Journal of Information Technology (JI-TECH)
Vol. 1, No. 1, September 2026, E-ISSN: - | P-ISSN: -
DOI: -

IDENTIFIKASI MOTIF KAIN SONGKET PALEMBANG MENGGUNAKAN MOBILENETV2 BERBASIS MOBILE

Adhitia Ibnu Huzaifa Istianto[1], Ana Yulianti[2*], Mutia Fadhilla[3]
Program Studi Teknik Informatika, Fakultas Teknik, Universitas Islam Riau[1,2,3]
Adhitiaibnu06@gmail.com[1], ana.yulianti@eng.uir.ac.id[2], tiafadhilla@eng.uir.ac.id[3]

Article Info

Article history:

Received June 27, 2026
Revised Aug. 21, 2026
Accepted Sept. 6, 2026

Keyword:

Songket Palembang
Klasifikasi citra
Convolutional Neural Network
MobileNetV2
Transfer Learning

ABSTRACT

Songket Palembang merupakan salah satu warisan budaya Indonesia yang memiliki beragam motif dengan karakteristik visual yang khas. Proses identifikasi motif Songket Palembang umumnya masih dilakukan secara manual berdasarkan pengalaman individu sehingga bersifat subjektif dan berpotensi menimbulkan kesalahan, terutama pada motif yang memiliki kemiripan pola visual. Penelitian ini mengusulkan model Convolutional Neural Network (CNN) berbasis arsitektur MobileNetV2 untuk mengklasifikasikan motif Songket Palembang secara otomatis. Dataset yang digunakan terdiri atas 420 citra yang dikelompokkan ke dalam tujuh kelas, yaitu enam kelas motif Songket Palembang dan satu kelas Bukan Songket. Pembagian data dilakukan menggunakan metode Stratified Hold-Out dengan rasio 80:10:10 untuk data pelatihan, validasi, dan pengujian. Proses pelatihan menerapkan pendekatan transfer learning, augmentasi data secara on-the-fly, serta menggunakan dua optimizer, yaitu AdamW dan RMSprop. Evaluasi model dilakukan menggunakan confusion matrix dengan metrik accuracy, precision, recall, dan F1-score. Hasil penelitian menunjukkan bahwa model MobileNetV2 dengan optimizer AdamW menghasilkan performa terbaik dengan nilai accuracy sebesar 88%, precision sebesar 90%, recall sebesar 88%, dan F1-score sebesar 87%. Model yang dihasilkan berhasil diimplementasikan ke dalam aplikasi Android berbasis Kotlin untuk mendukung proses identifikasi motif Songket Palembang secara praktis dan objektif.

© This work is licensed under a Creative Commons Attribution-ShareAlike 4.0 International License.

Corresponding Author:

Ana Yulianti
Departement of Infromatics Engineering
Universitas Islam Riau
Jl. Kaharuddin Nasution No. 113, Pekanbaru, Indonesia
Email: ana.yulianti@eng.uir.ac.id

1. PENDAHULUAN

Songket Palembang merupakan salah satu warisan budaya Indonesia yang memiliki beragam motif dengan karakteristik visual yang khas. Songket ini dikenal dengan penggunaan benang emas atau perak melalui teknik penyisipan benang tambahan sehingga menghasilkan motif bernilai seni tinggi. Secara historis, perkembangan Songket Palembang telah berlangsung sejak masa Kerajaan Sriwijaya dan dipengaruhi oleh aktivitas perdagangan internasional di kawasan Asia Tenggara. Pada

masa tersebut, penggunaan songket hanya diperuntukkan bagi kalangan tertentu sebagai simbol kehormatan dan status sosial dalam berbagai kegiatan adat dan seremonial [1].

Setiap motif Songket Palembang memiliki makna filosofis yang berbeda. Namun, beberapa motif memiliki karakteristik visual yang hampir serupa, terutama pada susunan ornamen dan pola geometrisnya. Kondisi tersebut menyebabkan proses identifikasi motif masih sulit dilakukan secara tepat, khususnya oleh masyarakat yang tidak memiliki pengetahuan mengenai karakteristik masing-masing motif. Penelitian sebelumnya menunjukkan bahwa masyarakat masih mengalami kesulitan dalam membedakan motif Songket Palembang secara visual sehingga proses identifikasi masih bergantung pada informasi dari penenun maupun pedagang [2]. Selain itu, rendahnya pengetahuan generasi muda terhadap keragaman motif Songket Palembang juga berpotensi mengurangi upaya pelestarian warisan budaya tersebut [3]. Oleh karena itu, diperlukan suatu sistem yang mampu membantu proses identifikasi motif secara otomatis, objektif, dan mudah digunakan oleh masyarakat.

Perkembangan teknologi pengolahan citra digital dan kecerdasan buatan memberikan peluang untuk membantu proses identifikasi motif kain tradisional secara otomatis. Citra digital merupakan representasi dua dimensi dari suatu objek yang telah dikonversi menjadi data diskrit sehingga dapat diproses oleh komputer [4]. Salah satu metode yang banyak digunakan pada tugas klasifikasi citra adalah *Convolutional Neural Network* (CNN) karena mampu mengekstraksi fitur visual secara otomatis tanpa memerlukan proses ekstraksi fitur manual [5],[6]. Kemampuan tersebut menjadikan CNN banyak diterapkan pada berbagai penelitian klasifikasi citra, termasuk pengenalan objek budaya.

Beberapa penelitian terdahulu telah mengimplementasikan metode komputasi pada klasifikasi kain tradisional. Yohannes *et al.* [2] menerapkan metode *Support Vector Machine* (SVM) dengan ekstraksi fitur *Histogram of Oriented Gradients* (HOG) pada klasifikasi motif Songket Palembang dan memperoleh akurasi sebesar 88,1%. Devella *et al.* [3] juga memanfaatkan metode *Scale Invariant Feature Transform* (SIFT) dan *Random Forest* pada klasifikasi motif Songket Palembang dengan akurasi mencapai 92,98%. Meskipun menghasilkan performa yang cukup baik, kedua penelitian tersebut masih bergantung pada proses ekstraksi fitur secara manual sehingga representasi fitur yang diperoleh masih terbatas.

Perkembangan metode *deep learning* mulai diterapkan secara luas pada klasifikasi kain tradisional di Nusantara. Fonda *et al.* [7] telah menerapkan arsitektur CNN dasar untuk klasifikasi Batik Riau yang bermotif flora dan alur tabir, meskipun akurasinya masih terbatas pada angka 65% karena kemiripan motif dan pola warna antar kelas. Hal serupa dijumpai pada penelitian Azmi *et al.* [8] yang menggunakan arsitektur CNN yang dibangun dari awal (*train from scratch*) untuk klasifikasi Batik Tanah Liat Sumatera Barat dan memperoleh akurasi data latih sebesar 98,75%, tetapi hanya menghasilkan akurasi data uji sebesar 62,5% akibat terjadinya *overfitting* karena keterbatasan jumlah dataset. Pada pengenalan motif tenun dengan pola geometris dan flora yang kompleks, seperti kain tenun Sabu Raijua, Dabbo dan Bisilisin [9] membuktikan bahwa metode CNN berbasis citra mampu menghasilkan akurasi evaluasi hingga 90% pada pengujian *fold* tertentu dengan akurasi keseluruhan mencapai 85%.

Untuk mengatasi risiko *overfitting* dan keterbatasan akurasi pada pemodelan *from scratch*, pendekatan arsitektur *pre-trained* mulai banyak dieksplorasi. Ananda *et al.* [10] menerapkan arsitektur MobileNetV2 berbasis *transfer learning* pada klasifikasi Songket Pandai Sikek dan memperoleh akurasi hingga 100% pada skenario pembagian data tertentu. Penelitian lain oleh Sahpira [11] juga menunjukkan bahwa MobileNetV2 yang dikombinasikan dengan *optimizer* AdamW mampu menghasilkan akurasi sebesar 97% pada klasifikasi motif Jumputan Palembang. Keunggulan pemodelan CNN pada kain songket juga dibuktikan oleh Mutaqin dan Imran [12] yang mengklasifikasikan Songket Khas Lombok menggunakan arsitektur AlexNet berbasis *transfer learning*, serta mengintegrasikan model tersebut ke dalam antarmuka grafis sederhana sehingga mencapai akurasi evaluasi hingga 97%.

MobileNetV2 merupakan arsitektur CNN ringan yang memanfaatkan *depthwise separable convolution* sehingga cocok diterapkan pada perangkat bergerak [13],[14]. Selain itu, penggunaan pendekatan *transfer learning* memungkinkan model memanfaatkan bobot hasil pelatihan pada dataset ImageNet sehingga proses pelatihan menjadi lebih efisien dan mampu meningkatkan

performa pada dataset yang relatif terbatas [15]. Keunggulan efisiensi dan performa MobileNetV2 berbasis *transfer learning* juga telah dibuktikan dalam berbagai studi komparatif terbaru pada domain klasifikasi citra lain, misalnya pada pengenalan jenis buah kurma, di mana MobileNetV2 mengungguli ResNet50 dengan akurasi 95% [16].

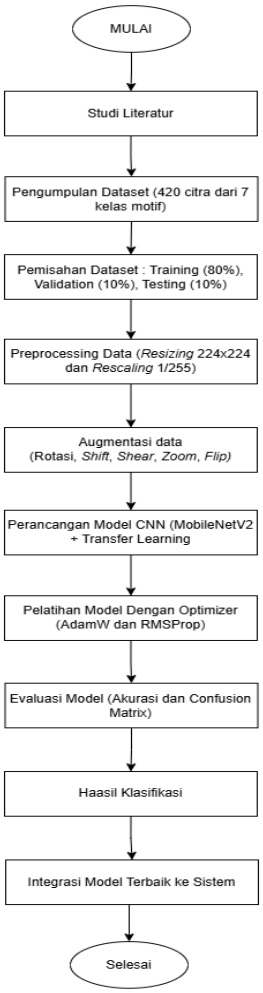
Proses pelatihan model sangat dipengaruhi oleh pemilihan *optimizer* yang digunakan. *Optimizer* berfungsi memperbarui bobot model berdasarkan nilai fungsi kerugian sehingga berpengaruh langsung terhadap kecepatan konvergensi dan kestabilan proses pembelajaran[17]. Efektivitas pemilihan *optimizer* pada model CNN telah dibuktikan oleh setyawan *et al.* [17] , di mana perbandingan algoritma optimasi menunjukkan dampak yang signifikan terhadap peningkatan performa dan stabilitas akurasi model pada klasifikasi citra. Hal ini sejalan dengan penelitian Adhitya *et al.* [18] yang membuktikan bahwa penerapan dan analisis perbandingan *optimizer* (termasuk keluarga Adam dan RMSprop) pada model CNN sangat krusial untuk meminimalisir risiko *overfitting* sekaligus meningkatkan akurasi validasi model secara drastis. Dua *optimizer* modern yang banyak digunakan saat ini adalah RMSprop dan AdamW. RMSprop mampu menyesuaikan *learning rate* secara adaptif untuk mengatasi fluktuasi gradien [19], sedangkan AdamW menggabungkan mekanisme adaptif Adam dengan *weight decay* sehingga mampu meningkatkan kemampuan generalisasi model [19]. Untuk mengurangi risiko *overfitting*, proses pelatihan juga dapat dikombinasikan dengan teknik augmentasi data yang menghasilkan variasi citra baru selama proses pelatihan berlangsung [20].

Berdasarkan penelitian-penelitian tersebut, masih terdapat peluang untuk mengembangkan model klasifikasi motif Songket Palembang menggunakan arsitektur MobileNetV2. Penelitian sebelumnya pada objek Songket Palembang masih didominasi oleh metode berbasis ekstraksi fitur manual, sedangkan penerapan MobileNetV2 lebih banyak dilakukan pada objek kain tradisional lain. Selain itu, implementasi model klasifikasi motif Songket Palembang ke dalam aplikasi bergerak (*mobile application*) juga masih sangat terbatas. Padahal, karakteristik visual Songket Palembang yang memiliki struktur ornamen cukup kompleks memerlukan model yang mampu mengekstraksi fitur citra secara optimal sekaligus tetap ringan untuk dijalankan pada perangkat bergerak.

Oleh karena itu, penelitian ini mengusulkan model klasifikasi motif Songket Palembang menggunakan *Convolutional Neural Network* (CNN) berbasis MobileNetV2 dengan pendekatan *transfer learning*. Dataset yang digunakan terdiri atas 420 citra yang mewakili enam jenis motif Songket Palembang, yaitu Bintang Berantai, Bunga Cina, Cantik Manis, Naga Besaung, Nampan Perak, dan Pulir, serta satu kelas Bukan Songket. Proses pelatihan membandingkan dua *optimizer*, yaitu AdamW dan RMSprop, sedangkan evaluasi model dilakukan menggunakan *confusion matrix* dengan metrik *accuracy*, *precision*, *recall*, dan *F1-score*. Model terbaik kemudian diimplementasikan ke dalam aplikasi Android berbasis Kotlin sehingga dapat digunakan sebagai alat bantu identifikasi motif Songket Palembang secara praktis dan objektif. Kontribusi utama penelitian ini adalah penerapan MobileNetV2 berbasis *transfer learning* pada klasifikasi motif Songket Palembang serta implementasinya ke dalam aplikasi Android untuk mendukung pelestarian budaya melalui pemanfaatan teknologi kecerdasan buatan.

2. METODE PENELITIAN

Penelitian ini menggunakan metode *Convolutional Neural Network* (CNN) dengan arsitektur *MobileNetV2* berbasis *transfer learning* untuk melakukan klasifikasi motif Songket Palembang. Tahapan penelitian meliputi studi literatur, pengumpulan dataset, penyusunan dataset, pra-pemrosesan dan augmentasi data, perancangan model, pelatihan model, evaluasi model, serta integrasi model ke dalam aplikasi Android. Alur penelitian ditunjukkan pada Gambar 1.



Gambar 1 Alur Penelitian

2.1. Pengumpulan dan Pembagian Dataset

Dataset yang digunakan dalam penelitian ini diperoleh melalui observasi langsung dan pengambilan citra pada Museum Zainal Songket di Kota Palembang. Total dataset berjumlah 420 citra digital yang terbagi ke dalam tujuh kelas kategori, yaitu *Bintang Berantai*, *Bunga Cina*, *Cantik Manis*, *Naga Besaung*, *Nampan Perak*, *Pulir*, serta kelas *Bukan Songket*. Kelas *Bukan Songket* diisi dengan objek latar belakang umum (seperti wajah manusia, furnitur, dan tekstur dinding) sebagai kontrol negatif agar sistem aplikasi tidak mendeteksi objek non-songket sebagai motif songket saat digunakan di lingkungan nyata. Gambar 2 menyajikan jenis kain motif songket yang akan digunakan dalam proses pelatihan dan pengujian.



(a) (b) (c)



(d) (e) (f)

Gambar 2 Jenis Motif Songket Palembang: (a) Bintang Berantai; (b) Bunga Cina; (c) Cantik Manis; (d) Naga Besaung; (e) Nampan Perak; (f) Pulir

Pembagian dataset dilakukan menggunakan metode Stratified Hold-Out dengan rasio 80% untuk data pelatihan (*training*), 10% untuk data validasi (*validation*), dan 10% untuk data pengujian (*testing*). Metode ini digunakan untuk menjaga proporsi jumlah data pada setiap kelas sehingga distribusi dataset tetap seimbang pada setiap tahap pelatihan dan pengujian. Distribusi jumlah citra pada setiap kelas ditunjukkan pada Tabel 1.

Tabel 1 Distribusi Dataset

No	Kelas Motif	Data Pelatihan (Training)	Data Validasi (Validation)	Data Pengujian (Testing)	Total
1	Bintang Berantai	48	6	6	60
2	Bunga Cina	48	6	6	60
3	Cantik Manis	48	6	6	60
4	Naga Besaung	48	6	6	60
5	Nampan Perak	48	6	6	60
6	Pulir	48	6	6	60
7	Bukan Songket	48	6	6	60
Total		336	42	42	420

2.2. Pra-pengolahan dan Augmentasi Data

Sebelum digunakan dalam proses pelatihan, seluruh citra melalui tahap prapengolahan yang meliputi perubahan ukuran (*resize*) menjadi 224 × 224 piksel dan normalisasi nilai piksel. Selanjutnya dilakukan augmentasi data secara *on-the-fly* menggunakan ImageDataGenerator untuk meningkatkan variasi data pelatihan dan mengurangi risiko *overfitting*. Teknik augmentasi yang digunakan meliputi rotasi (*rotation*), pergeseran horizontal dan vertikal (*width* dan *height shift*), pembesaran (*zoom*), serta pembalikan horizontal (*horizontal flip*).

2.3. Perancangan dan Pelatihan Model

Model klasifikasi dibangun menggunakan arsitektur MobileNetV2 dengan pendekatan *transfer learning*. Bobot awal (*pre-trained weights*) yang telah dilatih pada dataset ImageNet dimanfaatkan sebagai ekstraktor fitur, sedangkan lapisan klasifikasi disesuaikan dengan jumlah kelas pada penelitian ini.

Penelitian ini terdiri atas dua skenario pelatihan. Skenario pertama menerapkan mekanisme *Early Stopping* dan *ReduceLROnPlateau* untuk memperoleh model terbaik secara otomatis. Selanjutnya, pada skenario kedua dilakukan pelatihan tanpa *Early Stopping* hingga mencapai 100 epoch guna menganalisis pengaruh durasi pelatihan terhadap kemampuan generalisasi model. Parameter pelatihan yang digunakan pada kedua skenario ditunjukkan pada Tabel 2.

Tabel 2 Skenario Model

Parameter	**Nilai**
Arsitektur	MobileNetV2
Pendekatan	Transfer Learning

Ukuran Citra	224 × 224 piksel
Batch Size	16
Epoch Maksimum	100
Optimizer	AdamW dan RMSprop
Learning Rate Awal	0.0001
Loss Function	Categorical Crossentropy
Callback	Early Stopping, ReduceLROnPlateau
Framework	TensorFlow/Keras

2.4. Evaluasi Model dan Implementasi Aplikasi

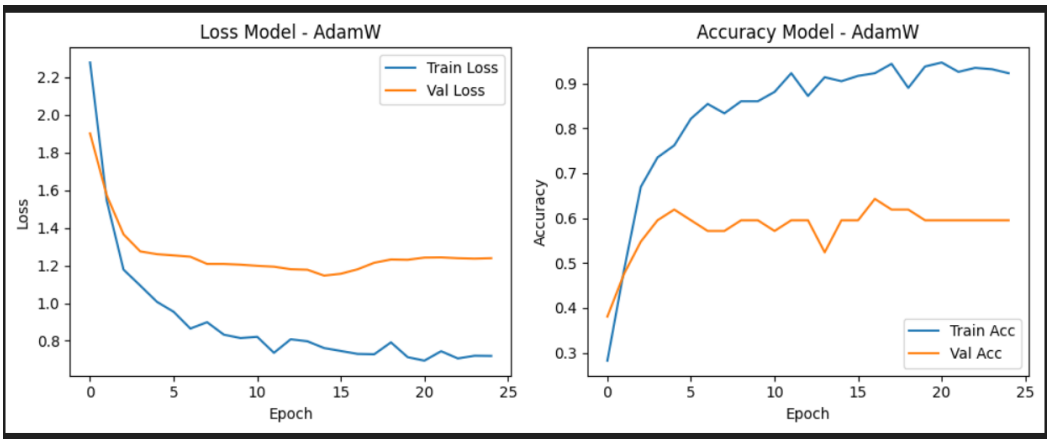
Evaluasi model dilakukan menggunakan *Confusion Matrix* dengan menghitung nilai *Accuracy, Precision, Recall*, dan *F1-score*. Metrik tersebut digunakan untuk mengukur kemampuan model dalam mengklasifikasikan setiap kelas motif Songket Palembang.

Model dengan performa terbaik selanjutnya dikonversi ke format TensorFlow Lite (TFLite) dan diintegrasikan ke dalam aplikasi Android yang dikembangkan menggunakan bahasa pemrograman Kotlin, sehingga dapat digunakan sebagai alat bantu identifikasi motif Songket Palembang secara otomatis.

3. HASIL DAN PEMBAHASAN

3.1. Pelatihan dan Validasi Model

Pada penelitian ini dilakukan proses pelatihan model MobileNetV2 menggunakan dua optimizer, yaitu AdamW dan RMSprop, untuk membandingkan performa keduanya dalam mengklasifikasikan motif Songket Palembang. Setiap optimizer diuji menggunakan dua skenario pelatihan, yaitu dengan menerapkan mekanisme *Early Stopping* dan tanpa *Early Stopping* hingga mencapai 100 epoch. Performa model diamati berdasarkan perkembangan nilai *training accuracy*, *validation accuracy*, *training loss*, dan *validation loss*. Pelatihan pertama dilakukan menggunakan optimizer AdamW dengan menerapkan mekanisme *Early Stopping*. Grafik perkembangan *accuracy* dan *loss* selama proses pelatihan ditunjukkan pada Gambar 3, sedangkan ringkasan hasil pelatihan disajikan pada Tabel 3.



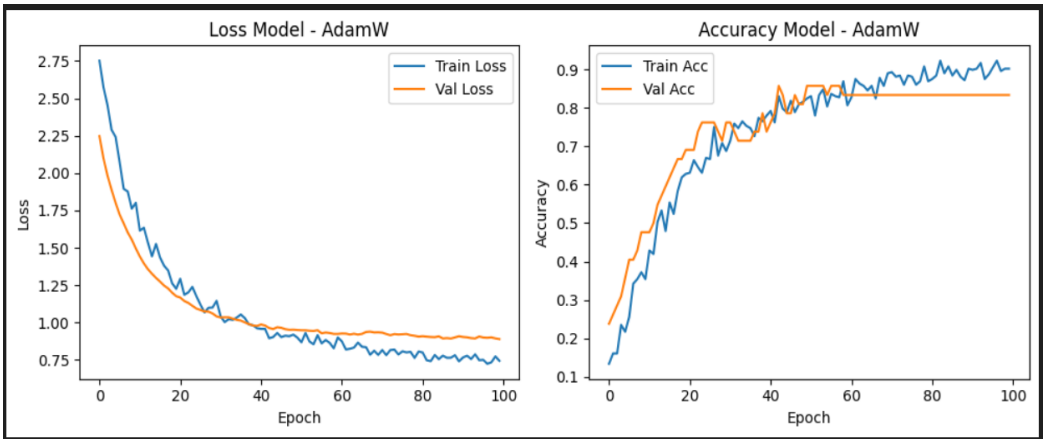
Gambar 3 Grafik Loss dan Accuracy AdamW

Tabel 3 Ringkasan Hasil Pelatihan dan Validasi Optimizer AdamW

Epoch Berhenti	Epoch Terbaik	Training Accuracy	Validation Accuracy	Training Loss	Validation Loss
25	15	90.48%	60.52%	0.7614	1.1462

Berdasarkan Gambar 3 dan Tabel 3, proses pelatihan dihentikan secara otomatis pada epoch ke-25 oleh mekanisme *Early Stopping*, sedangkan bobot model terbaik diperoleh pada epoch ke-15. Nilai *training accuracy* mencapai 90,48%, sedangkan *validation accuracy* sebesar 60,52%. Perbedaan tersebut menunjukkan bahwa model lebih mampu mempelajari data pelatihan dibandingkan dengan melakukan generalisasi terhadap data validasi, sehingga mulai menunjukkan indikasi *overfitting*. Kondisi tersebut diduga dipengaruhi oleh keterbatasan jumlah dataset serta adanya kemiripan karakteristik visual pada beberapa motif Songket Palembang.

Untuk mengetahui pengaruh durasi pelatihan terhadap kemampuan generalisasi model, dilakukan pengujian lanjutan dengan menonaktifkan mekanisme *Early Stopping* sehingga proses pelatihan berlangsung hingga mencapai 100 epoch. Hasil pelatihan ditunjukkan pada Gambar 4 dan Tabel 4.



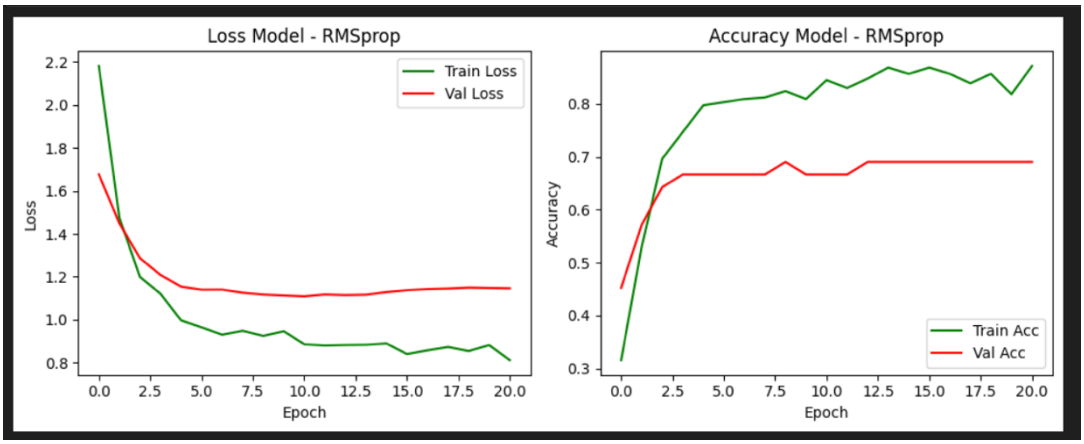
Gambar 4 Grafik Loss dan Accuracy AdamW (Tanpa Early Stopping)

Tabel 4 Ringkasan Hasil Pelatihan dan Validasi Optimizer AdamW (Tanpa Early Stopping)

Epoch Total	Training Accuracy	Validation Accuracy	Training Loss	Validation Loss
100	90.18%	83.00%	0.7443	0.8895

Pelatihan hingga 100 epoch menghasilkan proses pembelajaran yang lebih stabil dibandingkan dengan skenario sebelumnya. *Validation accuracy* meningkat menjadi 83,33% dengan *validation loss* sebesar 0,8895. Selain itu, selisih antara *training accuracy* dan *validation accuracy* menjadi lebih kecil sehingga kemampuan generalisasi model mengalami peningkatan meskipun masih terdapat indikasi *overfitting* ringan.

Selanjutnya dilakukan pelatihan menggunakan optimizer RMSprop. Grafik perkembangan *accuracy* dan *loss* ditampilkan pada Gambar 5, sedangkan hasil pelatihan dirangkum pada Tabel 5.



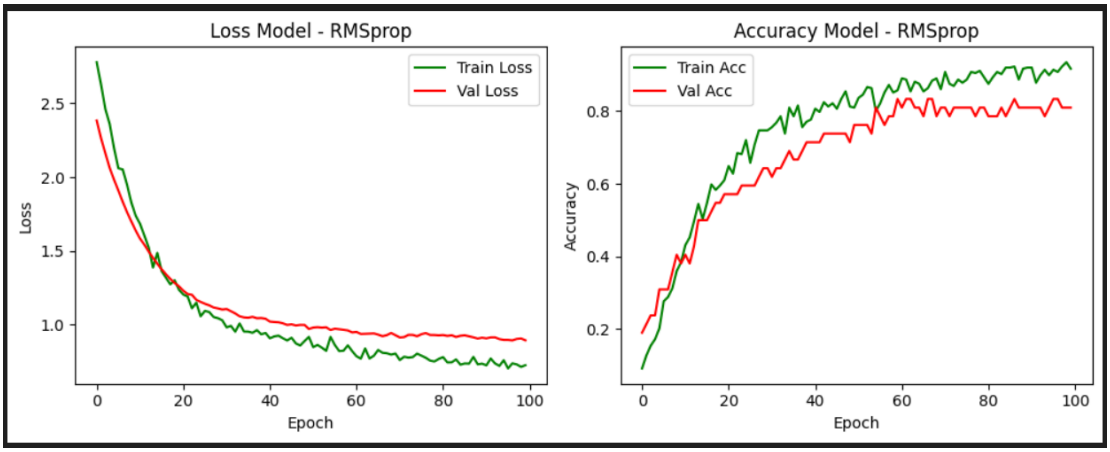
Gambar 5 Grafik Loss dan Accuracy RMSprop

Tabel 5 Ringkasan Hasil Pelatihan dan Validasi Optimizer RMSprop

Epoch Berhenti	Epoch Terbaik	Training Accuracy	Validation Accuracy	Training Loss	Validation Loss
21	11	84.52%	66.67%	0.8858	1.1089

Berdasarkan Gambar 5 dan Tabel 5, proses pelatihan dihentikan pada epoch ke-21, dengan bobot terbaik diperoleh pada epoch ke-11. Nilai *training accuracy* mencapai 84,52%, sedangkan *validation accuracy* sebesar 66,67%. Perbedaan performa antara data pelatihan dan data validasi relatif lebih kecil dibandingkan dengan AdamW sehingga menunjukkan kecenderungan *overfitting* yang lebih rendah.

Pengujian kemudian dilanjutkan tanpa mekanisme *Early Stopping* hingga mencapai 100 epoch. Hasil pelatihan ditampilkan pada Gambar 6 dan Tabel 6.



Gambar 6 Grafik Loss dan Accuracy RMSprop (Tanpa Early Stopping)

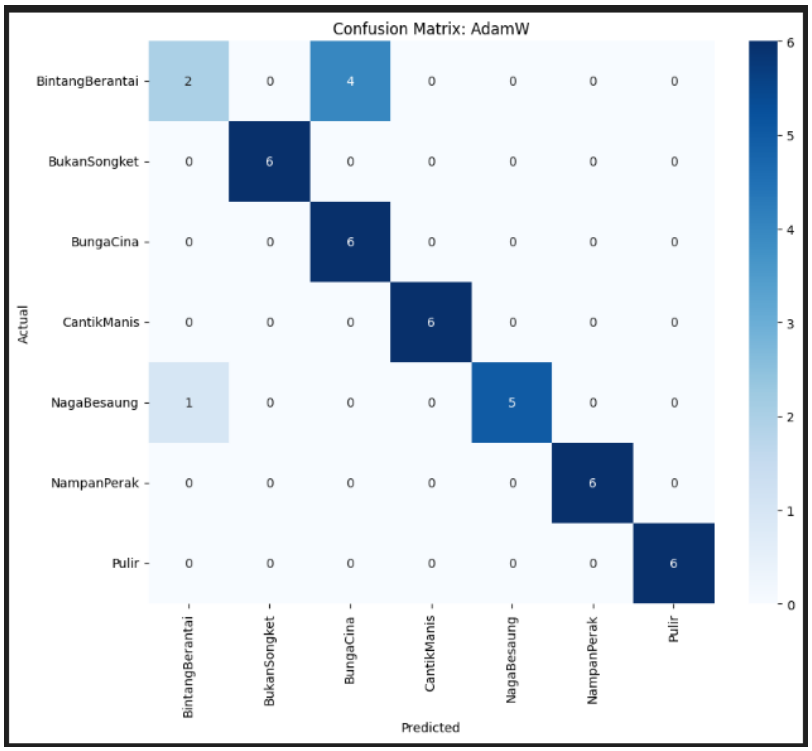
Tabel 6 Ringkasan Hasil Pelatihan dan Validasi Optimizer RMSprop (Tanpa Early Stopping)

Epoch Total	Training Accuracy	Validation Accuracy	Training Loss	Validation Loss
100	91,67%	80,95%	0,7258	0,8950

Pelatihan hingga 100 epoch menghasilkan peningkatan *validation accuracy* menjadi 80,95% dengan *validation loss* sebesar 0,8950. Hasil tersebut menunjukkan bahwa pelatihan tanpa *Early Stopping* mampu meningkatkan kemampuan generalisasi model dibandingkan dengan skenario sebelumnya.

3.2. Evaluasi Model

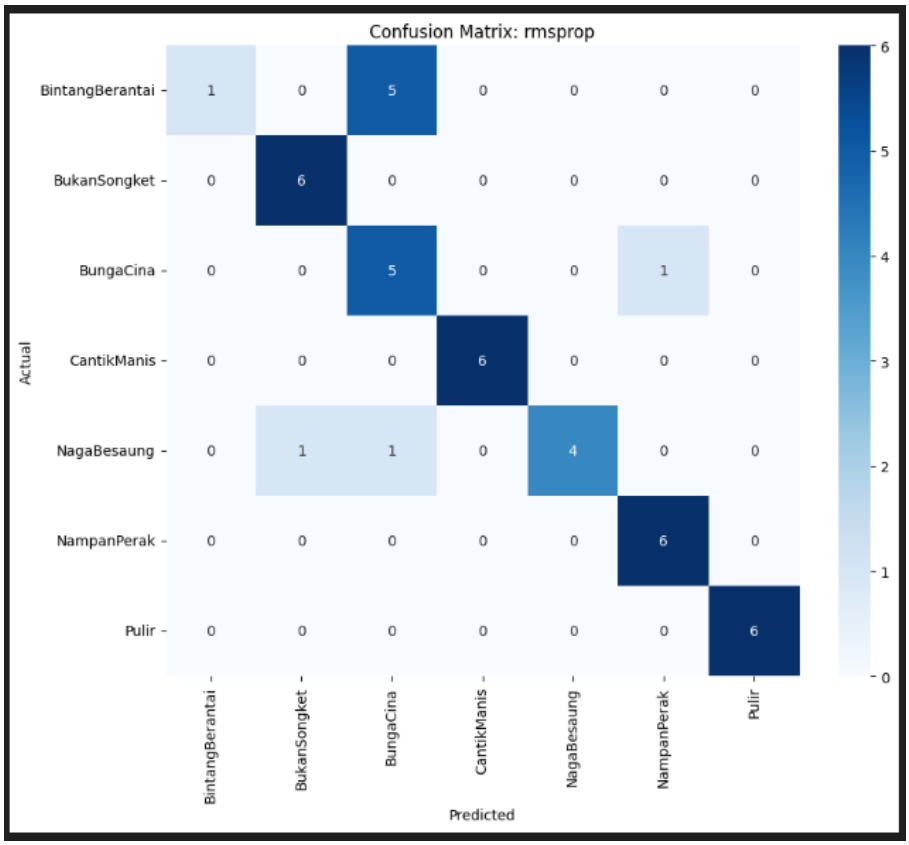
Evaluasi model dilakukan menggunakan data pengujian sebanyak 42 citra yang tidak pernah digunakan selama proses pelatihan maupun validasi. Evaluasi dilakukan menggunakan *confusion matrix* untuk memperoleh nilai *accuracy*, *precision*, *recall*, dan *F1-score*. Hasil evaluasi model menggunakan optimizer AdamW ditunjukkan pada Gambar 7.



Gambar 7 Confusion Matrix AdamW

Model AdamW berhasil mengklasifikasikan 37 dari 42 citra pengujian dengan benar sehingga memperoleh *accuracy* sebesar 88%. Kesalahan klasifikasi paling banyak terjadi antara motif Bintang Berantai dan Bunga Cina yang memiliki karakteristik visual serupa.

Selanjutnya dilakukan evaluasi terhadap model menggunakan optimizer RMSprop. Hasil evaluasi ditunjukkan pada Gambar 8.



Gambar 8 Confusion Matrix RMSprop

Model RMSprop memperoleh *accuracy* sebesar 81% dengan 34 citra yang berhasil diklasifikasikan secara benar. Kesalahan klasifikasi masih didominasi oleh motif Bintang Berantai yang diprediksi sebagai Bunga Cina. Ringkasan hasil evaluasi kedua model disajikan pada Tabel 7.

Tabel 7 Tabel Perbandingan Hasil Evaluasi

Optimizer	**Accuracy**	**Precision**	**Recall**	**F1-Score**
AdamW	88%	90%	88%	87%
RMSprop	81%	88%	81%	79%

Berdasarkan Tabel 7, optimizer AdamW menghasilkan performa terbaik pada seluruh metrik evaluasi. Nilai *accuracy*, *precision*, *recall*, dan *F1-score* yang diperoleh lebih tinggi dibandingkan dengan RMSprop. Oleh karena itu, model MobileNetV2 dengan optimizer AdamW dipilih sebagai model terbaik untuk diimplementasikan ke dalam aplikasi Android.

3.3. Implementasi Aplikasi

Model MobileNetV2 dengan optimizer AdamW kemudian dikonversi ke format TensorFlow Lite (*TFLite*) dan diintegrasikan ke dalam aplikasi Android yang dikembangkan menggunakan bahasa pemrograman Kotlin. Implementasi ini memungkinkan proses identifikasi motif Songket Palembang dilakukan secara langsung pada perangkat bergerak.



(a) (b)

(c) (d)

Gambar 9 Tampilan Aplikasi: (a) Halaman Utama Aplikasi; (b) Halaman Kamera; (c) Halaman Hasil Klasifikasi; (d) Halaman About;

Aplikasi mampu melakukan prediksi motif Songket Palembang berdasarkan citra masukan dan menampilkan hasil klasifikasi secara otomatis. Implementasi ini menunjukkan bahwa model yang dikembangkan tidak hanya memiliki performa klasifikasi yang baik, tetapi juga dapat diterapkan pada perangkat Android sebagai alat bantu identifikasi motif Songket Palembang secara praktis.

4. KESIMPULAN

Penelitian ini berhasil mengembangkan model klasifikasi motif Songket Palembang menggunakan metode *Convolutional Neural Network* (CNN) dengan arsitektur MobileNetV2 menggunakan *transfer learning*. Model yang dikembangkan mampu mengidentifikasi tujuh kelas citra, yaitu enam motif Songket Palembang dan satu kelas Bukan Songket, kemudian diimplementasikan ke dalam aplikasi Android berbasis Kotlin menggunakan TensorFlow Lite sebagai alat bantu identifikasi motif secara praktis.

Hasil pengujian menunjukkan bahwa model MobileNetV2 mampu mengenali sebagian besar motif Songket Palembang dengan baik. Meskipun demikian, masih ditemukan beberapa kesalahan klasifikasi pada motif yang memiliki karakteristik visual yang mirip, khususnya antara motif Bintang Berantai dan Bunga Cina. Kondisi tersebut menunjukkan bahwa kemiripan pola visual antarmotif serta keterbatasan jumlah dan variasi dataset masih menjadi tantangan dalam proses klasifikasi.

Berdasarkan hasil evaluasi menggunakan *confusion matrix*, model terbaik diperoleh pada penggunaan optimizer AdamW dengan nilai *accuracy* sebesar 88%, *precision* sebesar 90%, *recall* sebesar 88%, dan *F1-score* sebesar 87%. Hasil tersebut menunjukkan bahwa model yang dikembangkan memiliki performa yang baik dalam mengklasifikasikan motif Songket Palembang pada dataset yang digunakan.

Penelitian selanjutnya diharapkan dapat menggunakan dataset yang lebih besar dan lebih beragam, mengeksplorasi arsitektur *deep learning* maupun strategi pelatihan lainnya, serta mengembangkan aplikasi dengan fitur yang lebih lengkap agar kemampuan klasifikasi dan pemanfaatannya dalam pelestarian budaya dapat semakin ditingkatkan.

REFERENCES

[1] I. Muhammad Fadhlan, "Geologi Situs Gua Batu, Desa Napal Licin, Kecamatan Ulu Rawas, Kabupaten Musi Rawas Utara, Provinsi Sumatera Selatan," *J. Arkeol. Siddhayatra*, vol. 21, no. 2, hal. 129–141, 2016, [Daring]. Tersedia pada: https://repositori.kemendikdasmen.go.id/7182/1/Siddhayatra Vol 21 %282%29 November 2016.pdf

[2] Y. Yohannes, M. E. Al Rivan, S. Devella, dan M. Meiriyama, "KLASIFIKASI MOTIF SONGKET PALEMBANG MENGGUNAKAN SUPPORT VECTOR MACHINE BERDASARKAN HISTOGRAM OF ORIENTED GRADIENTS," vol. 9, no. 2, hal. 143–149, 2023.

[3] S. Devella, Y. Yohannes, dan F. N. Rahmawati, "Implementasi Random Forest Untuk Klasifikasi Motif Songket Palembang Berdasarkan SIFT," *JATISI (Jurnal Tek. Inform. dan Sist. Informasi)*, vol. 7, no. 2, hal. 310–320, 2021, doi: 10.35957/jatisi.v7i2.289.

[4] P. A. R. Devi dan H. Rosyid, "Pemaparan Materi Dasar Pengolahan Citra Digital untuk Upgrade Wawasan Siswa di SMK Dharma Wanita Gresik," *J. Abdi Masy. Indones.*, vol. 2, no. 4, hal. 1259–1264, 2022, doi: 10.54082/jamsi.405.

[5] B. Raharjo, *Deep Learning dengan Python*. 2022.

[6] A. Syalsabila, R. Saputra, Ridwan Sutri, Riyan Saputra, dan R. Sovia, "Klasifikasi Citra Buah Jeruk Mandarin dan Kelapa Menggunakan Algoritma PCA dan Metode K-Nearest Neighbor (KNN)," *JPG J. Pendidik. Guru*, vol. 6, no. 2, hal. 263–270, 2025, doi: 10.32832/jpg.v6i2.19351.

[7] H. Fonda, "Classification of Riau Batik Using Convolutional Neural Networks (CNN)," *J. Ilmu Komput.*, vol. 9, no. 1, hal. 7–10, 2021.

[8] K. Azmi, S. Defit, dan Sumijan, "Implementasi Convolutional Neural Network (CNN) Untuk Klasifikasi Batik Tanah Liat Sumatera Barat," vol. 16, no. 1, hal. 2580–2582, 2023.

[9] P. Dabbo, F. Yusuf Bisilisin, dan I. A. Abstrak, "Klasifikasi Motif Kain Tenun Sabu Raijua Menggunakan Convolutional Neural Network (CNN) Berbasis Citra," *KETIK J. Inform.*, vol. 1, no. 06, hal. 11–18, 2024, [Daring]. Tersedia pada: https://jurnal.faatuatua.com/index.php/KETIK/article/view/88

[10] T. D. Ananda, Garno, A. Primajaya, D. Juardi, dan J. H. Jaman, "Identifikasi Citra Kain

Songket Pandai Sikek Menggunakan Metode Convolutional Neural Network (CNN)," vol. 11, no. July, hal. 278–287, 2025.
[11] M. Sahpira, "Transfer Learning dengan MobileNetV2 untuk Klasifikasi Motif Jumputan Palembang," *J. Algoritm.*, vol. 5, no. 3, hal. 264–273, 2025, doi: 10.35957/algoritme.v6i1.10998.
[12] Z. Mutaqin dan B. Imran, "Klasifikasi Kain Songket Khas Lombok Menggunakan CNN dengan Arsitektur Alexnet," vol. 14, no. 2, hal. 99–107, 2024.
[13] R. R. Santosa, A. Sasikirana, Z. L. Ramadhan, Y. Putra, dan B. Satria, "Perbandingan Kinerja MobileNetV2 dan ResNet50V2 Dalam Klasifikasi Tingkat Kematangan Tomat," vol. 3, no. 1, hal. 49–56, 2025.
[14] A. Santoso dan G. Ariyanto, "IMPLEMENTASI DEEP LEARNING BERBASIS KERAS UNTUK PENGENALAN WAJAH," *J. Emit.*, vol. 18, no. 01, hal. 15–21, 2022, [Daring]. Tersedia pada: http://eprints.ums.ac.id/62956/
[15] O. V. Putra, M. Z. Mustaqim, dan D. Muriatmoko, "Transfer Learning untuk Klasifikasi Penyakit dan Hama Padi Menggunakan MobileNetV2," *Techno.Com*, vol. 22, no. 3, hal. 562–575, 2023, doi: 10.33633/tc.v22i3.8516.
[16] A. R. Hermanto, A. Aziz, dan S. Sudianto, "Perbandingan Arsitektur MobileNetV2 dan RestNet50 untuk Klasifikasi Jenis Buah Kurma Comparison of MobileNetV2 and RestNet50 Architectures for Date Fruit Classification by Type," *J. Sist. dan Teknol. Inf.*, vol. 12, no. 4, hal. 630–637, 2024, doi: 10.26418/justin.v12i4.80358.
[17] P. A. Setyawan, A. Danuarta, F. N. Alam, dan T. Agustin, "Analisis Perbandingan Optimizer Pada Model Convolutional Neural Network Untuk Deteksi Kanker Paru-paru," *Semin. Nas. Amikom Surakarta*, vol. 2, no. November, hal. 320–330, 2024.
[18] R. Y. Adhitya, M. K. Hasin, M. Syai, dan E. Setiawan, "Analisis Pengaruh Optimizer pada Model CNN untuk Identifikasi Cacat pada Perekat Kemasan Optimizer Analysis on the CNN Model for Identification Packaging Defects," vol. 13, no. 2, hal. 217–229, 2023.
[19] W. R. N. Rifa'i, D. Erwanto, dan I. Yanuartanti, "Evaluasi Kinerja CNN dengan Optimizer RMSprop , Adam dan," *J. Tek. Elektro Electron. Control. Telecommun. Comput. Inf. Power Syst.*, vol. 10, no. 1, hal. 91–104, 2025.
[20] M. A. Al-Fahrezi, "Pengaruh Augmentasi Data Terhadap Akurasi Pelatihan Model CNN untuk Klasifikasi Jenis Ikan," *JITSI J. Ilm. Teknol. Sist. Inf.*, vol. 6, no. 2, hal. 177–185, 2025, doi: 10.62527/jitsi.6.2.471.