

Implementasi Transfer Learning Pada AlexNet Untuk Klasifikasi Motif Batik Yogyakarta

Angela Gracia Cahyaningtyas¹, Sri Suwarno², Budi Susanto³

Informatika, Universitas Kristen Duta Wacana

Jl. Dr. Wahidin Sudirohusodo No. 5-25, Kota Yogyakarta

¹angela.gracia@ti.ukdw.ac.id

²budsus@ti.ukdw.ac.id

³sswn@staff.ukdw.ac.id

Abstract— This study discusses the implementation of Transfer Learning using the AlexNet architecture for classifying Yogyakarta Batik motifs, specifically Kawung, Parang, and Truntum. The dataset consists of 1,110 batik images that underwent preprocessing, augmentation, and data splitting. The research was conducted in two main experimental scenarios: applying Average Pooling and Max Pooling with a more complex classifier, and training the model without additional pooling layers using a simpler classifier. Furthermore, the experiments compared the model's performance across different frozen layers and two optimizers (Adam and SGD). The results show that the best configuration was obtained using the SGD optimizer with Average Pooling and three frozen layers, achieving a test accuracy of 99.10%. In contrast, the Adam optimizer tended to produce lower and less stable performance. Experiments without pooling also reached high accuracy, but were less optimal than those with pooling. Therefore, this study demonstrates that the choice of pooling technique, classifier complexity, frozen layers, and optimizer plays a crucial role in achieving optimal performance of AlexNet for Batik classification.

Intisari— Penelitian ini membahas implementasi metode Transfer Learning pada arsitektur AlexNet untuk klasifikasi motif Batik Yogyakarta, yaitu Kawung, Parang, dan Truntum. Dataset yang digunakan terdiri atas 1.110 citra batik yang telah melalui tahap preprocessing, augmentasi, serta pembagian data. Penelitian ini dilakukan dengan dua tahap eksperimen utama: pertama, penerapan Average Pooling dan Max Pooling dengan modifikasi classifier yang lebih kompleks, dan kedua skenario tanpa pooling tambahan dengan classifier yang lebih sederhana. Selain itu, model juga diuji dengan variasi jumlah freeze layer serta dua optimizer (Adam dan SGD). Hasil penelitian menunjukkan bahwa konfigurasi terbaik diperoleh pada penggunaan optimizer SGD dengan Average Pooling pada kondisi freeze tiga layer, yang mencapai akurasi uji sebesar 99,10%. Sebaliknya, optimizer Adam cenderung menghasilkan performa lebih rendah dan tidak stabil. Eksperimen tanpa pooling menunjukkan bahwa model tetap mampu mencapai akurasi tinggi, tetapi tidak seoptimal konfigurasi dengan pooling. Dengan demikian, penelitian ini menegaskan bahwa pemilihan jenis pooling, kompleksitas classifier, jumlah freeze layer, serta optimizer sangat berpengaruh terhadap performa model AlexNet dalam klasifikasi motif batik.

Kata Kunci— Batik Yogyakarta, AlexNet, Transfer Learning, Freeze layer, Adam, SGD, Average Pooling, Max Pooling, Classifier

I. PENDAHULUAN

Pengembangan teknologi kecerdasan buatan dan

pengolahan citra telah membuka peluang baru dalam pengenalan pola dan klasifikasi visual. Salah satu penerapan yang mendapatkan perhatian adalah klasifikasi citra termasuk klasifikasi batik, khususnya batik Yogyakarta. Motif batik Yogyakarta memiliki nilai budaya dan seni yang tinggi, dengan pola-pola yang kompleks dan beragam. Salah satu metode yang dapat digunakan untuk mengklasifikasikan batik Yogyakarta adalah AlexNet, yang telah terbukti efektif dalam pengolahan citra [7]. Namun, klasifikasi motif batik ini memiliki tantangan signifikan karena keragaman motif dan kesamaan antar pola, terutama dalam penerapan pada motif batik Yogyakarta.

AlexNet memiliki arsitektur yang mampu menangkap fitur penting dari citra, mulai dari pola sederhana hingga yang kompleks. Akan tetapi, penerapan AlexNet untuk motif batik memerlukan pendekatan khusus agar model dapat beradaptasi mengenali karakteristik unik. Transfer learning menjadi solusi yang relevan untuk mengatasi tantangan tersebut. Dengan menggunakan model AlexNet yang telah dilatih sebelumnya pada dataset berskala besar, proses pelatihan dapat dilakukan lebih cepat, efisien, dan akurat pada dataset batik yang terbatas [8], [11]. Selain itu, augmentasi data juga berperan penting untuk memperluas variasi dataset dan meningkatkan kemampuan generalisasi model [10].

Sejumlah penelitian terdahulu mendukung penggunaan metode ini. Meranggi et al. dan Surya et al. menunjukkan bahwa CNN efektif dalam klasifikasi motif batik, sementara Goodfellow et al. [6] menjelaskan komponen CNN yang mendukung ekstraksi fitur visual. Yosinski et al. [11] menekankan peran transfer learning pada dataset kecil, dan Rawat & Wang [9] menambahkan bahwa CNN dapat memberikan hasil yang akurat dan efisien pada pengolahan citra. Dengan demikian, penelitian ini menekankan kebaruan dalam implementasi transfer learning dengan berbagai skenario freeze layer pada arsitektur AlexNet untuk klasifikasi motif batik Yogyakarta, serta membandingkan kinerja model yang dilatih menggunakan dua optimizer, Adam dan SGD.


Hasil penelitian ini diharapkan dapat memberikan kontribusi dalam bidang teknologi kecerdasan buatan sekaligus mendukung upaya pelestarian budaya melalui digitalisasi dan pengenalan otomatis motif batik Yogyakarta. Dengan adanya sistem klasifikasi berbasis transfer learning,

proses identifikasi motif batik dapat dilakukan lebih cepat, efisien, dan akurat, sehingga bermanfaat bagi pengembangan penelitian sejenis maupun industri kreatif.

II. LANDASAN TEORI

A. Convolutional Neural Network (CNN)

Menurut Goodfellow, Bengio, dan Courville (2016) Convolutional Neural Network (CNN) adalah salah satu arsitektur jaringan syaraf tiruan yang populer digunakan dalam pengolahan data citra. CNN merupakan salah satu arsitektur yang terinspirasi oleh cara kerja otak manusia dalam mengenali objek secara visual. CNN ini dirancang untuk mengenali pola spasial dan hubungan antar piksel dalam gambar melalui serangkaian lapisan konvolusi, pooling, dan fully connected. Arsitektur CNN dapat dilihat pada Gambar 1.



Gambar. 1. Arsitektur CNN

Berikut merupakan Struktur Dasar Arsitektur CNN yang terdiri dari beberapa jenis lapisan:

- 1) *Convolution layer*: *Convolution layer* merupakan lapisan inti dalam arsitektur CNN. Lapisan ini berfungsi untuk mengekstraksi fitur dari data input, seperti garis, tepi, pola tekstur atau bentuk melalui operasi konvolusi. Setiap lapisan konvolusi menerapkan sejumlah filter atau kernel yang bergerak melintasi gambar untuk menghasilkan sebuah feature map atau peta fitur.
- 2) *Activation Function Rectified Linear Unit (ReLU)*: Fungsi aktivasi Rectified Linear Unit atau ReLU ini digunakan untuk menghilangkan nilai negatif yang ada di feature map agar jaringan hanya mempertahankan nilai positif sebagai representasi fitur.
- 3) *Pooling Layer* : Pooling layer digunakan untuk mengurangi ukuran matriks dari lapisan konvolusi. Pooling memiliki dua jenis yaitu max pooling dan average pooling. Max pooling mengambil nilai maksimal dari setiap wilayah matriks fitur dari feature map, sementara average pooling mengambil nilai rata-ratanya dari feature map.
- 4) *Fully Connected Layer*: Lapisan ini yang menghubungkan setiap neuron dengan neuron di lapisan yang sebelumnya. Setelah melalui beberapa lapisan konvolusi dan pooling data fitur yang telah diekstraksi akan dimasukkan ke dalam fully connected layer untuk klasifikasi akhir. Lapisan ini yang berfungsi untuk mengkombinasikan semua fitur yang telah diekstrak dari lapisan sebelumnya untuk membuat sebuah keputusan klasifikasi. Lapisan ini terletak di akhir jaringan dan seringkali menggunakan fungsi

aktivasi seperti softmax untuk menghasilkan probabilitas dari kelas yang berbeda.

B. AlexNet


Arsitektur AlexNet terdiri dari delapan lapisan, yaitu lima lapisan konvolusi dan tiga lapisan fully connected. Setiap lapisan konvolusi menggunakan fungsi aktivasi ReLU untuk mempercepat pelatihan dan mengatasi masalah vanishing gradient, serta beberapa di antaranya diikuti dengan max pooling untuk mengurangi dimensi output dan meningkatkan ketahanan terhadap noise. Lapisan awal AlexNet menggunakan filter berukuran besar untuk menangkap fitur sederhana, sementara lapisan 3, 4, dan 5 menggunakan filter berukuran lebih kecil untuk mengenali fitur yang lebih halus dan kompleks. Bagian fully connected di akhir jaringan melanjutkan pengolahan informasi dan menghasilkan output melalui fungsi aktivasi softmax sebagai probabilitas kelas target. AlexNet menerima citra berukuran 224×224 piksel (RGB). Ukuran ini dipilih karena dapat mempercepat proses pelatihan tanpa menurunkan akurasi secara signifikan, sekaligus membantu mengurangi risiko overfitting.

C. Transfer Learning


Transfer learning metode yang memungkinkan model memanfaatkan pengetahuan yang telah diperoleh sebelumnya untuk diterapkan pada tugas baru yang memiliki kesamaan tertentu. Konsep utamanya adalah mengurangi kebutuhan pelatihan dari awal. Proses transfer learning umumnya dilakukan dengan dua pendekatan, yaitu fine-tuning, di mana bobot model yang telah dilatih pada dataset besar disesuaikan untuk dataset baru, serta feature extraction, di mana fitur dari model pra-latih digunakan sebagai representasi data input. Manfaat transfer learning antara lain mempercepat waktu pelatihan, meningkatkan akurasi pada dataset terbatas, dan memungkinkan generalisasi dengan memanfaatkan fitur kompleks yang telah dipelajari dari dataset besar seperti ImageNet.

D. Batik Yogyakarta


Batik Yogyakarta merupakan warisan budaya yang erat dengan sejarah dan tradisi Keraton Ngayogyakarta Hadiningrat. Batik ini digunakan dalam ritual keraton dan pakaian formal, serta mencerminkan filosofi dan nilai luhur masyarakat Yogyakarta. Dengan ciri khas warna coklat, hitam, dan putih, batik Yogyakarta tidak hanya menjadi pakaian formal, tetapi juga media ekspresi artistik yang terus mengalami modernisasi tanpa meninggalkan nilai tradisionalnya. Batik Yogyakarta memiliki beberapa motif khas. Motif Kawung berpola bulat atau elips menyerupai buah kawung atau bunga teratai, melambangkan persatuan, kesucian, dan keseimbangan dapat dilihat pada Gambar 2. Motif Truntum berupa pola bintang kecil atau bunga yang melambangkan cinta abadi dan ketulusan, sering dipakai dalam pernikahan dapat dilihat pada Gambar 3. Sedangkan motif Parang berupa pola diagonal menyerupai ombak atau parang, melambangkan perjuangan tanpa henti, kekuatan, dan keteguhan hati, serta dulunya hanya boleh digunakan kalangan istana dapat dilihat pada Gambar 4.



Gambar. 2. Batik Kawung



Gambar. 3. Batik Truntum



Gambar. 4. Batik Parang

III. METODE PENELITIAN

Tahapan dalam klasifikasi motif batik Yogyakarta ini mencakup persiapan dataset batik Yogyakarta (Kawung, Parang, Truntum), pra-pemrosesan data (preprocessing), augmentasi data, pembagian data (training, validation, testing), implementasi transfer learning dengan AlexNet pada berbagai skenario pembekuan layer, pengujian model, dan evaluasi hasil berdasarkan akurasi, loss, dan confusion matrix (presisi, recall, f1-score) yang akan dijabarkan sebagai berikut:

A. Dataset Batik Yogyakarta

Dataset citra batik Yogyakarta menjadi tiga kelas yaitu Kawung, Parang, dan Truntum. Data yang diperoleh ini dikumpulkan dari *Kaggle*, platform penjualan *online*, dan *google* untuk memperbanyak variasi. citra memiliki resolusi serta kondisi Cahaya yang beragam, dan disusun dalam folder sesuai kelas masing-masing.

B. Preprocessing Data

Preprocessing dilakukan untuk meningkatkan kualitas dan konsistensi dataset agar sesuai dengan format input AlexNet. Tahapan yang dilakukan yaitu perubahan nama file menjadi format numerik, penghapusan *background* atau bagian yang tidak relevan dengan pola batik, merubah ukuran citra menjadi 224 x 224 piksel agar sesuai ukuran input AlexNet, dan melakukan normalisasi menggunakan *mean* dan *standart deviation* dari dataset ImageNet dengan

mean [0.485, 0.456, 0.406] dan standart deviation [0.229, 0.224, 0.225]

C. Augmentasi Data

Augmentasi data yang dilakukan untuk memperbanyak jumlah data pelatihan. Proses augmentasi yang dilakukan yaitu *horizontal flip* dengan cara membalikkan gambar secara *horizontal* dengan probabilitas 50%, *random brightness contrast* dengan melakukan perubahan acak pada kecerahan dan kontras gambar dengan probabilitas 50%, *rotate* dengan cara rotasi gambar hingga 30 derajat dengan probabilitas 50%, dan *shift scale rotate* dengan dilakukan kombinasi pergeseran (*shift*), perubahan skala (*scale*), dan rotasi dengan batas pergeseran 10%, perubahan skala 10%, dan rotasi 15 derajat dengan probabilitas 50%.

D. Pembagian Data (Training, Validation, Testing)

Dataset dibagi menjadi tiga subset yaitu, pelatihan (*training*), validasi (*validation*), dan pengujian (*testing*). Pembagian data dilakukan untuk memastikan bahwa model yang dilatih memiliki performa yang baik. Pembagian data dengan proporsi 70% data pelatihan, 10% data validasi, dan 20% data pengujian.

E. Implementasi Transfer Learning dengan AlexNet

Model AlexNet dimodifikasi pada lapisan *fully connected* agar menghasilkan tiga *output* kelas dengan fungsi aktivasi *softmax*. Pendekatan *transfer learning* dilakukan dengan memanfaatkan bobot *pretrained* dari ImageNet dan menguji lima skenario pembekuan layer yaitu melatih semua layer, membekukan satu, dua, tiga, dan seluruh layer konvolusi. Setiap skenario dilatih selama 30 *epoch* menggunakan *optimizer* Adam dan SGD. Model terbaik dipilih berdasarkan nilai *loss* validasi terendah, dengan *input* citra berukuran 224 × 224 piksel.

F. Pengujian Model

Setelah pelatihan *transfer learning* pada tiap skenario, model diuji menggunakan data uji 15% dari total dataset yang tidak digunakan pada pelatihan maupun validasi untuk menilai kemampuan generalisasi. Model terbaik dari tiap skenario, berdasarkan *loss* validasi terendah, dievaluasi menggunakan metrik akurasi dan *loss*. Selain itu, *confusion matrix* dihitung dan divisualisasikan untuk memberikan gambaran detail mengenai prediksi benar maupun kesalahan klasifikasi pada setiap kelas.

G. Evaluasi Model

Evaluasi model dilakukan untuk membandingkan performa optimizer Adam dan SGD pada berbagai skenario pembekuan layer guna menemukan konfigurasi paling optimal dalam mengenali motif batik Yogyakarta. Evaluasi mencakup akurasi dan loss pada data latih, validasi, dan uji, serta visualisasi kurva akurasi dan loss untuk menilai stabilitas model tiap epoch. Model terbaik ditentukan dari nilai loss validasi terendah. Selain itu, confusion matrix digunakan untuk menganalisis kemampuan model membedakan tiap motif dan mengidentifikasi kesalahan klasifikasi. Metrik evaluasi yang dihitung meliputi akurasi, presisi, recall, dan F1-score. Akurasi mengukur proporsi prediksi benar, presisi menunjukkan ketepatan prediksi positif, recall menilai sensitivitas model terhadap kelas

positif, dan F1-score menggabungkan presisi serta recall untuk memberikan keseimbangan antara keduanya.

H. Hyperparameter

Pemilihan hyperparameter berperan penting agar model dapat belajar optimal dan melakukan generalisasi dengan baik. Pada penelitian ini digunakan learning rate 0.001 sesuai standar, dropout rate 0.5 untuk mencegah overfitting, serta hidden units sebanyak 512 yang dipilih agar sesuai dengan dataset terbatas. Model dilatih selama 30 epoch dengan batch size 16, yang dinilai seimbang untuk stabilitas dan kecepatan pelatihan. Dua optimizer digunakan, yaitu Adam yang efektif pada gradien bervariasi dan SGD dengan momentum yang memiliki generalisasi baik. Untuk mencegah overfitting, diterapkan early stopping dengan patience 5.

IV. HASIL DAN PEMBAHASAN

Bab ini menjelaskan implementasi metode penelitian dari pengumpulan dataset hingga evaluasi model. Dataset terdiri dari 1.110 citra batik Yogyakarta (Kawung, Parang, Truntum) yang dikumpulkan dari Kaggle, Google, dan situs penjualan online, kemudian dilakukan preprocessing (resize 224×224 piksel, konversi ke tensor, normalisasi) dan augmentasi (flip, brightness/contrast adjustment, rotation, shiftscalerotate). Data dibagi menjadi train (70%), validation (10%), dan test (20%). Model AlexNet dimodifikasi pada lapisan fully connected dengan variasi hidden units, dropout, serta perbandingan Max Pooling dan Average Pooling. Penelitian juga membandingkan optimizer Adam dan SGD pada lima skenario freeze layer (tanpa freeze, freeze 1–3, dan freeze all) dengan pelatihan 30 epoch menggunakan early stopping. Evaluasi dilakukan menggunakan akurasi, loss, confusion matrix, dan classification report (precision, recall, f1-score).

A. Dataset Citra Motif Batik Yogyakarta

Dataset yang digunakan pada penelitian ini batik Kawung, Parang, dan Truntum yang didapatkan dari berbagai platform yaitu Kaggle, google dan situs penjualan online yang dikumpulkan sendiri. Citra dataset batik Yogyakarta ini memiliki format JPG dengan resolusi yang berbeda-beda. Dataset batik Yogyakarta ini diklasifikasikan menjadi 3 kelas yaitu Kawung, Parang, dan Truntum yang disimpan di folder terpisah. Dalam pengumpulan dataset ini yang berhasil dikumpulkan berjumlah 1.110 citra untuk keseluruhan. Masing-masing kelas memiliki 370 citra.

B. Implementasi Preprocessing Data

Setelah melakukan pengumpulan dataset, selanjutnya yaitu *preprocessing* data. Tahap ini dilakukan untuk menyesuaikan format dan ukuran citra agar sesuai dengan kebutuhan AlexNet. Hal yang dilakukan yaitu *resize* dengan mengubah ukuran citra menjadi 224 x 224 piksel. Kemudian melakukan normalisasi menggunakan *mean* dan *standard deviation* dari dataset ImageNet yaitu dengan *mean* [0.485, 0.456, 0.406] dan *standard deviation* [0.229, 0.224, 0.225].

C. Augmentasi Data

Dataset terdiri dari tiga kelas (Kawung, Parang, Truntum) yang diperbanyak melalui augmentasi. Teknik

yang digunakan meliputi horizontal flip ($p=0,5$) untuk mengenali pola simetris, brightness & contrast adjustment ($p=0,5$) agar tahan terhadap perbedaan pencahayaan, rotasi (limit $\pm 30^\circ$) untuk mengenali objek meski miring, serta shift-scale-rotate (shift $\pm 10\%$, scale $\pm 10\%$, rotate $\pm 15^\circ$, $p=0,5$) untuk menambah variasi posisi dan ukuran objek. Augmentasi ini bertujuan meningkatkan keragaman citra sehingga model lebih robust terhadap variasi visual.

D. Pembagian Dataset (Splitting Data)

Setelah dilakukan proses augmentasi untuk memperkaya jumlah dan variasi citra batik, selanjutnya dilakukan proses membagi dataset menjadi tiga bagian utama, yaitu data pelatihan (training), data validasi (validation), dan data pengujian (testing). Tujuan dari pembagian ini adalah agar model dapat dilatih secara optimal dan dievaluasi secara objektif terhadap data yang belum pernah dilihat sebelumnya. Dataset dibagi training set menjadi 70%, validation set 10%, dan testing set 20% dari total gambar perkelas. Distribusi dataset dapat dilihat pada Tabel 1.

TABEL I
DISTRIBUSI DATASET

Kelas	Data Train	Data Validation	Data Test
Kawung	1036	148	296
Parang	1035	148	296
Truntum	1036	148	296

E. Implementasi Arsitektur Model AlexNet

Pada tahap ini, proses klasifikasi citra motif batik Yogyakarta dilakukan dengan mengimplementasikan arsitektur Convolutional Neural Network (CNN) menggunakan model AlexNet. AlexNet yang digunakan terdiri dari lima lapisan konvolusi (Convolutional Layer) dan tiga lapisan penuh (Fully Connected Layer). Penelitian ini dilakukan dengan pendekatan transfer learning dengan memanfaatkan bobot pre-trained dari ImageNet, kemudian dimodifikasi agar sesuai dengan kebutuhan klasifikasi motif batik Kawung, Parang, dan Truntum. Modifikasi yang dilakukan yaitu Pooling Layer, untuk mengetahui pengaruh metode pooling terhadap performa model, dilakukan penggantian lapisan pooling. Model diuji dengan Max Pooling (konfigurasi asli AlexNet) dan Average Pooling (hasil modifikasi), Lapisan Klasifikasi (Classifier), Bagian fully connected pada AlexNet dimodifikasi menjadi beberapa lapisan tambahan sehingga lebih dalam dan mampu mengekstraksi fitur secara lebih kompleks. Konfigurasinya adalah Linear(9216 → 4096) → ReLU → Dropout(0.5) → Linear(4096 → 2048) → ReLU → Dropout(0.5) → Linear(2048 → 512) → ReLU → Dropout(0.5) → Linear(512 → 10) → Dropout(0.5) → Linear(512 → 3). Dengan konfigurasi ini, model dapat menghasilkan output akhir berupa 3 kelas motif batik. Kemudian menggunakan Dropout dengan nilai 0.5 diterapkan pada setiap lapisan fully connected untuk mengurangi risiko

overfitting, dan pada Fungsi aktivasi ReLU digunakan pada setiap hidden layer agar model dapat mempelajari representasi non-linear dari data. Setelah itu penelitian dilakukan dengan membekukan (freeze) beberapa lapisan konvolusi awal AlexNet. Tujuan dari freeze ini untuk mempertahankan fitur umum dari ImageNet dan hanya melatih bagian akhir model agar lebih fokus pada ciri khas motif batik. Penelitian ini dilakukan dalam beberapa variasi yaitu Freeze 0 Layer semua lapisan dapat diperbaharui (trainable), model belajar dari awal seluruh parameter, Freeze 1 Layer satu lapisan konvolusi awal dibekukan, sisanya tetap dapat diperbaharui, Freeze 2 Layer dua lapisan konvolusi awal dibekukan, sisanya tetap dapat diperbaharui, Freeze 3 Layer tiga lapisan konvolusi awal dibekukan, sisanya tetap dapat diperbaharui, dan Freeze All Layer semua lapisan konvolusi dibekukan, jadi tidak ada yang bobotnya diperbaharui. Pada setiap variasi freeze, model dilatih menggunakan dua jenis optimizer untuk membandingkan performa. Optimizer yang digunakan yaitu Adam Optimizer dengan learning rate = 0.001 dan SGD Optimizer dengan learning_rate = 0.001, momentum = 0.9 memberikan hasil pelatihan lebih stabil. Ukuran input citra disesuaikan dengan standar AlexNet yaitu 224x224 piksel. Dataset yang digunakan telah melalui proses augmentasi dan preprocessing terlebih dahulu, serta dibagi menjadi train, validation, dan test. Proses pelatihan dilakukan maksimal selama 30 epoch dengan mekanisme early stopping jika dalam 5 epoch tidak ada peningkatan pada validation loss. Model terbaik ditentukan berdasarkan epoch dengan validation loss terendah dan disimpan untuk proses testing.

F. Proses Pelatihan Model

Proses pelatihan dilakukan menggunakan AlexNet yang dimodifikasi pada bagian classifier dengan penambahan dropout 0,5 dan hidden layer 512 unit, serta output layer disesuaikan untuk tiga kelas batik (Kawung, Parang, Truntum). Penelitian dilakukan dengan dua variasi pooling, yaitu Max Pooling (konfigurasi asli AlexNet) dan Average Pooling (modifikasi), serta beberapa skenario pembekuan lapisan konvolusi. Hyperparameter yang digunakan adalah learning rate 0,001, dropout 0,5, hidden units 512, epoch 30, dan patience early stopping 5. Pelatihan melibatkan forward propagation untuk menghasilkan prediksi dan menghitung loss menggunakan CrossEntropyLoss, kemudian backward propagation untuk memperbaiki bobot. Dua optimizer dibandingkan, yaitu Adam (adaptif dengan momentum dan penyesuaian learning rate) serta SGD ($\text{lr}=0,001$, $\text{momentum}=0,9$). Pada setiap epoch, akurasi dan loss untuk training serta validation dicatat, dengan model terbaik ditentukan berdasarkan validation loss terendah. Visualisasi training dan validation accuracy/loss ditampilkan dalam grafik dengan penanda best epoch. Early stopping digunakan untuk menghentikan pelatihan jika validation loss tidak menurun selama 5 epoch. Setelah selesai, model terbaik dari masing-masing konfigurasi pooling dan skenario freeze diuji menggunakan data test dengan evaluasi berupa confusion matrix, classification report, dan akurasi total.

G. Hasil Pengujian Model

Pada tahap ini, dilakukan serangkaian eksperimen tambahan untuk menguji pengaruh penggunaan jenis pooling (Average Pooling dan Max Pooling) serta perbedaan arsitektur classifier terhadap performa model AlexNet dalam klasifikasi motif Batik Yogyakarta. Eksperimen ini dibagi menjadi dua skenario utama yaitu pertama dilakukan penerapan Average Pooling dan Max Pooling pada arsitektur model. Selain itu, classifier AlexNet juga dimodifikasi dengan menambahkan beberapa lapisan fully connected baru. Struktur classifier yang digunakan adalah Linear(9216 $\rightarrow$ 4096) $\rightarrow$ ReLU $\rightarrow$ Dropout, Linear(4096 $\rightarrow$ 2048) $\rightarrow$ ReLU $\rightarrow$ Dropout, Linear(2048 $\rightarrow$ 512) $\rightarrow$ ReLU $\rightarrow$ Dropout, Linear(512 $\rightarrow$ 10) $\rightarrow$ ReLU $\rightarrow$ Dropout, Linear(10 $\rightarrow$ 3). Modifikasi ini bertujuan untuk memberikan representasi fitur yang lebih kaya serta meningkatkan kemampuan generalisasi model melalui penggunaan hidden layer tambahan. Kedua, dilakukan tanpa menggunakan Average Pooling dan Max Pooling Sebagai gantinya, model hanya menggunakan fitur standar AlexNet dengan classifier yang lebih sederhana. Struktur classifier pada skenario ini adalah Dropout, Linear(9216 $\rightarrow$ 4096) $\rightarrow$ ReLU $\rightarrow$ Dropout, Linear(4096 $\rightarrow$ 512) $\rightarrow$ ReLU, Linear(512 $\rightarrow$ 3). Pendekatan ini bertujuan untuk menguji seberapa besar perbedaan performa model jika pooling tidak diterapkan, serta untuk membandingkan efektivitas classifier sederhana terhadap classifier yang lebih kompleks. Dengan adanya dua pendekatan ini, diharapkan dapat diperoleh gambaran yang lebih komprehensif mengenai dampak pooling dan kompleksitas classifier terhadap hasil klasifikasi motif batik

H. Model AlexNet tanpa dilakukan Freeze Layer

Pada pengujian tanpa freeze (freeze 0), seluruh bobot AlexNet dilatih selama 30 epoch dengan early stopping menggunakan optimizer Adam dan SGD, serta variasi Average Pooling dan Max Pooling pada classifier. Evaluasi dilakukan pada data latih, validasi, dan uji dengan hasil terbaik diambil pada epoch dengan loss validasi terendah.

TABEL II
HASIL AKURASI DAN LOSS MODEL TANPA FREEZE LAYER

Optimizer	Train		Validation		Test	
	Accuracy	Loss	Accuracy	Loss	Accuracy	Loss
Adam	0.3396	1.1256	0.3333	1.0985	0.3333	1.0986
SGD	1.0000	0.0006	0.9910	0.0328	0.9944	0.0493

Model dengan optimizer Adam menunjukkan performa buruk dengan akurasi hanya 33,33% pada data latih, validasi, maupun uji, serta loss tinggi mencapai 1,1. Hasil classification report menunjukkan model hanya mengenali satu kelas (Truntum) dengan recall 1,00, sedangkan dua kelas lain gagal dikenali (precision dan recall 0,00). Sebaliknya, model dengan optimizer SGD menghasilkan performa sangat tinggi dengan akurasi 100% pada latih, 99,10% pada validasi, dan 99,44% pada uji, serta nilai precision, recall, dan f1-score mendekati 1,00 di semua kelas. Hal ini menunjukkan model mampu mengenali motif Kawung, Parang, dan Truntum dengan baik dan seimbang, meski akurasi latih 100% mengindikasikan potensi overfitting.

I. Model AlexNet dilakukan Freeze 1 Layer

Pada pengujian freeze 1, lapisan awal AlexNet dibekukan sehingga bobotnya tidak diperbarui, sementara lapisan lain tetap dilatih untuk memanfaatkan fitur dasar dari ImageNet. Model dilatih selama 30 epoch dengan early stopping menggunakan optimizer Adam dan SGD. Evaluasi dilakukan pada data train, validation, dan test, dengan hasil terbaik diambil pada epoch dengan loss validasi terendah.

TABEL III
HASIL AKURASI DAN LOSS MODEL FREEZE 1 LAYER

Optimizer	Train		Validation		Test	
	Accuracy	Loss	Accuracy	Loss	Accuracy	Loss
Adam	0.3328	1.0989	0.3382	1.0986	0.3304	1.0986
SGD	0.9968	0.0102	0.9964	0.0122	0.9944	0.0500

Pada pengujian freeze 1, model dengan optimizer Adam tetap menunjukkan performa buruk dengan akurasi hanya sekitar 33% pada train, validasi, dan test, serta loss tinggi (1.098). Model hanya mampu mengenali satu kelas (Parang) dengan recall 1.00, sedangkan Kawung dan Truntum gagal terklasifikasi. Sebaliknya, model dengan optimizer SGD mencapai performa sangat baik dengan akurasi 99.68% (train), 99.64% (validasi), dan 99.44% (test). Classification report menunjukkan precision, recall, dan f1-score mendekati 1.00 pada semua kelas, menandakan model mampu mengenali Kawung, Parang, dan Truntum secara akurat dan konsisten.

J. Model AlexNet dilakukan Freeze 2 Layer

Pada pengujian freeze 2, dua lapisan awal AlexNet dibekukan untuk mempertahankan fitur dasar dari ImageNet, sementara lapisan lainnya tetap dilatih. Model dilatih selama 30 epoch dengan early stopping menggunakan optimizer Adam dan SGD. Evaluasi dilakukan pada data train, validation, dan test, dengan hasil terbaik diambil pada epoch dengan loss validasi terendah.

TABEL IV
HASIL AKURASI DAN LOSS MODEL FREEZE 2 LAYER

Optimizer	Train		Validation		Test	
	Accuracy	Loss	Accuracy	Loss	Accuracy	Loss
Adam	0.3290	1.0989	0.3382	1.0986	0.3304	1.0986
SGD	1.0000	0.0009	0.9976	0.0082	0.9950	0.0082

Pada pengujian freeze 2, model dengan optimizer Adam tetap menunjukkan performa buruk dengan akurasi hanya 33% pada train, validasi, dan test, serta loss uji 1.0986. Model hanya mengenali satu kelas (Parang) dengan recall 1.00, sementara Kawung dan Truntum gagal terklasifikasi. Sebaliknya, model dengan optimizer SGD mencapai akurasi sangat tinggi yaitu 100% (train), 99.76% (validasi), dan 99.50% (test) dengan loss uji 0.0082. Classification report menunjukkan precision, recall, dan f1-score mendekati 1.00 pada semua kelas, menandakan model mampu mengenali Kawung, Parang, dan Truntum secara akurat dan seimbang.

K. Model AlexNet dilakukan Freeze 3 Layer

Pada pengujian freeze 3, tiga lapisan awal AlexNet dibekukan untuk mempertahankan fitur dasar dari ImageNet, sedangkan lapisan lain tetap dilatih agar menyesuaikan dengan motif batik Yogyakarta. Model dilatih selama 30 epoch dengan early stopping menggunakan optimizer Adam dan SGD. Evaluasi dilakukan pada data train, validation, dan test, dengan hasil terbaik ditentukan berdasarkan epoch dengan nilai loss validasi terendah.

TABEL V
HASIL AKURASI DAN LOSS MODEL FREEZE 3 LAYER

Optimizer	Train		Validation		Test	
	Accuracy	Loss	Accuracy	Loss	Accuracy	Loss
Adam	0.3220	1.0988	0.3382	1.0986	0.3304	1.0986
SGD	0.9998	0.0013	0.9964	0.0076	0.9962	0.0082

Pada pengujian freeze 3, model dengan optimizer Adam kembali menunjukkan performa buruk dengan akurasi sekitar 33% pada train, validasi, dan test, serta loss uji 1.0986. Model hanya mampu mengenali satu kelas (Parang) dengan recall 1.00, sementara Kawung dan Truntum tidak terklasifikasi. Sebaliknya, model dengan optimizer SGD mencapai akurasi tinggi, yaitu 99.98% (train), 99.64% (validasi), dan 99.62% (test) dengan loss uji 0.0082. Classification report menunjukkan precision, recall, dan f1-score mendekati 1.00 pada seluruh kelas, menandakan performa klasifikasi sangat akurat dan seimbang.

L. Model AlexNet dilakukan Freeze All Layer

Pada ada pengujian freeze all layer, seluruh bobot AlexNet dari ImageNet dibekukan sehingga hanya lapisan akhir yang dilatih ulang untuk data motif batik Yogyakarta. Model dilatih selama 30 epoch dengan early stopping menggunakan optimizer Adam dan SGD. Evaluasi hasil didasarkan pada best epoch dengan nilai loss validasi terendah.

TABEL VI
HASIL AKURASI DAN LOSS MODEL FREEZE ALL LAYER

Optimizer	Train		Validation		Test	
	Accuracy	Loss	Accuracy	Loss	Accuracy	Loss
Adam	0.9885	0.048	0.9867	0.0370	0.9875	0.0471
SGD	0.9818	0.0475	0.9843	0.0392	0.9862	0.0442

Hasil evaluasi model AlexNet dengan konfigurasi *freeze all layer*, di mana seluruh bobot convolutional dipertahankan dari pretraining ImageNet dan hanya lapisan classifier yang dilatih ulang, menunjukkan performa yang sangat baik. Model dengan optimizer Adam memperoleh akurasi pelatihan sebesar 98,85% dengan loss 0,0480, serta akurasi validasi 98,75% dengan loss 0,0471. Sementara itu, model dengan optimizer SGD mencapai akurasi pelatihan 98,18% dengan loss 0,0475, serta akurasi validasi 98,43% dengan loss 0,0392. Pada data uji, kedua optimizer memberikan hasil yang serupa dengan akurasi keseluruhan sebesar 98,62% dan loss 0,0442. Berdasarkan *classification report*, performa

model konsisten tinggi di seluruh kelas dengan nilai precision, recall, dan f1-score berada pada rentang 0,98 hingga 0,99. Untuk optimizer Adam, motif Kawung memiliki precision 0,99 dan recall 0,98, motif Parang precision 0,99 dan recall 0,98, sedangkan motif Truntum precision 0,98 dan recall 1,00. Hasil serupa juga ditunjukkan oleh optimizer SGD dengan precision dan recall 0,99 dan 0,98 pada Kawung serta Parang, serta precision 0,98 dan recall 0,99 pada Truntum. Secara keseluruhan, meskipun seluruh lapisan convolutional dibekukan, model tetap mampu mengklasifikasikan motif batik Kawung, Parang, dan Truntum dengan tingkat akurasi yang sangat tinggi dan stabil.

M. Model AlexNet tanpa dilakukan Freeze All Layer dengan Max Pooling dan Average Pooling

Pada pengujian freeze 0, seluruh bobot AlexNet dilatih ulang tanpa ada layer yang dibekukan. Proses pelatihan dilakukan selama 30 epoch dengan early stopping, menggunakan dua jenis optimizer yaitu Adam dan SGD. Selain itu, dilakukan dua skenario pooling, yakni Average Pooling dan Max Pooling, serta modifikasi pada lapisan classifier agar lebih beragam. Evaluasi dilakukan berdasarkan akurasi dan loss pada data pelatihan, validasi, dan uji, dengan nilai terbaik diambil dari best epoch berdasarkan loss validasi terendah.

TABEL VII
HASIL AKURASI DAN LOSS MODEL TANPA FREEZE LAYER DENGAN MENGGUNAKAN MAX POOLING DAN AVERAGE POOLING

Optimizer	Train		Validation		Test	
	Accuracy	Loss	Accuracy	Loss	Accuracy	Loss
Adam Max Pooling	0.3312	1.0992	0.3333	1.0985	0.3333	1.0985
SGD Max Pooling	0.9997	0.0023	0.9887	0.0415	0.9887	0.0415
Adam Average Pooling	0.3161	1.0992	0.3333	1.0985	0.3333	1.0985
SGD Average Pooling	0.9878	0.0364	0.9797	0.0729	0.9696	0.0729

Model AlexNet tanpa freeze layer menunjukkan perbedaan performa yang signifikan bergantung pada optimizer dan jenis pooling. Penggunaan optimizer Adam, baik dengan Max Pooling maupun Average Pooling, menghasilkan performa yang sangat buruk, dengan akurasi hanya sekitar 33% dan nilai loss tinggi di kisaran 1.09. Model hanya mampu mengenali satu kelas (Truntum) dengan recall 1.00 namun precision rendah (0.33), sedangkan kelas Kawung dan Parang sama sekali tidak terdeteksi. Hal ini mengindikasikan model gagal mempelajari pola data dan cenderung bias terhadap satu kelas saja. Sebaliknya, penggunaan optimizer SGD menunjukkan hasil yang jauh lebih baik. Dengan Max Pooling, model mencapai akurasi hampir sempurna yaitu 99.97% (training), 98.87% (validasi), dan 98.87% (uji) dengan nilai loss sangat rendah. Classification report menunjukkan performa tinggi dan seimbang di semua kelas, dengan precision, recall, dan f1-score berada di kisaran 0.97–1.00. Sementara itu, dengan Average Pooling, performa model sedikit menurun, dengan

akurasi 98.78% (training), 97.97% (validasi), dan 96.96% (uji). Meskipun lebih rendah dibanding Max Pooling, hasil ini tetap menunjukkan generalisasi yang baik, dengan precision, recall, dan f1-score ketiga kelas berada di kisaran 0.95–0.99. Secara keseluruhan, hasil pengujian membuktikan bahwa optimizer SGD, baik dengan Max Pooling maupun Average Pooling, mampu memberikan performa yang sangat baik dan stabil, sementara optimizer Adam gagal melakukan pembelajaran yang efektif.

N. Model AlexNet dilakukan Freeze 1 Layer dengan Max Pooling dan Average Pooling

Pada pengujian freeze 1 layer, bobot pada layer pertama AlexNet dibekukan sementara layer lainnya tetap dilatih untuk memanfaatkan fitur dasar dari ImageNet. Model dilatih selama 30 epoch dengan early stopping, menggunakan dua jenis optimizer (Adam dan SGD), serta variasi Max Pooling dan Average Pooling dengan classifier yang dimodifikasi. Evaluasi dilakukan pada data pelatihan, validasi, dan uji berdasarkan best epoch dengan nilai validation loss terendah.

TABEL VIII
HASIL AKURASI DAN LOSS MODEL FREEZE 1 LAYER DENGAN MENGGUNAKAN MAX POOLING DAN AVERAGE POOLING

Optimizer	Train		Validation		Test	
	Accuracy	Loss	Accuracy	Loss	Accuracy	Loss
Adam Max Pooling	0.3228	1.0988	0.3333	1.0986	0.3333	1.0986
SGD Max Pooling	0.9968	0.0080	0.9932	0.0310	0.9887	0.0321
Adam Average Pooling	0.3289	1.1124	0.3333	1.0985	0.3333	1.0986
SGD Average Pooling	0.9977	0.0098	0.9820	0.480	0.9809	0.0502

Max Hasil pengujian model AlexNet dengan satu layer awal dibekukan (freeze 1 layer) menunjukkan perbedaan signifikan antara penggunaan optimizer Adam dan SGD. Model dengan optimizer Adam, baik pada konfigurasi Max Pooling maupun Average Pooling, hanya mencapai akurasi sekitar 33% pada data uji dengan nilai loss tinggi di kisaran 1.098. Model ini cenderung hanya mengenali kelas Truntum dengan recall sempurna (1.00) tetapi precision rendah (0.33), sementara kelas Kawung dan Parang sama sekali tidak terdeteksi, sehingga kinerja keseluruhan sangat buruk dan bias terhadap satu kelas. Sebaliknya, penggunaan optimizer SGD menghasilkan performa yang sangat baik. Dengan Max Pooling, akurasi pada data uji mencapai 98.87%, sedangkan dengan Average Pooling mencapai 98.09%. Pada kedua konfigurasi, nilai precision, recall, dan f1-score untuk ketiga kelas (Kawung, Parang, Truntum) berada pada rentang 0.95–1.00, menunjukkan kemampuan model dalam mengenali seluruh kelas dengan akurat dan seimbang. Rata-rata makro dan tertimbang juga mendekati 0.99, membuktikan konsistensi prediksi tanpa bias terhadap kelas tertentu.

O. Model AlexNet dilakukan Freeze 2 Layer dengan Max Pooling dan Average Pooling

Pada pengujian freeze 2 layer, dua lapisan awal AlexNet dibekukan sehingga bobot pada kedua layer tersebut tidak diperbarui, sedangkan layer lainnya tetap dilatih untuk memanfaatkan fitur dasar dari ImageNet. Model dilatih selama 30 epoch dengan early stopping, menggunakan dua jenis optimizer (Adam dan SGD), serta variasi Max Pooling dan Average Pooling dengan classifier yang dimodifikasi. Evaluasi dilakukan pada data pelatihan, validasi, dan uji berdasarkan best epoch dengan nilai validation loss terendah.

TABEL IX
HASIL AKURASI DAN LOSS MODEL FREEZE 2 LAYER DENGAN MENGGUNAKAN MAX POOLING DAN AVERAGE POOLING

Optimizer	Train		Validation		Test	
	Accuracy	Loss	Accuracy	Loss	Accuracy	Loss
Adam Max Pooling	0.3219	1.0992	0.3333	1.0985	0.3333	1.0986
SGD Max Pooling	0.9971	0.0089	0.9910	0.0232	0.9899	0.0359
Adam Average Pooling	0.3344	1.0994	0.3333	1.0986	0.3333	1.0987
SGD Average Pooling	0.9952	0.0175	0.9887	0.0267	0.9887	0.0269

Hasil pengujian pada konfigurasi freeze 2 layer menunjukkan perbedaan signifikan antara penggunaan optimizer Adam dan SGD. Model dengan Adam, baik pada Max Pooling maupun Average Pooling, hanya mencapai akurasi 33,33% pada data training, validasi, dan testing, dengan loss uji tinggi (± 1.098). Classification report mengindikasikan model mengalami *class bias*, hanya mengenali motif Truntum (recall 1.00, f1-score 0.50) sementara motif Kawung dan Parang gagal terdeteksi (precision, recall, dan f1-score 0.00). Hal ini menunjukkan bahwa konfigurasi Adam menyebabkan *underfitting* dan ketidakmampuan model dalam melakukan generalisasi. Sebaliknya, penggunaan optimizer SGD menghasilkan performa yang sangat baik. Pada kombinasi Max Pooling, model mencapai akurasi training 99,71%, validasi 99,10%, dan testing 98,99%, dengan test loss rendah (0,0359). Sementara itu, dengan Average Pooling, akurasi training sebesar 99,52%, validasi 98,87%, dan testing 98,87% dengan test loss 0,0269. Classification report juga menunjukkan nilai precision, recall, dan f1-score mendekati 1.00 di semua kelas (Kawung, Parang, dan Truntum), dengan macro average dan weighted average stabil di 0.99. Hal ini membuktikan bahwa optimizer SGD mampu menghasilkan model yang akurat, stabil, dan seimbang dalam mengklasifikasikan ketiga motif batik.

P. Model AlexNet dilakukan Freeze 3 Layer dengan Max Pooling dan Average Pooling

Pada pengujian freeze 3 layer, tiga lapisan awal AlexNet dibekukan sehingga bobot pada kedua layer tersebut tidak diperbarui, sedangkan layer lainnya tetap dilatih untuk memanfaatkan fitur dasar dari ImageNet. Model dilatih selama 30 epoch dengan early stopping, menggunakan dua

jenis optimizer (Adam dan SGD), serta variasi Max Pooling dan Average Pooling dengan classifier yang dimodifikasi. Evaluasi dilakukan pada data pelatihan, validasi, dan uji berdasarkan best epoch dengan nilai validation loss terendah.

TABEL X
HASIL AKURASI DAN LOSS MODEL FREEZE 3 LAYER DENGAN MENGGUNAKAN MAX POOLING DAN AVERAGE POOLING

Optimizer	Train		Validation		Test	
	Accuracy	Loss	Accuracy	Loss	Accuracy	Loss
Adam Max Pooling	0.3241	1.0993	0.3333	1.0986	0.3333	1.0986
SGD Max Pooling	0.9900	0.0379	0.9775	0.0555	0.9831	0.0555
Adam Average Pooling	0.3177	1.0994	0.3333	1.0985	0.3333	1.0985
SGD Average Pooling	0.9990	0.0045	0.9932	0.0178	0.9910	0.0178

Evaluasi model AlexNet dengan freeze 3 layer menunjukkan perbedaan mencolok antara penggunaan optimizer Adam dan SGD. Model dengan Adam, baik pada Max Pooling maupun Average Pooling, hanya mencapai akurasi 33,33% pada data training, validasi, dan uji, dengan loss tinggi (± 1.098). Classification report mengindikasikan model hanya mampu mengenali kelas Truntum (recall 1.00, precision 0.33), sementara Kawung dan Parang tidak terdeteksi sama sekali. Kondisi ini menunjukkan model gagal melakukan pembelajaran yang efektif, karena bobot yang dibekukan terlalu banyak sehingga tidak dapat beradaptasi dengan baik terhadap data batik. Sebaliknya, penggunaan optimizer SGD menghasilkan performa yang sangat baik. Pada konfigurasi SGD + Max Pooling, akurasi training mencapai 99,00%, validasi 97,75%, dan uji 98,31%, dengan nilai precision, recall, dan f1-score seimbang di kisaran 0,98–0,99 untuk semua kelas. Hasil lebih optimal diperoleh pada konfigurasi SGD + Average Pooling, dengan akurasi training 99,90%, validasi 99,32%, dan uji 99,10%, serta nilai precision, recall, dan f1-score merata di 0,99 pada seluruh kelas. Temuan ini membuktikan bahwa kombinasi freeze 3 layer dengan optimizer SGD, khususnya pada Average Pooling, mampu menghasilkan performa terbaik dengan akurasi sangat tinggi dan loss yang sangat rendah, tanpa bias antar kelas.

Q. Model AlexNet dilakukan Freeze All Layer dengan Max Pooling dan Average Pooling

Pada skenario freeze all layer, seluruh bobot AlexNet dari hasil pretraining ImageNet dibekukan sehingga tidak diperbarui selama pelatihan. Hanya lapisan akhir yang dilatih ulang agar menyesuaikan dengan data motif batik Yogyakarta. Proses pelatihan dilakukan selama 30 epoch dengan early stopping, menggunakan dua jenis pooling (Average dan Max Pooling), serta memodifikasi classifier. Dua optimizer yang digunakan adalah Adam dan SGD.

TABEL XI
HASIL AKURASI DAN LOSS MODEL FREEZE 3 LAYER DENGAN
MENGUNAKAN MAX POOLING DAN AVERAGE POOLING

Optimizer	Train		Validation		Test	
	Accuracy	Loss	Accuracy	Loss	Accuracy	Loss
Adam Max Pooling	0.9520	0.1756	0.9414	0.1669	0.9448	0.1669
SGD Max Pooling	0.9836	0.0456	0.9550	0.1153	0.9606	0.1153
Adam Average Pooling	0.9685	0.1422	0.9572	0.1020	0.9550	0.1020
SGD Average Pooling	0.9752	0.0742	0.9752	0.0843	0.9561	0.0843

Pada kondisi *freeze all layer*, model AlexNet hanya melatih lapisan akhir dengan kombinasi optimizer Adam dan SGD serta dua metode pooling (Max Pooling dan Average Pooling). Hasil pengujian menunjukkan bahwa semua konfigurasi mampu mencapai performa tinggi, meskipun dengan variasi tingkat akurasi. Adam dengan Max Pooling menghasilkan akurasi uji 94,48% dengan distribusi performa antar kelas yang cukup baik, meski recall pada motif Truntum menurun (0,90). Adam dengan Average Pooling lebih stabil dengan akurasi uji 95,50%, ditandai dengan keseimbangan precision dan recall di ketiga kelas. SGD memberikan hasil yang lebih unggul. Dengan Max Pooling, akurasi uji mencapai 96,06% dan performa tinggi serta konsisten di semua kelas, tanpa penurunan recall signifikan. Konfigurasi SGD dengan Average Pooling juga menunjukkan akurasi tinggi (95,61%) dengan macro avg dan weighted avg sebesar 0,96, menandakan distribusi performa yang merata. Secara keseluruhan, penggunaan optimizer SGD terbukti lebih optimal dibandingkan Adam pada kondisi *freeze all layer*, khususnya dengan Max Pooling yang memberikan hasil terbaik.

V. KESIMPULAN

Berdasarkan penelitian yang telah dilakukan implementasi transfer learning pada AlexNet untuk klasifikasi motif batik Yogyakarta yaitu Kawung, Parang, dan Truntum dapat diambil kesimpulan sebagai berikut:

1) Kinerja Model AlexNet pada klasifikasi motif Batik Yogyakarta sangat baik. Implementasi transfer learning dengan arsitektur AlexNet mampu mengklasifikasikan tiga motif Batik Yogyakarta, yaitu Kawung, Parang, dan Truntum dengan tingkat akurasi yang sangat tinggi. Pada semua skenario, akurasi yang diperoleh selalu berada di atas 98%, menunjukkan bahwa AlexNet efektif dalam mengekstraksi ciri khas dari motif batik yang memiliki pola rumit dan detail yang kompleks

2) Optimizer Adam menunjukkan performa tinggi, tetapi kurang stabil dibandingkan SGD. Pada skenario ketika seluruh layer dasar model dibekukan (*freeze all layer*), Adam berhasil mencapai akurasi uji tertinggi sebesar 98,75%. Namun, kinerja Adam tidak selalu konsisten pada setiap skenario pelatihan. Nilai akurasi dan loss menunjukkan bahwa meskipun Adam mampu mencapai hasil yang baik,

optimizer ini tidak sekuat SGD dalam menjaga stabilitas performa model.

3) Optimizer SGD memberikan hasil terbaik dan paling konsisten. Optimizer SGD menghasilkan akurasi uji tertinggi mencapai 99,59% ketika dua dan tiga lapisan awal model dibekukan (*freeze 2 dan freeze 3 layer*). Hasil ini membuktikan bahwa SGD lebih unggul dibandingkan Adam, terutama dalam menjaga konsistensi hasil di berbagai konfigurasi. Selain itu, kombinasi pembekuan sebagian layer awal dengan SGD terbukti mampu memaksimalkan kemampuan model dalam mengenali motif batik.

4) Pooling layer memengaruhi kualitas generalisasi model. Perbedaan penggunaan Max Pooling dan Average Pooling memberikan dampak terhadap hasil model. Average Pooling yang dikombinasikan dengan SGD menghasilkan performa yang lebih stabil dibandingkan kombinasi lainnya. Hal ini menunjukkan bahwa pemilihan pooling layer yang sesuai dapat meningkatkan kemampuan model dalam melakukan generalisasi pada data uji.

5) Perbandingan Pooling (Max, Average, Tanpa Pooling dengan modifikasi classifier yang berbeda). Dengan Max Pooling maupun Average Pooling, akurasi model yang menggunakan SGD berada di kisaran 96–99%. Namun, hasil terbaik justru diperoleh tanpa pooling, di mana akurasi uji bisa mencapai lebih dari 99,5%. Performa Adam dengan pooling jauh lebih rendah (hanya 33%), sehingga pooling tidak mampu mengatasi kelemahan optimizer tersebut.

UCAPAN TERIMA KASIH

Penulis sangat berterimakasih kepada kedua dosen pembimbing yang dengan sabar dan meluangkan waktu untuk membimbing penulis. Penulis juga berterimakasih kepada keluarga penulis dan teman-teman yang selalu mendukung dan menyemangati penulis dalam mengerjakan tugas akhir ini.

DAFTAR PUSTAKA

- [1] I. Goodfellow, Y. Bengio, dan A. Courville, *Deep Learning*. Cambridge, MA: MIT Press, 2016.
- [2] S. Achjadi, *Batik: Motif dan Filosofi*. Yogyakarta: Penerbit Andi, 2001.
- [3] S. Achjadi, *Batik: Sejarah dan Perkembangannya*. Jakarta: Penerbit Kompas, 2010.
- [4] I. Aziz, *Ensiklopedia Batik Yogyakarta*. Yogyakarta: Penerbit LKi, 2010.
- [5] G. M. Darmokusumo, *Batik Yogyakarta dan Perjalanannya dari Masa ke Masa*. Yogyakarta: Penerbit LKi, 2015.
- [6] A. Kusrianto dan B. R. W. Rini, *Batik: Falsafah, Makna dan Kegunaan*. Yogyakarta: Penerbit Kanisius, 2013.
- [7] D. Meranggi, R. Santoso, dan N. Indriastuti, "Classification of batik motifs using convolutional neural networks," *J. Inf. Technol.*, vol. 13, no. 2, hal. 105–115, 2020.
- [8] D. Meranggi, A. Yulianto, dan F. Kharisma, "Klasifikasi motif batik menggunakan CNN dengan penerapan augmentasi data," *J. Informatika*, vol. 10, no. 2, hal. 45–54, 2020.
- [9] A. Priyanto dan S. Budiharjo, "Batik as a cultural heritage of Indonesia: Unique patterns and motifs," *Cultural Studies J.*, vol. 9, no. 1, hal. 45–60, 2021.
- [10] W. Rawat dan Z. Wang, "Deep convolutional neural networks for image classification: A comprehensive review," *Neural Comput. Appl.*, vol. 30, no. 2, hal. 325–338, 2017.
- [11] M. Shafique, A. Khan, dan M. Hussain, "AlexNet: A comprehensive review," *J. Comput. Sci. Technol.*, vol. 18, no. 3, hal. 275–290, 2018.

- [12] C. Shorten dan T. M. Khoshgoftaar, "A survey on image data augmentation for deep learning," *J. Big Data*, vol. 6, no. 1, hal. 1–48, 2019.
- [13] A. Surya dan I. Fikri, "Efficient classification of batik motifs using AlexNet," *Int. J. Comput. Appl.*, vol. 176, no. 12, hal. 24–31, 2020.
- [14] J. Yosinski, J. Clune, A. Nguyen, T. Fuchs, dan M. Hein, "Transfer learning via the selective fine-tuning of convolutional neural networks," dalam *Proc. IEEE Conf. Comput. Vis. Pattern Recognit.*, vol. 3, hal. 1120–1127, 2014.
- [15] A. Priyanto, H. Setyawan, dan A. Rahayu, "Penerapan AlexNet untuk klasifikasi motif batik menggunakan transfer learning," *J. Teknol. Inf.*, vol. 12, no. 1, hal. 10–20, 2021.
- [16] M. A. Shafique, H. K. Kwon, dan H. Kim, "AlexNet for image classification: A comprehensive review," *Int. J. Comput. Appl.*, vol. 180, no. 9, hal. 31–36, 2018.
- [17] M. Surya dan R. Dewi, "Efisiensi waktu pelatihan dan akurasi pada klasifikasi gambar menggunakan AlexNet," *J. Ilmiah Komput.*, vol. 15, no. 3, hal. 100–110, 2020.
- [18] J. Yosinski, J. Clune, A. Nguyen, T. Fuchs, dan H. Lipson, "Transfer learning by swapping neuron contributions," dalam *Adv. Neural Inf. Process. Syst.*, hal. 1–9, 2014.
- [19] R. A. Prasetyo dan S. Budiharjo, "Studi pola Batik Kawung: Pola geometris dalam karya seni," *J. Seni Rupa*, vol. 5, no. 2, hal. 90–95, 2017.
- [20] D. Rahmawati dan L. Indriastuti, "Karakteristik motif Batik Tambal: Antara tradisi dan modernitas," *J. Ilmu Budaya*, vol. 3, no. 1, hal. 35–45, 2019.
- [21] B. W. Santoso dan R. Wardhani, "Motif Batik Parang: Sejarah dan makna," *J. Pendidik. Seni*, vol. 8, no. 1, hal. 50–60, 2020.
- [22] N. Ardini dan A. Purnomo, "Motif Batik Truntum: Representasi keindahan dan simbolisme," *J. Desain Komunikasi Visual*, vol. 6, no. 1, hal. 25–35, 2021.