulang.
Balo Makkalu	Garis horizontal atau melintang yang tersusun berulang.
Balo Renni'	Pola kotak-kotak kecil yang tersusun rapat dan berulang.
Balo Cobo'	Deretan segitiga tinggi dan ramping yang menyerupai bentuk atap rumah Bugis.
Balo Bombang	Deretan segitiga atau garis zig-zag yang saling tersambung dan melambangkan ombak.

Sumber: Ciri operasional dirumuskan dengan mengacu pada uraian motif Sadapotto et al. [3].



Gambar 2. Representasi skematis ciri visual lima motif berdasarkan sumber pustaka [3].

2.2. Akuisisi Citra dan Metadata

Rencana akuisisi menetapkan 40 kain yang berbeda untuk masing-masing kelas. Setiap kain direkam sebanyak 10 kali, sehingga keseluruhan target berjumlah 2.000 citra dari 200 kain. Keanekaragaman pengamatan dibentuk melalui perbedaan jarak, arah kain, sudut pengambilan, cahaya, dan cara kain dibentangkan. Filter artistik serta peningkatan warna otomatis yang agresif tidak digunakan. Pada setiap sesi, satu foto boleh menyertakan kartu warna atau bidang abu-abu untuk memeriksa konsistensi, tetapi penanda tersebut harus berada di luar citra yang masuk ke model.

Sebuah kode fabric_id yang tidak berulang diberikan kepada setiap kain. Catatan pendamping sedikitnya berisi image_id, fabric_id, kelas, tempat dan waktu pemotretan, perangkat, jarak, arah kamera, pencahayaan, kondisi bahan, asal koleksi, hasil validasi, serta cakupan izin. Data identitas pemilik disimpan pada arsip terpisah dan tidak dimasukkan ke publikasi. Pemilik dapat memilih izin terbatas untuk kegiatan internal, izin penayangan contoh pada artikel, atau izin pelepasan citra sebagai dataset terbuka. Berkas dengan pembatasan hanya diproses di lingkungan penelitian.

Tabel 2. Sasaran dan ketentuan akuisisi dataset

Parameter	Target utama	Ketentuan
Jumlah kelas	5 motif	Divalidasi ahli
Kain fisik per kelas	40	fabric_id unik
Foto per kain	10	Citra multiview
Citra asli per kelas	400	Setelah kendali mutu
Total citra asli	2.000	Berasal dari 200 kain
Validator	2 orang	Validator ketiga sebagai adjudikator

2.3. Kendali Mutu dan Kurasi

Proses kurasi memadukan pemeriksaan teknis dan pemeriksaan makna label. Pada tahap teknis,


berkas yang rusak, sangat buram, kekurangan cahaya, identik, atau tidak memperlihatkan motif dengan jelas dikeluarkan. Tahap semantik menilai kesesuaian antara citra, kelas, dan metadata. Perceptual hash digunakan untuk menandai kemiripan yang patut diperiksa, tetapi keputusan akhir tetap dilakukan secara visual. Foto multiview yang memang merekam sudut berbeda dipertahankan; yang dihapus hanyalah salinan akibat penyimpanan atau pengiriman berulang.

Komposisi koleksi dilaporkan dengan dua satuan, yaitu jumlah kain dan jumlah foto. Keduanya tidak boleh dipertukarkan karena sepuluh tampilan dari kain yang sama masih berasal dari satu objek. Pelaporan juga merangkum perangkat, lokasi, dan pencahayaan untuk mendeteksi ketimpangan proses akuisisi. Contohnya, apabila satu kelas selalu berkaitan dengan satu jenis latar, sesi tambahan perlu dilakukan agar konteks pemotretan tidak menjadi penanda kelas.

2.4. Pembagian Dataset Bebas Kebocoran

Pengukuran kinerja utama menggunakan stratified group five-fold cross-validation dengan fabric_id sebagai variabel kelompok. Dua ratus kain dibagi ke lima fold dengan proporsi kelas yang setara. Dalam satu putaran, sekitar 160 kain dari empat fold membentuk data pengembangan, sedangkan 40 kain pada fold yang tersisa menjadi data uji outer. Lima belas persen dari data pengembangan dipilih lagi secara berstratifikasi untuk validasi internal, penentuan hiperparameter, dan early stopping. Seluruh foto yang memiliki fabric_id sama mengikuti fold yang sama. Data uji outer tidak disentuh selama penyesuaian model, kemudian seluruh hasil antarputaran digabungkan sebagai prediksi out-of-fold.

Evaluasi Utama: 5-Fold Stratified Group Cross-Validation



Setiap fabric_id hanya berada pada satu fold; seluruh citra multiview dari kain yang sama selalu mengikuti fold tersebut.

Gambar 3. Skema five-fold cross-validation berstrata dan berkelompok menurut fabric_id


2.5. Prapemrosesan dan Augmentasi

Sebelum pelatihan, orientasi gambar diperiksa melalui informasi EXIF dan ruang warna diseragamkan menjadi RGB. Masukan model berukuran 224×224 piksel. Rasio bentuk motif dijaga dengan center crop atau padding sehingga citra tidak ditarik secara anisotropik. Variasi pada data pelatihan dibuat secara terbatas melalui random resized crop, rotasi hingga $\pm 15^\circ$, horizontal flip yang tidak mengubah kelas, color jitter ringan, perspective transformation kecil, dan random erasing [14].

Transformasi untuk validasi dan pengujian bersifat tetap: resize, crop atau padding, perubahan menjadi tensor, lalu normalisasi. Augmentasi baru dijalankan sesudah fold terbentuk dan hanya berlaku pada data pelatihan. Untuk menilai manfaatnya, studi ablasi membandingkan tiga keadaan, yaitu tanpa augmentasi, augmentasi geometri saja, dan kombinasi perubahan geometri dengan fotometri.

2.6. Arsitektur dan Strategi Pelatihan

EfficientNet-B0 berbobot awal ImageNet ditetapkan sebagai arsitektur utama. Kepala bawaan diganti dengan global average pooling, dropout, dan dense layer softmax yang memiliki lima keluaran. Lima epoch awal hanya melatih kepala klasifikasi karena backbone dibekukan. Setelah itu, beberapa blok terakhir dibuka dan disesuaikan menggunakan learning rate yang lebih rendah. Pemanfaatan transfer learning dimaksudkan untuk mengurangi kebutuhan sampel awal [17], [18], sedangkan mekanisme compound scaling EfficientNet menjaga keseimbangan dimensi jaringan [9]. Rangkaian arsitekturnya diperlihatkan pada Gambar 4.



Gambar 4. Aliran klasifikasi EfficientNet-B0 dan pembentukan peta Grad-CAM.

Tolok ukur melibatkan tiga pembandingan. Model CNN dasar menggunakan tiga rangkaian Conv2D, BatchNorm, ReLU, dan MaxPooling sebelum kepala klasifikasi. MobileNetV3-Large dipilih sebagai jaringan hemat sumber daya [11], sedangkan ResNet50 mewakili keluarga residual [10]. Input, fold, augmentasi, loss, dan aturan penghentian dibuat seragam supaya perbandingan adil. AdamW menjalankan optimasi dengan learning rate awal 1×10^{-3} pada kepala dan 1×10^{-4} pada fase fine-tuning [15], [16]. Keempat jaringan diuji pada susunan kain yang identik di setiap fold.

Tabel 3. Rancangan awal konfigurasi pelatihan

Komponen	Konfigurasi
Ukuran input	224×224 piksel, RGB
Pembagian data	Stratified group five-fold cross-validation berdasarkan fabric_id; validasi internal 15% dari data pengembangan
Model	CNN, MobileNetV3, ResNet50, EfficientNet-B0
Pengoptimal	AdamW
Laju pembelajaran	1×10^{-3} (kepala klasifikasi); 1×10^{-4} (fine-tuning)
Ukuran batch	16 atau disesuaikan dengan memori GPU
Epoch maksimum	50
Penghentian dini	Kesabaran 8 epoch; memantau F1-makro validasi
Fungsi loss	Cross-entropy; bobot kelas bila diperlukan
Replikasi	Lima fold; seed pelatihan didokumentasikan

2.7. Metrik Evaluasi

F1-makro menjadi ukuran utama agar kontribusi setiap motif terhadap evaluasi tetap setara. Akurasi digunakan sebagai gambaran umum proporsi keputusan benar, sedangkan presisi dan recall disajikan untuk tiap kelas berikut rerata makro dan berbobotnya. Confusion matrix dibentuk dari keluaran out-of-fold untuk melihat pasangan motif yang paling sering tertukar. Kebutuhan implementasi dibandingkan melalui kecepatan inferensi, banyaknya parameter, dan ukuran berkas model.

Notasi TP, TN, FP, dan FN masing-masing menyatakan true positive, true negative, false positive, dan false negative. Rumus yang digunakan dituliskan sebagai berikut:

$$\text{Accuracy} = (\text{TP} + \text{TN}) / (\text{TP} + \text{TN} + \text{FP} + \text{FN}) \quad (1)$$

$$\text{Precision} = \text{TP} / (\text{TP} + \text{FP}) \quad (2)$$

$$\text{Recall} = \text{TP} / (\text{TP} + \text{FN}) \quad (3)$$

$$\text{F1-score} = 2 \times (\text{Precision} \times \text{Recall}) / (\text{Precision} + \text{Recall}) \quad (4)$$

Perhitungan multikelas dilakukan secara one-versus-rest untuk memperoleh metrik per kategori. Hasil setiap arsitektur dirangkum menggunakan rerata dan simpangan baku lima fold. Interval kepercayaan 95% diperoleh melalui bootstrap dengan fabric_id sebagai unit resampling, bukan berkas citra. Selisih F1-makro diuji melalui bootstrap berpasangan yang distratifikasi menurut kelas pada prediksi out-of-fold. Koreksi Holm diterapkan ketika beberapa pasangan model dibandingkan. Interpretasi tidak hanya bergantung pada nilai p, tetapi juga pada besar selisih metrik dan rentang interval kepercayaannya.

2.8. Explainable Artificial Intelligence dengan Grad-CAM

Pada Grad-CAM, gradien skor kelas digunakan untuk menimbang feature map dari lapisan konvolusi terakhir [12]. Kombinasi peta berbobot melewati ReLU, kemudian diperbesar ke dimensi citra sumber dan ditampilkan sebagai heatmap transparan. Prosedur yang sama dijalankan pada CNN sederhana, MobileNetV3, ResNet50, dan EfficientNet-B0. Dengan demikian, lokasi perhatian model utama dapat diperiksa terhadap pola perhatian ketiga arsitektur pembandingan.

Audit heatmap terdiri atas pemeriksaan sistem dan penilaian ahli. Sampelnya mencakup keputusan benar dengan keyakinan tinggi, keputusan benar dengan keyakinan rendah, serta kesalahan dari tiap kelas. Pemeriksaan sistem memastikan bahwa aktivasi lebih banyak berada pada kain daripada latar. Dua validator memberikan nilai ordinal 1–4 secara mandiri sesuai kecocokan sorotan dengan ciri motif. Selisih lebih dari satu tingkat dibicarakan kembali; apabila belum selesai, nilai akhir ditetapkan oleh validator ketiga. Weighted Cohen's kappa dihitung dari skor awal, sedangkan ringkasan akhir memakai skor hasil adjudikasi. Interpretasi tetap dibatasi sebagai audit korelasi visual.

2.9. Etika, Hak Penggunaan, dan Rencana Publikasi Dataset

Tata kelola data menempatkan hak pemilik kain, pengrajin, dan pengetahuan lokal sebagai pertimbangan utama. Sebelum kamera digunakan, pemilik menerima informasi tentang sasaran studi, jenis rekaman, kemungkinan publikasi, dan fungsi model. Persetujuan diberikan secara bertingkat untuk pemakaian internal, penayangan contoh pada publikasi, dan penyebaran dataset. Status izin diikat pada fabric_id, sementara informasi pribadi disimpan di luar kumpulan data yang dibagikan.

Dokumen pendamping rilis akan memuat asal dan susunan data, metode akuisisi, prapemrosesan,

kegunaan yang diperbolehkan, pembatasan, lisensi, dan pengelola. Sistem tidak diarahkan untuk menetapkan otentisitas budaya atau harga kain tanpa pendapat ahli. Perangkat komputasi juga tidak menggantikan wewenang pengrajin dan budayawan ketika menjelaskan makna motif. Untuk koleksi dengan pembatasan budaya atau komersial, publikasi dibatasi pada statistik atau metadata agregat.

Perubahan dataset dapat dilacak melalui nomor versi, checksum, dan changelog koreksi label. Bahan replikasi mencakup kode pembentukan fold, seed, konfigurasi pelatihan, serta daftar fabric_id pada setiap fold. Penyediaan informasi itu memungkinkan eksperimen diulang tanpa membuka identitas orang yang memiliki kain.

3. PROTOKOL EVALUASI EMPIRIS DAN LUARAN YANG DIHARAPKAN

3.1. Rencana Komposisi Dataset

Komposisi yang direncanakan terdiri atas 200 kain dan 2.000 foto. Tiap motif diwakili oleh 40 kain atau 400 foto, dan satu kain menyumbangkan 10 tampilan. Dengan five-fold cross-validation, satu fold kira-kira memuat 40 kain—delapan kain untuk setiap motif—atau 400 foto. Setelah kurasi, laporan akhir mencantumkan berapa kain dan citra yang lolos serta alasan pengeluarannya. Tingkat kesepakatan dua ahli sebelum kasus masuk ke adjudikator dilaporkan melalui persentase agreement dan Cohen's kappa.

Tabel 4. Pembagian rencana data pada lima fold evaluasi

Motif	Jumlah kain	Jumlah citra	Kain per fold	Citra per fold	Jumlah fold
Balo Tettong	40	400	8	80	5
Balo Makkalu	40	400	8	80	5
Balo Renni'	40	400	8	80	5
Balo Cobo'	40	400	8	80	5
Balo Bombang	40	400	8	80	5
Total	200	2.000	40	400	5

Keseimbangan jumlah kain dan foto antarkelas merupakan sasaran awal, sedangkan komposisi aktual mengikuti hasil pemotretan dan keputusan validator. fabric_id tetap menjadi dasar pembentukan kelompok, sehingga sepuluh tampilan dari satu kain tidak mungkin muncul pada fold berlainan. Rotasi fold membuat setiap kain berperan satu kali sebagai data uji dan menghasilkan satu set prediksi out-of-fold untuk analisis gabungan.

3.2. Rencana Evaluasi Kinerja Model

CNN sederhana, MobileNetV3, ResNet50, dan EfficientNet-B0 menjalani lima fold yang sama dengan aturan pelatihan yang setara. Peringkat utama ditentukan oleh F1-makro out-of-fold. Akurasi, presisi, recall, kompleksitas parameter, besar model, serta durasi inferensi melengkapi penilaian. Informasi seed, keanggotaan fold, dan pengaturan eksperimen disimpan agar hasilnya dapat diuji ulang.

Dalam setiap putaran, F1-makro pada validasi internal digunakan untuk memilih konfigurasi dari data pengembangan. Fold uji tetap tertutup sampai keputusan konfigurasi selesai. Setelah lima putaran berakhir, hasil tiap fold dirangkum bersama interval kepercayaan dan pengujian berpasangan antarmodel.

3.3. Rencana Analisis Per Kelas dan Kesalahan

Laporan tiap motif memuat presisi, recall, F1-score, dan banyaknya contoh uji. Pola pertukaran kelas ditelaah melalui confusion matrix. Citra yang salah diklasifikasikan kemudian diperiksa satu per satu untuk membedakan kemungkinan penyebab, seperti kemiripan bentuk, motif yang hanya memenuhi area kecil, lipatan kain, pencahayaan, maupun unsur latar.

Temuan dari pemeriksaan kesalahan menjadi umpan balik untuk akuisisi dan rumusan kelas. Motif yang memiliki elemen berukuran kecil, misalnya, dapat membutuhkan rekaman close-up. Jika jaringan terlalu bergantung pada latar, komposisi konteks pemotretan antarkelas perlu diseimbangkan kembali.

3.4. Rencana Audit Grad-CAM

Pemeriksaan Grad-CAM dilaksanakan pada keempat model dengan kelompok contoh yang sama, meliputi prediksi benar berkeyakinan tinggi, prediksi benar berkeyakinan rendah, dan semua prediksi keliru. Audit teknis mengecek apakah area aktif berada pada kain. Selanjutnya, dua ahli memberi skor 1–4 secara terpisah berdasarkan keselarasan heatmap dengan ciri operasional. Perbedaan lebih dari satu nilai dibahas, dan kasus yang belum mencapai kesepakatan dialihkan kepada validator ketiga.

Statistik audit mencakup rerata, simpangan baku, serta weighted Cohen's kappa dari penilaian awal; laporan ringkas memakai nilai sesudah adjudikasi. Setiap heatmap dibaca bersama citra asal dan deskripsi

kelas. Uji grayscale dan color jitter digunakan untuk memeriksa ketergantungan pada warna, lipatan, atau lingkungan foto. Hasil Grad-CAM tidak dipakai sebagai bukti kausal maupun sebagai sumber penafsiran simbol budaya.

3.5. Rencana Studi Ablasi dan Validitas

Eksperimen ablasi memisahkan pengaruh augmentasi, pembukaan kembali backbone, dan pengelompokan data. Protokol penuh memakai fabric_id, augmentasi, serta fine-tuning. Sebaliknya, pemisahan acak pada tingkat foto hanya berfungsi sebagai uji diagnostik untuk memperlihatkan kemungkinan inflasi akibat kebocoran; nilainya tidak dianggap sebagai hasil utama.

Tabel 5. Skenario ablasi dan tujuan pengujiannya

Konfigurasi	Augmentasi	Fine-tuning	Tujuan evaluasi
Protokol utama	Ya	Ya	Menetapkan kinerja utama melalui five-fold cross-validation berbasis fabric_id.
Tanpa augmentasi	Tidak	Ya	Mengukur kontribusi augmentasi data.
Backbone dibekukan	Ya	Tidak	Mengukur kontribusi fine-tuning.
Pemisahan citra acak	Ya	Ya	Mendiagnosis inflasi akibat kebocoran; tidak menjadi hasil utama.

Ancaman validitas internal dikendalikan melalui five-fold berbasis kain, validasi internal yang tidak bercampur dengan fold uji, keluaran out-of-fold, serta dokumentasi seed dan transformasi. Ketepatan konsep kelas tetap bergantung pada taksonomi dan penilaian ahli. Adapun kemampuan generalisasi dibatasi oleh asal koleksi, kamera, lokasi, situasi pencahayaan, dan variasi motif yang berhasil direkam. Oleh sebab itu, simpulan kelak hanya berlaku pada ruang lingkup data yang benar-benar tersedia.

3.6. Perbandingan dengan Penelitian Terdahulu

Studi batik terdahulu memperlihatkan bahwa CNN mampu memisahkan kelas motif [6]. Penelitian tekstil lainnya memanfaatkan penggabungan fitur mendalam untuk image retrieval [7] dan metric learning untuk autentikasi tenun [8]. Kerangka yang diajukan di sini tidak semata-mata menawarkan pilihan jaringan, melainkan menghubungkan pembangunan dataset sutra Bugis, identitas kain sebagai kelompok, verifikasi ahli, tolok ukur beberapa backbone, dan audit visual. Dengan cara itu, mutu data dan keabsahan evaluasi diperlakukan sebagai kontribusi penelitian, bukan sekadar pekerjaan pendahuluan.

Batik Nitik menyediakan contoh pencatatan pemotretan dan ekstraksi area pola [4], sementara koleksi tenun Sikka menekankan kelas yang telah dikurasi [5]. Protokol ini menambahkan fabric_id agar seluruh citra multiview dapat dirunut kembali ke kain sumber dan dipisahkan secara benar. Untuk objek yang lebih dekat, Kurniawan [19] menguji CNN pada 140 foto tenun sutra Bugis. Rancangan sekarang memperluas cakupan tersebut melalui metadata, validasi label, evaluasi tingkat kain, perbandingan empat model, dan telaah Grad-CAM.

3.7. Implikasi Ilmiah dan Praktis Studi

Dari sisi metodologi, rancangan ini menempatkan definisi unit sampel sebagai bagian penting computer vision. Banyaknya berkas pada koleksi multiview tidak sama dengan banyaknya objek yang bebas satu sama lain. fabric_id memperjelas hubungan tersebut dan memungkinkan pengujian benar-benar dilakukan pada kain yang tidak pernah masuk ke proses pelatihan.

Pada tahap pemanfaatan, arsitektur terbaik dapat menjadi dasar aplikasi dokumentasi yang memperlihatkan label prediksi, probabilitas, dan heatmap Grad-CAM. Keluaran tersebut hanya berfungsi sebagai bantuan, bukan keputusan otoritatif. Kasus dengan keyakinan kecil atau sorotan yang tidak mengenai motif harus dikembalikan kepada validator untuk ditinjau.

Koleksi yang terkurasi juga berpotensi menjadi media pembelajaran variasi motif bagi mahasiswa dan masyarakat. Walaupun demikian, label yang dihasilkan jaringan tidak boleh dipakai untuk menciptakan cerita sejarah atau makna simbolik. Informasi semacam itu wajib bersumber dari pustaka dan ahli budaya yang memiliki kewenangan. Pemisahan antara pengenalan bentuk dan interpretasi budaya diperlukan agar komputasi tidak mereduksi pengetahuan yang bergantung pada konteks.

3.8. Status Implementasi dan Batasan Dari

Ketika artikel ini disiapkan, proses pemotretan 2.000 citra, pelatihan empat arsitektur, pengujian statistik, dan penilaian Grad-CAM oleh ahli belum dilaksanakan. Bagian evaluasi karenanya menjelaskan langkah dan keluaran yang direncanakan, bukan temuan numerik. Nilai accuracy, F1-makro, interval kepercayaan, maupun skor heatmap tidak dicantumkan sebelum seluruh kegiatan empiris tuntas. Penegasan ini membatasi klaim artikel pada kerangka kerja yang dapat diterapkan dan direplikasi.

4. KESIMPULAN

Artikel ini merumuskan protokol pembangunan dataset lima motif sutra Bugis serta rencana pembandingan EfficientNet-B0, CNN sederhana, MobileNetV3, dan ResNet50 dengan dukungan audit Grad-CAM. Sasaran koleksi dibuat seragam, yakni 2.000 foto dari 200 kain. Pengujian utama memakai stratified group five-fold cross-validation pada fabric_id, sehingga seluruh tampilan dari satu kain tetap berada dalam fold yang sama. Protokol meliputi verifikasi label, analisis statistik tingkat kain, konsensus dan adjudikasi penilai, serta evaluasi heatmap pada semua arsitektur. Kontribusi yang dapat dinyatakan saat ini adalah rancangan yang replikatif; performa klasifikasi dan daya generalisasi masih menunggu implementasi serta validasi empiris.

5. SARAN

Pekerjaan lanjutan perlu menjalankan seluruh protokol, mulai dari pengambilan 2.000 foto pada 200 kain, verifikasi label, pelatihan empat model, five-fold cross-validation, pengujian statistik, hingga audit Grad-CAM oleh ahli. Sampel sebaiknya mencakup pengrajin, tempat, perangkat, dan kondisi pemotretan yang beragam. Sesudah izin final diperoleh, metadata, definisi kelas, susunan fold, kode eksperimen, dan bagian dataset yang dapat dibagikan perlu dirilis dengan lisensi yang tegas.

UCAPAN TERIMA KASIH

Penulis menghargai dukungan institusional dan fasilitasi akademik dari P3M Universitas Dipa Makassar selama perancangan dan penyusunan kajian ini.

DAFTAR PUSTAKA

- [1] A. A. Sulolipu, B. E. Soetjipto, H. Wahyono, and A. Haryono, "Silk weaving business sustainability as a cultural heritage of Indonesia: A case study in Wajo Regency, South Sulawesi," *Industria Textila*, vol. 73, no. 2, pp. 184–190, 2022, doi: 10.35530/IT.073.02.202056.
- [2] I. Inanna, R. Rahmatullah, M. I. M. Haeruddin, and M. Marhawati, "Silk weaving as a cultural heritage in the informal entrepreneurship education perspective," *Journal of Entrepreneurship Education*, vol. 23, no. 1, pp. 1–11, 2020.
- [3] A. Sadapotto et al., "An analysis of the shape and pattern of Lipa' Sabbe motif as one of the Buginese traditional clothes," *La Ogi: English Language Journal*, vol. 9, no. 1, pp. 70–84, 2023, doi: 10.55678/loj.v9i1.841.
- [4] A. E. Minarno, I. Soesanti, and H. A. Nugroho, "Batik Nitik 960 dataset for classification, retrieval, and generator," *Data*, vol. 8, no. 4, art. 63, 2023, doi: 10.3390/data8040063.
- [5] I. D. Reja, "Motif-Sikka: A curated image dataset of traditional Sikka ikat weaving motifs for textile pattern analysis," *Mendeley Data*, ver. 3, 2025, doi: 10.17632/b2k52v9mkc.3.
- [6] D. G. Meranggi, N. Yudistira, and Y. A. Sari, "Batik classification using convolutional neural network with data improvements," *International Journal on Informatics Visualization*, vol. 6, no. 1, pp. 6–11, 2022, doi: 10.30630/joiv.6.1.716.
- [7] S. Varshney, S. Singh, C. V. Lakshmi, and C. Patvardhan, "Content-based image retrieval of Indian traditional textile motifs using deep feature fusion," *Scientific Reports*, vol. 14, art. 10035, 2024, doi: 10.1038/s41598-024-56465-9.
- [8] A. Das, A. Deka, K. Medhi, and M. J. Saikia, "Deep learning to authenticate traditional handloom textile," *Information*, vol. 15, no. 8, art. 465, 2024, doi: 10.3390/info15080465.
- [9] M. Tan and Q. V. Le, "EfficientNet: Rethinking model scaling for convolutional neural networks," in *Proc. 36th Int. Conf. Machine Learning, PMLR*, vol. 97, 2019, pp. 6105–6114.
- [10] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," in *Proc. IEEE Conf. Computer Vision and Pattern Recognition*, 2016, pp. 770–778.
- [11] A. Howard et al., "Searching for MobileNetV3," in *Proc. IEEE/CVF Int. Conf. Computer Vision*, 2019, pp. 1314–1324.

- [12] R. R. Selvaraju et al., “Grad-CAM: Visual explanations from deep networks via gradient-based localization,” in Proc. IEEE Int. Conf. Computer Vision, 2017, pp. 618–626.
- [13] P. Ramos, R. Ramos, and N. Garcia, “Data leakage in visual datasets,” in Proc. IEEE/CVF Int. Conf. Computer Vision Workshops, 2025, pp. 6368–6378, doi: 10.1109/ICCVW69036.2025.00661.
- [14] C. Shorten and T. M. Khoshgoftaar, “A survey on image data augmentation for deep learning,” Journal of Big Data, vol. 6, art. 60, 2019, doi: 10.1186/s40537-019-0197-0.
- [15] D. P. Kingma and J. Ba, “Adam: A method for stochastic optimization,” in Proc. Int. Conf. Learning Representations, 2015.
- [16] I. Loshchilov and F. Hutter, “Decoupled weight decay regularization,” in Proc. Int. Conf. Learning Representations, 2019.
- [17] T. Pégeot, I. Kucher, A. Popescu, and B. Delezoide, “A comprehensive study of transfer learning under constraints,” in Proc. IEEE/CVF Int. Conf. Computer Vision Workshops, 2023, pp. 1148–1157, doi: 10.1109/ICCVW60793.2023.00123.
- [18] S. Jain, H. Salman, A. Khaddaj, E. Wong, S. M. Park, and A. Mądry, “A data-based perspective on transfer learning,” in Proc. IEEE/CVF Conf. Computer Vision and Pattern Recognition, 2023, pp. 3613–3622, doi: 10.1109/CVPR52729.2023.00352.
- [19] R. R. Kurniawan, “Klasifikasi motif kain tenun sutra Bugis menggunakan convolutional neural network,” Skripsi, Universitas Teknologi Akba Makassar, Makassar, Indonesia, 2025. [Online]. Available: https://perpustakaan.unitama.ac.id/index.php?id=7940&keywords=&p=show_detail