

## Klasifikasi Motif Batik Nitik Berbasis Fitur Ekstraksi SqueezeNet dengan Reduksi Dimensi PCA–LDA

Ratih Suciani\*, Usman Sudibyo

Fakultas Ilmu Komputer, Program Studi Teknik Informatika, Universitas Dian Nuswantoro, Semarang, Indonesia

Email: <sup>1,\*</sup>111202214558@mhs.dinus.ac.id, <sup>2</sup>usman.sudibyo@dsn.dinus.ac.id

Email Penulis Korespondensi: 111202214558@mhs.dinus.ac.id

Submitted: 22/02/2026; Accepted: 19/03/2026; Published: 19/03/2026

**Abstrak**—Klasifikasi motif batik nitik menghadapi tantangan signifikan karena tingginya variabilitas intra-class dan kompleksitas pola titik-titik geometris, serta keterbatasan jumlah sampel per kelas dalam dataset yang tersedia. Penelitian sebelumnya menggunakan metode ekstraksi fitur handcrafted seperti GLCM dan MTCO hanya mencapai akurasi 53%, sedangkan BSIF dengan augmentasi data mencapai 97.70%. Penelitian ini bertujuan mengembangkan metode klasifikasi batik nitik menggunakan ekstraksi fitur berbasis SqueezeNet (yang dilatih pada ImageNet) untuk mencapai akurasi superior tanpa penambahan teknik augmentasi data eksternal. Dataset Batik Nitik 960 yang terdiri dari 960 citra (60 kelas × 16 sampel) secara inheren mengandung keragaman visual alami tiap motif yang dikurasi oleh Minarno et al., sehingga deep feature extraction dari SqueezeNet dapat dioptimalkan tanpa augmentasi tambahan. Fitur berdimensi 1000 yang diekstraksi dari layer pool10 SqueezeNet kemudian melalui dimensionality reduction menggunakan PCA, LDA, atau PCA+LDA, dan diklasifikasikan dengan Random Forest, SVM, atau KNN. Ketiga classifier dipilih karena merepresentasikan paradigma pembelajaran yang berbeda: ensemble method (Random Forest), margin-based classifier (SVM), dan instance-based learning (KNN), sehingga perbandingan ketiganya memberikan analisis komprehensif terhadap karakteristik ruang fitur yang dihasilkan. Eksperimen dilakukan pada berbagai variasi jumlah data training (4-14 sampel per kelas). Hasil menunjukkan bahwa 8 dari 9 kombinasi model mencapai akurasi sempurna 100%, dengan kombinasi LDA+SVM, LDA+KNN, PCA+LDA+SVM, dan PCA+LDA+KNN hanya memerlukan 4 sampel training per kelas. Hanya LDA+Random Forest yang tidak mencapai 100% (maksimal 95.14%). Keunggulan metode ini terletak pada kemampuan deep feature extraction dari SqueezeNet yang jauh lebih diskriminatif dibanding handcrafted features, serta efisiensi supervised dimensionality reduction (LDA) dalam mengoptimalkan separabilitas kelas. Analisis inference time menunjukkan seluruh kombinasi model mampu melakukan prediksi dalam rentang 0,013–0,173 ms per citra, dan evaluasi stabilitas menggunakan 5 random state membuktikan konsistensi hasil dengan mean akurasi  $\geq 99,70\%$  pada 8 kombinasi (standar deviasi  $\leq 0,25\%$ ), mengkonfirmasi kelayakan implementasi real-time. Penelitian ini menetapkan state-of-the-art baru untuk dataset Batik Nitik 960 dan membuka peluang aplikasi praktis dalam autentikasi, quality control, dan preservasi warisan budaya batik Indonesia. Kontribusi utama penelitian ini mencakup penerapan SqueezeNet sebagai *fixed feature extractor* tanpa *fine-tuning* pada domain batik nitik yang belum pernah dieksplorasi sebelumnya, analisis komparatif komprehensif terhadap sembilan kombinasi *dimensionality reduction* dan *classifier*, serta penetapan *state-of-the-art* baru untuk dataset Batik Nitik 960 yang memvalidasi keunggulan *deep feature extraction* berbasis CNN dibanding metode *handcrafted* bahkan dengan data latih minimal empat sampel per kelas. Hasil penelitian membuka peluang implementasi praktis sistem identifikasi batik nitik berbasis *real-time* untuk keperluan autentikasi, *quality control*, dan pelestarian warisan budaya Indonesia

**Kata Kunci:** Klasifikasi Batik Nitik; SqueezeNet; Deep Feature Extraction; PCA-LDA; Linear Discriminant Analysis

**Abstract**—Batik nitik motif classification faces significant challenges due to high intra-class variability and complexity of geometric dot patterns, along with limited samples per class in available datasets. Previous research using handcrafted feature extraction methods such as GLCM and MTCO achieved only 53% accuracy, while BSIF with data augmentation reached 97.70%. This study aims to develop a batik nitik classification method using feature extraction based on SqueezeNet trained on ImageNet to achieve superior accuracy without additional external data augmentation techniques. The Batik Nitik 960 dataset consisting of 960 images (60 classes × 16 samples) inherently contains natural visual diversity for each motif as curated by Minarno et al., enabling deep feature extraction from SqueezeNet to be optimized without extra augmentation. A 1000-dimensional feature vector extracted from SqueezeNet's pool10 layer then underwent dimensionality reduction using PCA, LDA, or PCA+LDA, and was classified with Random Forest, SVM, or KNN. These three classifiers were selected to represent distinct learning paradigms: ensemble method (Random Forest), margin-based classifier (SVM), and instance-based learning (KNN), enabling a comprehensive analysis of the extracted feature space characteristics. Experiments were conducted across various training data sizes (4-14 samples per class). Results showed that 8 out of 9 model combinations achieved perfect 100% accuracy, with LDA+SVM, LDA+KNN, PCA+LDA+SVM, and PCA+LDA+KNN requiring only 4 training samples per class. Only LDA+Random Forest failed to reach 100% (maximum 95.14%). The method's advantages lie in the deep feature extraction capability of SqueezeNet, which produces far more discriminative representations than handcrafted features, combined with the efficiency of supervised dimensionality reduction (LDA) in optimizing class separability. Inference time analysis shows that all model combinations are capable of performing predictions within the range of 0.013–0.173 ms per image, and stability evaluation using 5 random states confirms result consistency with mean accuracy  $\geq 99.70\%$  across 8 combinations (standard deviation  $\leq 0.25\%$ ), confirming real-time implementation feasibility. This research establishes a new state-of-the-art for the Batik Nitik 960 dataset and opens opportunities for practical applications in authentication, quality control, and preservation of Indonesian batik cultural heritage. The primary contributions of this research encompass the application of SqueezeNet as a fixed feature extractor without fine-tuning for batik nitik classification a previously unexplored approach in this domain a comprehensive comparative analysis of nine dimensionality reduction and classifier combinations, and the establishment of a new state-of-the-art benchmark for the Batik Nitik 960 dataset, validating that CNN-based deep feature extraction surpasses handcrafted methods even with as few as four training samples per class. These findings pave the way for practical real-time batik identification systems applicable to authentication, quality control, and Indonesian cultural heritage preservation

**Keywords:** Batik Nitik Classification; SqueezeNet; Deep Feature Extraction; PCA-LDA; Linear Discriminant Analysis

## 1. PENDAHULUAN

Batik nitik adalah salah satu varian batik tradisional khas Yogyakarta yang dicirikan oleh susunan titik-titik geometris yang dikerjakan secara manual melalui teknik canting tulis. Tidak seperti motif batik figuratif atau floral, perbedaan antarmotif pada batik nitik hanya tampak dari variasi ukuran, jarak, dan orientasi titik-titik geometris pembentuknya, sehingga kemiripan antarkelas menjadi sangat tinggi. Kondisi inilah yang membuat klasifikasi otomatis batik nitik jauh lebih kompleks dibandingkan klasifikasi motif batik pada umumnya. Sebagai bagian dari warisan budaya Indonesia yang telah mendapat pengakuan UNESCO sejak tahun 2009, upaya preservasi digital batik nitik kian mendesak, terutama mengingat jumlah pengrajin yang menguasai teknik pembuatannya terus berkurang dari waktu ke waktu.

Tantangan dalam klasifikasi otomatis motif batik nitik bertumpu pada dua persoalan mendasar. Pertama, variabilitas intra-kelas yang cukup tinggi akibat perbedaan kondisi saat pengambilan citra, seperti intensitas pencahayaan, sudut pemotretan, dan kondisi fisik kain. Kedua, kemiripan antar-kelas yang sangat besar karena ke-60 motif dalam dataset Batik Nitik 960 berbagi struktur geometris dasar yang hampir serupa satu sama lain. Keterbatasan jumlah sampel per kelas yang hanya berjumlah 16 sampel semakin mempersulit penerapan metode berbasis pembelajaran yang pada umumnya membutuhkan data latih dalam jumlah besar. Situasi ini menuntut pendekatan yang mampu menghasilkan representasi fitur yang sangat diskriminatif meskipun bekerja pada dataset berskala kecil, sekaligus tidak bergantung pada teknik augmentasi data eksternal yang berpotensi memperpanjang pipeline dan meningkatkan beban komputasi secara keseluruhan.

Berbagai penelitian telah dilakukan untuk mengklasifikasi motif batik dengan memanfaatkan pendekatan *computer vision* dan *machine learning*. CNN telah terbukti efektif dalam domain ini: Wona et al. [1] berhasil mencapai akurasi 91,24% pada klasifikasi batik Indonesia, Hakim et al. [2] mendemonstrasikan efektivitas *deep learning* untuk batik regional Banyuwangi, dan Wahidah et al. [3] mengonfirmasi superioritas CNN dibanding metode tradisional dalam mengekstrak fitur hierarkis dari citra. Meski demikian, pendekatan CNN konvensional dengan pelatihan *end-to-end* memerlukan data latih dalam jumlah besar serta komputasi yang tinggi, sehingga kurang efisien untuk dataset dengan sampel terbatas seperti batik nitik. Kondisi ini mendorong eksplorasi pendekatan *deep feature extraction* menggunakan model CNN *pre-trained* sebagai *fixed feature extractor*, yang memungkinkan transfer pengetahuan visual dari dataset berskala besar ke domain target tanpa memerlukan pelatihan ulang pada keseluruhan jaringan.

Khusus untuk batik nitik, dataset Batik Nitik 960 yang dikembangkan oleh Minarno et al. [4] menjadi benchmark penting dalam penelitian klasifikasi motif batik nitik. Dataset ini berisi 960 citra dari 60 motif batik nitik berbeda, dengan setiap motif memiliki 16 variasi hasil rotasi. Dalam penelitian tersebut, metode ekstraksi fitur handcrafted seperti Gray Level Co-occurrence Matrix (GLCM) dan Multi Texton Co-Occurrence Descriptor (MTCO) hanya mencapai akurasi 53%, menunjukkan bahwa fitur tekstur statistik tingkat rendah tidak cukup untuk membedakan motif batik nitik yang sangat mirip. Penelitian terkini oleh Suprpto et al. [5] menggunakan metode Binarized Statistical Image Features (BSIF) sebagai ekstraksi fitur dengan Random Forest classifier pada dataset yang sama mencapai akurasi baseline 77,50% tanpa augmentasi data. Ketika dikombinasikan dengan teknik augmentasi flip, akurasi meningkat menjadi 97,70%, menunjukkan pentingnya augmentasi data dalam meningkatkan performa model. Meskipun hasil ini menunjukkan peningkatan signifikan, metode BSIF sebagai ekstraksi fitur handcrafted masih memiliki keterbatasan dalam menangkap pola hierarkis dan kompleksitas tekstur batik nitik secara optimal.

Perkembangan arsitektur CNN yang efisien dan pendekatan deep feature extraction telah membuka peluang baru dalam klasifikasi citra dengan dataset terbatas. Penelitian ekstraksi fitur menggunakan arsitektur VGG16 dan ResNet50 [6] membuktikan bahwa model CNN yang dilatih pada dataset besar dapat menghasilkan fitur yang efektif untuk tugas klasifikasi spesifik. Falakhi et al. [7] melakukan perbandingan model AlexNet dan ResNet dalam klasifikasi citra bunga memanfaatkan transfer learning, yang menunjukkan bahwa pemilihan arsitektur yang tepat sangat mempengaruhi hasil klasifikasi. Pendekatan deep feature extraction memungkinkan model CNN yang dilatih pada ImageNet digunakan sebagai *fixed feature extractor* bobot jaringan dibekukan dan output layer-nya dipakai sebagai representasi fitur citra domain target. Pendekatan ini sangat relevan untuk klasifikasi batik nitik mengingat keterbatasan jumlah data yang tersedia.

Salah satu arsitektur CNN yang menarik untuk dieksplorasi adalah SqueezeNet, yang dikembangkan oleh Iandola et al. untuk memberikan akurasi setara dengan AlexNet namun dengan jumlah parameter yang jauh lebih sedikit. SqueezeNet menggunakan fire modules yang terdiri dari squeeze layer dan expand layer untuk mengurangi dimensi fitur sambil tetap mempertahankan kemampuan representasi yang kuat. Arsitektur ini sangat cocok untuk aplikasi dengan keterbatasan komputasi dan memori, sekaligus memberikan performa klasifikasi yang kompetitif. Namun, hingga saat ini belum ada penelitian yang mengeksplorasi penggunaan SqueezeNet untuk klasifikasi motif batik nitik.

Berdasarkan analisis penelitian-penelitian terdahulu, terdapat gap penelitian yang signifikan dalam klasifikasi motif batik nitik. Pertama, penelitian eksisting masih menggunakan metode ekstraksi fitur handcrafted seperti BSIF dan GLCM yang memiliki keterbatasan dalam menangkap pola hierarkis dan kompleksitas tekstur batik nitik. Meskipun BSIF mencapai akurasi 77,50% dan dapat ditingkatkan hingga 97,70% dengan augmentasi [5], metode ini masih tidak optimal dalam automatic feature learning. Kedua, belum ada penelitian yang mengeksplorasi penggunaan CNN ringan seperti SqueezeNet sebagai *fixed feature extractor* pada Batik Nitik 960. Perlu dicatat bahwa dataset Batik Nitik 960 secara inheren mengandung 16 sampel per motif yang dikurasi oleh Minarno et al. untuk

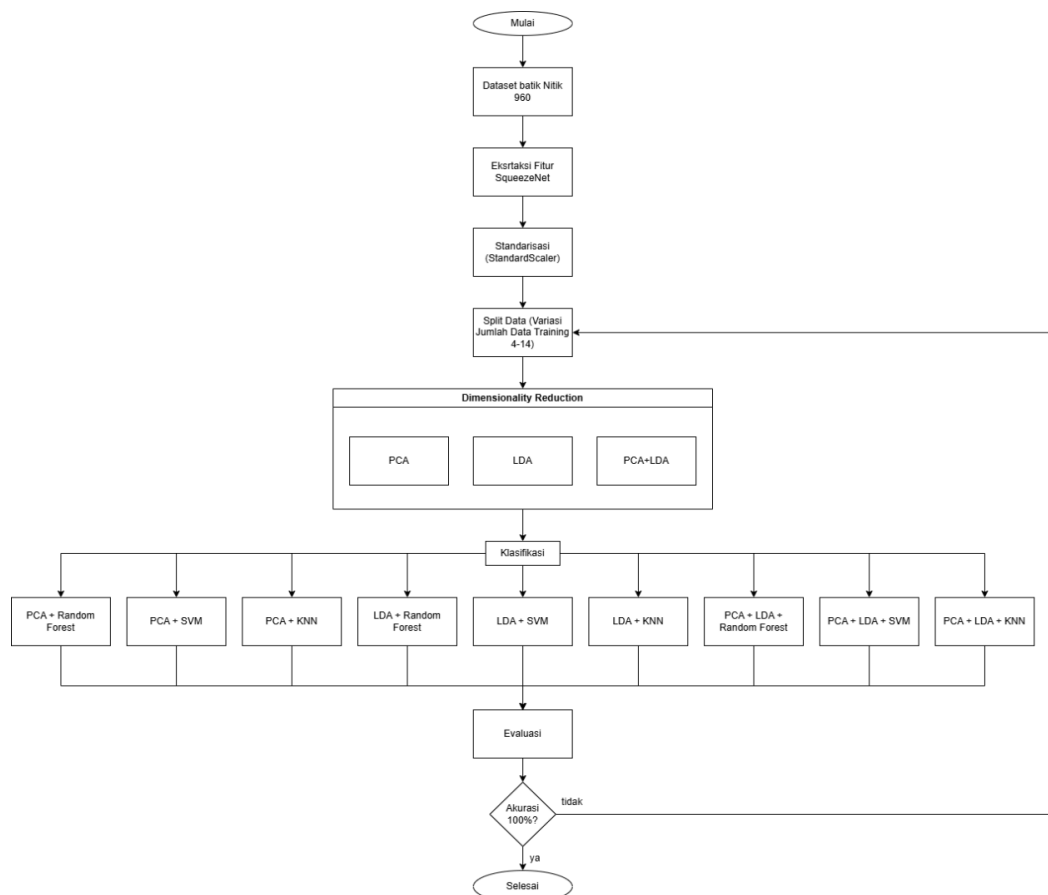
merepresentasikan keragaman visual alami tiap kelas. Deep features dari model pre-trained pada ImageNet berskala besar diharapkan mampu mengeksploitasi keragaman visual ini secara optimal, sehingga penambahan Teknik augmentasi data eksternal tidak diperlukan dan pipeline klasifikasi dapat disederhanakan. Berbagai classifier seperti Random Forest [8][9] dan SVM [10] telah terbukti efektif dikombinasikan dengan ekstraksi fitur CNN dalam domain klasifikasi citra, menjadikannya kandidat pembanding yang relevan dalam penelitian ini.

Penelitian ini bertujuan untuk mengembangkan metode klasifikasi motif batik nitik menggunakan ekstraksi fitur berbasis model SqueezeNet. Kontribusi utama penelitian ini terletak pada penerapan SqueezeNet sebagai *fixed feature extractor* tanpa *fine-tuning* untuk klasifikasi batik nitik, yang merupakan pendekatan baru yang belum pernah dieksplorasi sebelumnya dalam domain ini. Penelitian ini juga menyajikan analisis komparatif komprehensif terhadap sembilan kombinasi *dimensionality reduction* dan *classifier*, yang secara empiris membuktikan keunggulan *deep feature extraction* dibandingkan metode *handcrafted* pada dataset berskala kecil. Lebih jauh, penelitian ini mendemonstrasikan bahwa akurasi sempurna 100% dapat dicapai tanpa teknik augmentasi data eksternal dengan kebutuhan data latih minimal empat sampel per kelas, sehingga menjadikan metode ini efisien dan layak diterapkan pada kondisi dengan keterbatasan data. Hasil penelitian ini diharapkan dapat memberikan kontribusi dalam pelestarian warisan budaya batik Indonesia melalui sistem klasifikasi otomatis yang akurat dan efisien.

## 2. METODOLOGI PENELITIAN

### 2.1 Tahapan Penelitian

Penelitian ini dilakukan melalui serangkaian tahapan sistematis yang dirancang untuk mengklasifikasikan motif batik nitik menggunakan pendekatan ekstraksi fitur berbasis SqueezeNet yang dikombinasikan dengan metode *dimensionality reduction* dan *classifier machine learning*. Tahapan penelitian secara keseluruhan meliputi: (1) pengumpulan dataset, (2) ekstraksi fitur menggunakan SqueezeNet sebagai *fixed feature extractor*, (3) standarisasi, (4) split data dengan variasi jumlah training, (5) *dimensionality reduction* menggunakan PCA, LDA, atau PCA+LDA, (6) klasifikasi menggunakan Random Forest, SVM, atau KNN yang menghasilkan 9 kombinasi model, serta (7) evaluasi performa model. Alur keseluruhan proses penelitian ditunjukkan pada Gambar 1.



Gambar 1. Flowchart Tahapan Penelitian

Berdasarkan Gambar 1, proses dimulai dari dataset Batik Nitik 960 yang diekstrak fiturnya menggunakan SqueezeNet pada ImageNet menghasilkan 1000 fitur per citra. Fitur kemudian distandarisasi, lalu dibagi dengan variasi jumlah training 4–14 sampel per kelas. Setiap variasi melalui *dimensionality reduction* (PCA, LDA, atau

PCA+LDA) dan diklasifikasikan dengan tiga classifier, menghasilkan 9 kombinasi model. Eksperimen untuk setiap kombinasi model dihentikan ketika akurasi optimal pertama kali tercapai, dengan tujuan mengidentifikasi jumlah minimum sampel training yang sufficient untuk performa terbaik. Apabila akurasi optimal belum tercapai, proses dilanjutkan ke variasi training berikutnya hingga maksimum 14 sampel per kelas.

## 2.2 Dataset Batik Nitik

Dataset yang digunakan adalah Batik Nitik 960 yang dikembangkan oleh Minarno et al. [4][11], terdiri dari 960 citra batik nitik yang merepresentasikan 60 motif berbeda dengan 16 sampel per motif. Dataset ini bersifat balanced dimana setiap kelas memiliki jumlah sampel yang sama untuk menghindari bias dalam training dan evaluasi. Keenam belas sampel per motif merupakan karakteristik inheren dataset yang dikurasi oleh pembuatnya untuk merepresentasikan keragaman visual alami tiap motif, meliputi variasi kondisi pencahayaan, sudut pengambilan, dan kondisi kain. Keberagaman ini bukan merupakan hasil Teknik augmentasi yang ditambahkan oleh penelitian ini; klaim "tanpa augmentasi" dalam penelitian ini mengacu secara spesifik pada tidak digunakannya Teknik augmentasi eksternal seperti flip, rotation transform, brightness jitter, atau teknik sejenisnya dalam pipeline eksperimen. Karakteristik batik nitik yang memiliki motif titik-titik berulang dengan variasi ukuran dan orientasi menjadi tantangan dalam klasifikasi otomatis karena beberapa motif memiliki pola yang sangat mirip.



**Gambar 2.** Contoh Citra Dataset Batik Nitik 960 yang Menunjukkan Variasi Motif dari 60 Kelas

Gambar 2 menampilkan beberapa contoh citra dari dataset Batik Nitik 960. Terlihat bahwa setiap motif memiliki karakteristik titik-titik geometris yang khas namun dengan tingkat kemiripan antarmotif yang tinggi, sehingga metode ekstraksi fitur yang mampu menangkap pola hierarkis sangat diperlukan.

## 2.3 Fitur Ekstraksi (SqueezeNet)

SqueezeNet digunakan sebagai fixed feature extractor, di mana bobot jaringan tidak diperbarui (frozen). Fitur diekstraksi dari output layer pool10 (global average pooling layer) SqueezeNet, yaitu layer tepat sebelum classifier head (conv10 + softmax). Penggunaan layer pool10 bukan output softmax memastikan fitur yang diekstraksi merupakan representasi visual general yang belum terspesialisasi ke label kelas ImageNet, sehingga lebih transferable ke domain batik nitik. Ekstraksi fitur dilakukan menggunakan arsitektur SqueezeNet yang dilatih pada dataset ImageNet melalui software Orange Data Mining versi 3. SqueezeNet dipilih karena efisiensi parameter (~1.2M parameter) namun tetap mampu mengekstrak fitur diskriminatif yang telah terbukti efektif dalam berbagai aplikasi klasifikasi citra [12][13][14]. Pemanfaatan bobot SqueezeNet yang telah dilatih pada ImageNet (fixed/frozen) memungkinkan penggunaan representasi fitur low-level dan mid-level seperti edges, textures, dan patterns yang bersifat general dan terbukti relevan untuk domain batik nitik [13][14].

Proses ekstraksi dimulai dengan preprocessing otomatis yang dilakukan oleh Orange, meliputi resize citra ke 224×224 piksel sesuai input standar SqueezeNet, konversi format channel, dan normalisasi nilai piksel. Widget Image Embedding kemudian melakukan forward pass melalui network SqueezeNet dan mengambil output dari layer pool10 sebagai representasi fitur. Proses ini menghasilkan vektor fitur 1000 dimensi (n0-n999) untuk setiap citra yang merepresentasikan encoding high-level dari konten visual sebelum tahap keputusan klasifikasi. Pendekatan fixed feature extraction menggunakan SqueezeNet ini lebih efisien dibandingkan training CNN from scratch yang memerlukan dataset besar dan waktu komputasi tinggi [15][16]. Hasil ekstraksi fitur disimpan dalam format Excel untuk efisiensi, memungkinkan eksperimen klasifikasi dilakukan berulang tanpa perlu re-ekstraksi fitur [17].

## 2.4 Standardisasi

Fitur-fitur hasil ekstraksi SqueezeNet melalui proses standardisasi menggunakan StandardScaler untuk menormalisasi setiap fitur memiliki mean=0 dan standar deviasi=1. Standardisasi penting terutama untuk classifier seperti SVM dan KNN yang sensitif terhadap skala fitur [20][13]. StandardScaler di-fit hanya pada data training untuk menghindari data leakage, kemudian transformasi yang sama diterapkan pada data testing. Proses standardisasi memastikan bahwa setiap fitur memiliki kontribusi yang setara dalam perhitungan jarak maupun optimasi hyperplane.

## 2.5 Split Data Variasi Data Training

Pembagian data menggunakan stratified splitting untuk memastikan setiap kelas terwakili secara proporsional dalam training dan testing set. Penelitian ini menggunakan pendekatan variasi jumlah data training dari 4 hingga 14 sampel

per kelas untuk menganalisis pengaruh ukuran training set terhadap akurasi klasifikasi. Untuk setiap variasi, data dibagi menggunakan `sklearn.model_selection.train_test_split` dengan `random_state=42` untuk memastikan reproducibility dan konsistensi perbandingan antar kombinasi model. Penggunaan fixed random state merupakan praktik standar dalam penelitian benchmark yang bertujuan membandingkan performa antar model pada partisi data yang identik, sehingga perbedaan hasil murni mencerminkan perbedaan kemampuan model, bukan perbedaan partisi data. Untuk memvalidasi stabilitas hasil, dilakukan juga evaluasi tambahan menggunakan 5 random state berbeda [42, 0, 1, 7, 99] pada training size optimal tiap kombinasi, yang hasilnya dibahas pada Bagian 3.6. Misalnya, dengan 4 sampel training per kelas, terdapat 240 sampel ( $4 \times 60$  kelas) untuk training dan 720 sampel ( $12 \times 60$  kelas) untuk testing. Strategi variasi training size ini berbeda dari k-fold cross validation dan secara eksplisit dirancang untuk mengidentifikasi threshold minimum sampel training yang sufficient untuk mencapai akurasi optimal. Atas pertimbangan efisiensi komputasi dan fokus penelitian pada identifikasi threshold minimum tersebut, eksperimen untuk setiap kombinasi model dihentikan segera setelah akurasi optimal tercapai pada suatu variasi training size. Pendekatan ini memungkinkan identifikasi jumlah training minimum secara efisien, yang merupakan informasi praktis penting untuk aplikasi dengan keterbatasan data.

## 2.6 Dimensionality Reduction

Setelah standarisasi, dilakukan dimensionality reduction untuk mengurangi 1000 fitur hasil SqueezeNet sambil mempertahankan informasi diskriminatif, mengatasi curse of dimensionality, serta meningkatkan efisiensi komputasi. Tiga pendekatan dimensionality reduction dieksplorasi, yaitu PCA, LDA, dan kombinasi PCA+LDA. Ketiga pendekatan di-fit hanya pada training set, dan transformasi yang sama diterapkan pada training dan testing set untuk memastikan evaluasi yang fair.

### 2.6.1 Principal Component Analysis (PCA)

PCA adalah metode dimensionality reduction unsupervised yang mencari arah-arrah dengan variansi terbesar dalam data tanpa mempertimbangkan informasi label kelas [33]. PCA diimplementasikan dengan `n_components=60`, mereduksi 1000 fitur menjadi 60 komponen utama yang ortogonal dan diurutkan berdasarkan explained variance. PCA mencari eigenvector dari matriks kovarians yang didefinisikan sebagai:

$$S = \frac{1}{n} \sum_{i=1}^n (x_i - \mu)(x_i - \mu)^T \quad (1)$$

di mana  $n$  adalah jumlah sampel training,  $x_i$  adalah sampel ke- $i$ , dan  $\mu$  adalah mean keseluruhan data training. Eigenvector dan eigenvalue diperoleh dengan menyelesaikan masalah eigen:

$$Sw = \lambda w \quad (2)$$

di mana  $S$  adalah matriks kovarians,  $w$  adalah eigenvector (komponen utama), dan  $\lambda$  adalah eigenvalue yang merepresentasikan variansi yang dijelaskan oleh komponen tersebut. Proyeksi data ke ruang komponen utama dilakukan dengan:

$$y = W^T x \quad (3)$$

di mana  $W$  adalah matriks berukuran  $1000 \times 60$  yang kolom-kolomnya merupakan 60 eigenvector teratas, dan  $y$  adalah representasi data dalam ruang komponen utama [33].

### 2.6.2 Linear Discriminant Analysis (LDA)

LDA adalah metode dimensionality reduction supervised yang memaksimalkan separabilitas antar kelas dengan memanfaatkan informasi label [34]. LDA diimplementasikan dengan `n_components=59` ( $n\_classes - 1 = 60 - 1$ ), mencari proyeksi yang memaksimalkan rasio between-class scatter terhadap within-class scatter. Within-class scatter matrix ( $S_W$ ) mengukur sebaran data di dalam setiap kelas dan dihitung sebagai:

$$S_W = \sum_{c=1}^C \sum_{x_k \in c} (x_i - \mu_c)(x_i - \mu_c)^T \quad (4)$$

di mana  $C$  adalah jumlah kelas (60),  $\mu_c$  adalah vektor mean kelas  $c$ , dan  $x_i \in c$  menyatakan semua sampel yang termasuk dalam kelas  $c$ . Between-class scatter matrix ( $S_B$ ) mengukur sebaran mean antar kelas terhadap mean keseluruhan:

$$S_B = \sum_{c=1}^C n_c (\mu_c - \mu)(\mu_c - \mu)^T \quad (5)$$

di mana  $n_c$  adalah jumlah sampel pada kelas  $c$  dan  $\mu$  adalah mean keseluruhan data training. LDA mencari matriks proyeksi  $W^*$  yang memaksimalkan Fisher criterion:

$$W^* = \arg \max \frac{|W^T S_B W|}{|W^T S_W W|} \quad (6)$$

Solusi optimal diperoleh dengan menyelesaikan masalah eigen generalisasi:

$$S_W^{-1} S_B W = \lambda w \quad (7)$$

di mana eigenvector  $w$  yang bersesuaian dengan eigenvalue  $\lambda$  terbesar merupakan arah proyeksi yang paling diskriminatif antar kelas [34].

### 2.6.3 Kombinasi PCA + LDA

Penelitian ini juga mengeksplorasi kombinasi PCA+LDA dalam pipeline sekuensial di mana PCA (60 komponen) diterapkan terlebih dahulu untuk mengurangi dimensi dan noise, kemudian LDA (59 komponen) diterapkan pada hasil PCA untuk memaksimalkan separabilitas kelas [35]. Pendekatan ini mengatasi masalah singularity yang dapat terjadi pada LDA ketika jumlah dimensi jauh melebihi jumlah sampel, sekaligus memperoleh manfaat dari noise reduction PCA dan class discrimination LDA. Secara matematis, proyeksi akhir PCA+LDA dapat dituliskan sebagai  $y = W\_LDA^T (W\_PCA^T x)$ , di mana  $W\_PCA$  adalah matriks proyeksi PCA (1000×60) dan  $W\_LDA$  adalah matriks proyeksi LDA (60×59) yang diperoleh dari hasil PCA

## 2.7 Klasifikasi

Fitur hasil dimensionality reduction diklasifikasikan menggunakan tiga algoritma yang merepresentasikan paradigma pembelajaran berbeda: Random Forest, SVM, dan KNN. Kombinasi tiga metode dimensionality reduction dengan tiga classifier menghasilkan total 9 kombinasi model yang dievaluasi secara sistematis. Setiap classifier di-fit pada training set dan dievaluasi pada test set yang independen.

### 2.7.1 Random Forest

Random Forest adalah algoritma ensemble learning yang menggabungkan prediksi dari banyak decision trees untuk meningkatkan akurasi dan robustness [18][19][20][21]. Setiap tree dilatih pada subset data yang diambil secara random dengan replacement (bootstrap sampling), dan setiap split hanya mempertimbangkan subset random dari fitur. Prediksi akhir dilakukan dengan voting mayoritas dari semua trees.

$$\hat{y} = mode\{T_1(x), T_2(x), \dots, T_M(x)\} \quad (8)$$

di mana  $T_1(x), T_2(x), \dots, T_M(x)$  adalah prediksi label dari setiap decision tree pada input  $x$  [21]. Random Forest efektif untuk data berdimensi tinggi dan secara intrinsik melakukan feature selection pada setiap split [22]. Diimplementasikan menggunakan `sklearn.ensemble.RandomForestClassifier` dengan hyperparameter: `n_estimators=100`, `max_depth=20`, `min_samples_split=5`, `random_state=42`, dan `n_jobs=-1`.

### 2.7.2 SVM

SVM adalah algoritma supervised learning yang mencari hyperplane optimal untuk memaksimalkan margin antar kelas [22]. Untuk data non-linear, SVM menggunakan kernel trick untuk memetakan data ke ruang berdimensi lebih tinggi di mana data menjadi linearly separable. Formulasi optimasi primal SVM dengan slack variable  $\xi_i$  adalah:

$$min_{w,b} \frac{1}{2} \|w\|^2 + C \sum \xi_i \quad (9)$$

dengan constraint untuk setiap sampel training:

$$y_i(w^T \phi(x_i) + b) \geq 1 - \xi_i \quad (10)$$

di mana  $w$  adalah vektor bobot hyperplane,  $b$  adalah bias,  $C$  adalah parameter regularisasi yang mengontrol trade-off antara margin maksimal dan minimisasi error training,  $\phi(x_i)$  adalah fungsi pemetaan ke ruang dimensi tinggi, dan  $y_i \in \{-1, +1\}$  adalah label kelas [22]. Kernel RBF (Radial Basis Function) digunakan untuk menangani non-linearity dan didefinisikan sebagai:

$$K(x_i, x_j) = exp(-\gamma \|x_i - x_j\|^2) \quad (11)$$

di mana  $\gamma$  adalah parameter yang mengontrol lebar fungsi Gaussian. Kernel RBF dipilih karena fleksibilitasnya dalam menangkap decision boundary yang kompleks untuk klasifikasi multi-class. Diimplementasikan dengan parameter `C=10` dan `gamma="scale"`.

### 2.7.3 KNN

KNN adalah algoritma instance-based learning yang mengklasifikasikan sampel baru berdasarkan voting mayoritas dari  $K$  tetangga terdekatnya dalam ruang fitur [23]. Algoritma ini termasuk lazy learning karena tidak membangun model eksplisit selama training, melainkan menyimpan seluruh data training dan melakukan komputasi hanya pada saat prediksi. Prediksi label dilakukan dengan:

$$\hat{y} = mode\{y_i \mid x_i \in N_k(x)\} \quad (12)$$

di mana  $N_k(x)$  adalah himpunan  $K$  tetangga terdekat dari titik query  $x$ , dan  $y_i$  adalah label dari tetangga  $x_i$ . Kedekatan antar titik diukur menggunakan jarak Euclidean:

$$d(x_i, x_j) = \sqrt{\sum (x_i - x_j)^2} \quad (13)$$

di mana  $x_i$  dan  $x_j$  adalah dua titik data dalam ruang fitur [23]. Diimplementasikan menggunakan `sklearn.neighbors.KNeighborsClassifier` dengan `n_neighbors=5`, `weights="distance"` untuk memberikan bobot lebih besar kepada tetangga yang lebih dekat dalam voting, dan `metric="euclidean"`. KNN efektif untuk dataset dengan struktur well-clustered namun sensitif terhadap dimensi tinggi dan outlier [23].

### 2.7 Evaluasi

Evaluasi model menggunakan metrik accuracy yang dihitung dengan `sklearn.metrics.accuracy_score`, mengukur proporsi prediksi benar terhadap total prediksi. Confusion matrix dibuat menggunakan `sklearn.metrics.confusion_matrix` untuk menganalisis pola misclassification pada setiap kombinasi model. Untuk dataset balanced seperti Batik Nitik 960, accuracy sudah cukup representatif untuk mengukur performa keseluruhan model. Untuk setiap kombinasi dimensionality reduction dan classifier, disimpan confusion matrix pada kondisi akurasi terbaik yang dicapai. Hasil penelitian dibandingkan dengan state-of-the-art methods pada dataset yang sama: BSIF tanpa augmentasi (77.50%) dan BSIF dengan augmentasi flip (97.70%) , serta metode handcrafted features seperti GLCM dan MTCN yang hanya mencapai 53% [4]. Perbandingan ini memposisikan kontribusi penelitian dalam konteks penelitian sebelumnya dan menunjukkan keunggulan penggunaan SqueezeNet sebagai feature extractor dibandingkan metode handcrafted dan metode berbasis augmentasi data.

## 3. HASIL DAN PEMBAHASAN

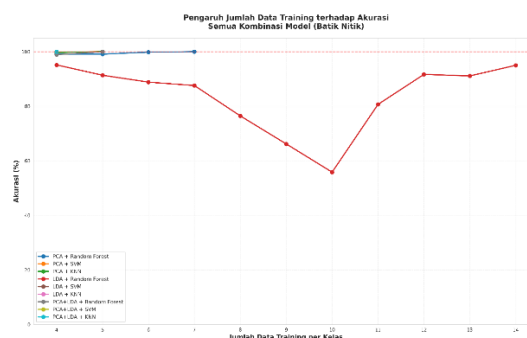
### 3.1 Hasil Klasifikasi dengan Variasi Data Training

Eksperimen dilakukan dengan memvariasikan jumlah data training dari 4 hingga 14 sampel per kelas. Setiap kombinasi dimensionality reduction (PCA, LDA, PCA+LDA) dengan classifier (Random Forest, SVM, KNN) dievaluasi secara sistematis, menghasilkan total 9 kombinasi model. Tabel 1 merangkum hasil akurasi terbaik untuk setiap kombinasi. Perlu dicatat bahwa akurasi yang dilaporkan merupakan akurasi pada test set yang sepenuhnya terpisah dari training set, dan nilai terbaik ini diperoleh pada jumlah training minimum yang pertama kali menghasilkan performa tersebut. Tingginya akurasi yang dicapai dapat diatribusikan pada kualitas representasi fitur SqueezeNet yang menghasilkan cluster fitur well-separated untuk 60 kelas batik nitik, sebagaimana dikonfirmasi oleh pola sebaran misclassification yang tidak terkonsentrasi pada pasangan kelas tertentu pada satu-satunya kombinasi yang tidak mencapai 100% (LDA + Random Forest)

**Tabel 1.** Ringkasan Hasil Akurasi Terbaik Semua Kombinasi

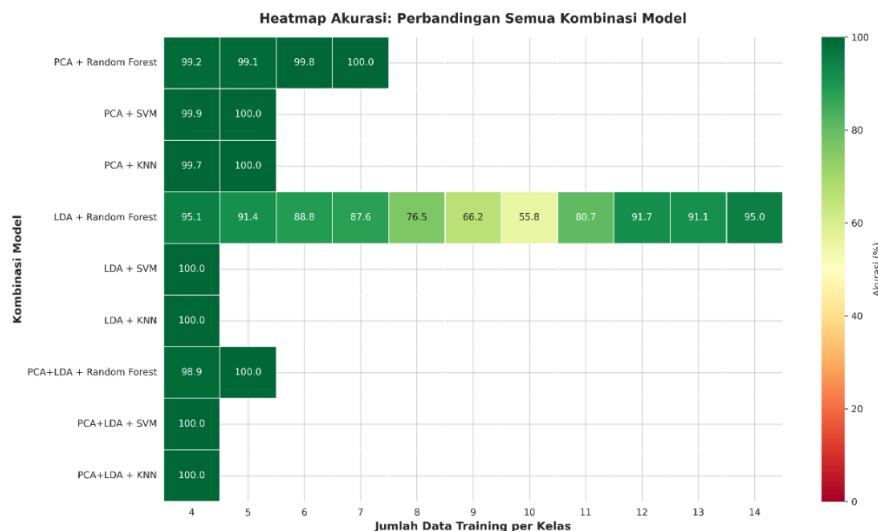
Kombinasi Model	Akurasi Terbaik (%)	Training per Kelas	Testing per Kelas	Total Training/Testing
PCA + Random Forest	100.00	7	9	420/540
PCA + SVM	100.00	5	11	300/660
PCA + KNN	100.00	5	11	300/660
LDA + Random Forest	95.14	4	12	240/720
LDA + SVM	100.00	4	12	240/720
LDA + KNN	100.00	4	12	240/720
PCA+LDA + Random Forest	100.00	5	11	300/660
PCA+LDA + SVM	100.00	4	12	240/720
PCA+LDA + KNN	100.00	4	12	240/720

Tabel 1 menunjukkan bahwa 8 dari 9 kombinasi mencapai akurasi 100%, dengan LDA + Random Forest sebagai satu-satunya kombinasi yang tidak mencapai akurasi maksimal. Kombinasi tercepat adalah LDA+SVM, LDA+KNN, PCA+LDA+SVM, dan PCA+LDA+KNN yang hanya memerlukan 4 sampel training per kelas (total 240 sampel), menunjukkan efisiensi tinggi dalam pemanfaatan data training terbatas.



**Gambar 3.** Perbandingan Akurasi Semua Kombinasi Model terhadap Jumlah Data Training per Kelas

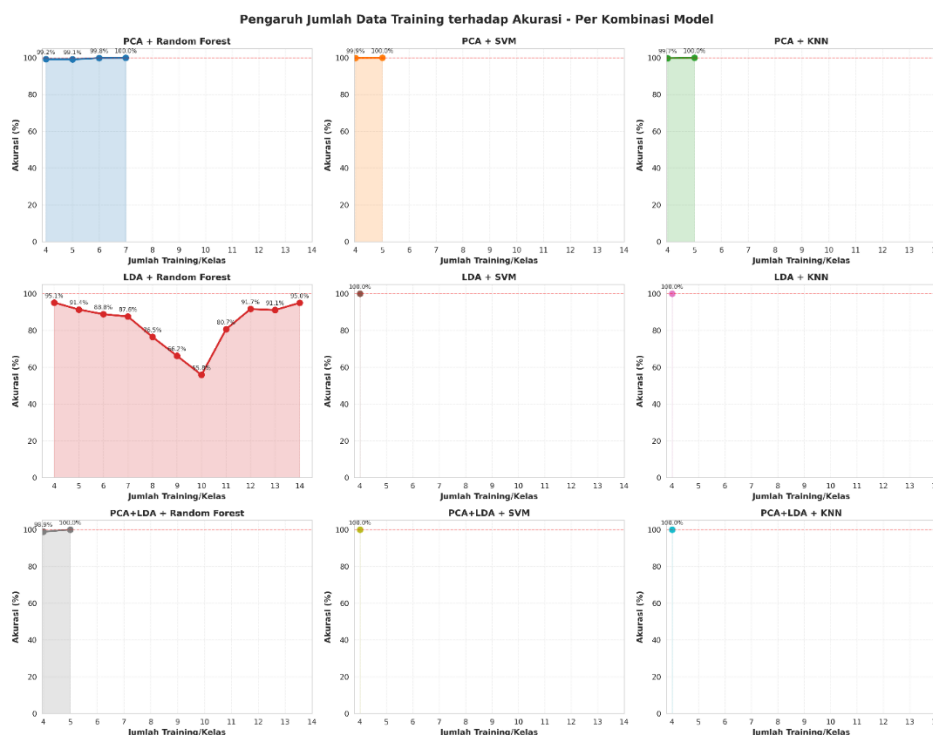
Gambar 3 menunjukkan perbandingan performa 9 kombinasi model pada berbagai variasi jumlah training data. Terlihat bahwa kombinasi PCA (biru, orange, hijau) dan PCA+LDA (abu-abu, kuning, cyan) menunjukkan trajectory stabil yang konvergen ke akurasi 100%. Sebaliknya, LDA + Random Forest (garis merah) menunjukkan fluktuasi signifikan dengan penurunan drastis dari 95.1% hingga 55.8% pada 10 training per kelas, kemudian meningkat kembali, mengindikasikan ketidakstabilan model dalam menangani variasi ukuran training set.



Gambar 4. Heatmap Akurasi: Perbandingan Semua Kombinasi Model

Gambar 4 menyajikan visualisasi heatmap yang memudahkan identifikasi pola performa model. Warna hijau pekat mengindikasikan akurasi tinggi (mendekati 100%), sedangkan warna kuning hingga merah menunjukkan akurasi lebih rendah. Terlihat jelas bahwa LDA + Random Forest (baris ke-4) memiliki pola warna bervariasi dengan beberapa area kuning-oranye pada training size 8-10, sementara kombinasi lainnya didominasi warna hijau pekat, mengkonfirmasi konsistensi performa tinggi.

Dari ketiga kelompok kombinasi, LDA+SVM dan LDA+KNN menjadi yang paling efisien dengan akurasi 100% hanya pada 4 sampel training per kelas, diikuti PCA+LDA+SVM dan PCA+LDA+KNN pada jumlah sampel yang sama. PCA+SVM dan PCA+KNN mencapai 100% pada 5 sampel, sedangkan PCA+Random Forest dan PCA+LDA+Random Forest memerlukan masing-masing 7 dan 5 sampel. Satu-satunya kombinasi yang tidak mencapai 100% adalah LDA+Random Forest (maksimal 95.14%), menunjukkan bahwa ensemble tree-based method memerlukan feature space dengan variabilitas lebih tinggi dibanding yang dihasilkan LDA standalone



Gambar 5. Grafik Akurasi Individual untuk Setiap Kombinasi Model

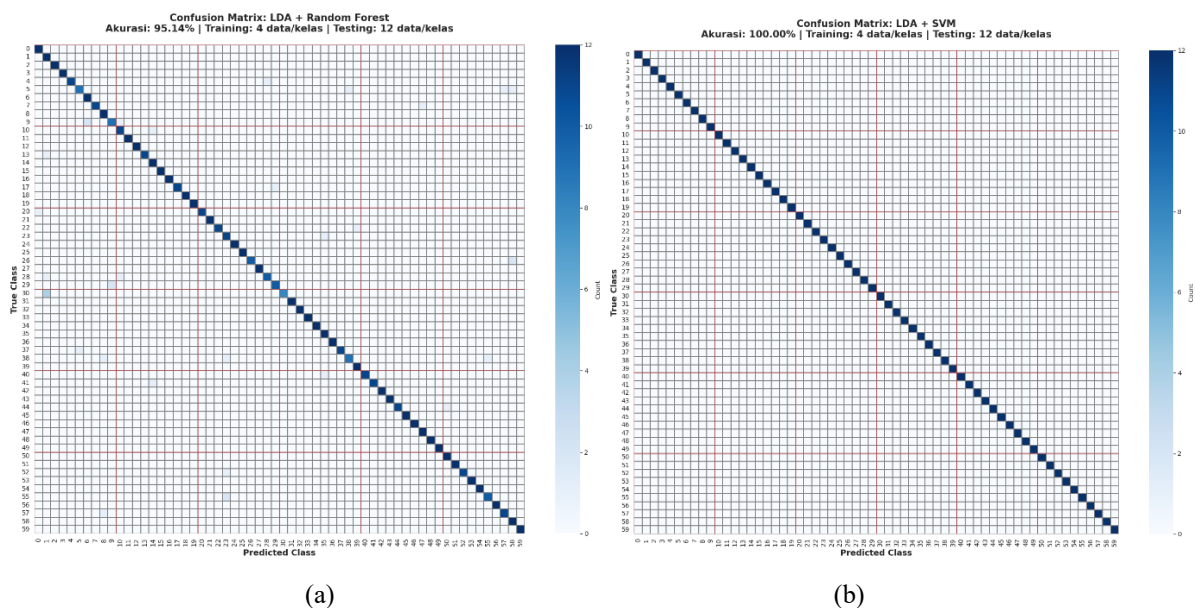
Gambar 5 menampilkan 9 subplot individual yang memudahkan analisis detail setiap kombinasi. Terlihat bahwa kombinasi PCA+SVM, PCA+KNN, LDA+SVM, LDA+KNN, PCA+LDA+SVM, dan PCA+LDA+KNN mencapai 100% dengan cepat dan stabil. PCA+Random Forest dan PCA+LDA+Random Forest menunjukkan konvergensi bertahap namun tetap mencapai 100%. LDA+Random Forest (subplot tengah kiri) menunjukkan pola U-shape yang khas dengan penurunan dan kenaikan akurasi, mengkonfirmasi ketidakstabilan model ini.

### 3.2 Analisis Perbandingan Model

Berdasarkan metode dimensionality reduction, PCA+LDA menawarkan trade-off optimal dengan akurasi 100% pada semua classifier (3/3) sambil mempertahankan efisiensi data 4–5 sampel per kelas. LDA menunjukkan efisiensi tertinggi (100% hanya dengan 4 sampel/kelas pada SVM dan KNN) namun konsistensinya lebih rendah (2/3 classifier). PCA memerlukan minimal 5 sampel namun konsisten pada 3/3 classifier. Berdasarkan classifier, SVM dan KNN secara konsisten mencapai 100% pada semua metode dimensionality reduction, sedangkan Random Forest memerlukan feature space dengan variabilitas lebih tinggi, terbukti dari performa inferiornya pada LDA standalone (95.14%).

#### 3.3.3 Analisis Confusion Matrix

Confusion matrix ditampilkan untuk dua kombinasi model yang merepresentasikan hasil kontras: satu kombinasi dengan akurasi 100% (LDA + SVM) sebagai representasi dari delapan kombinasi yang mencapai hasil sempurna, dan LDA + Random Forest (akurasi 95.14%) sebagai satu-satunya kombinasi yang tidak mencapai akurasi sempurna. Perbandingan kedua confusion matrix ini cukup untuk menggambarkan perbedaan pola klasifikasi antar kombinasi, mengingat delapan kombinasi yang mencapai 100% menunjukkan pola diagonal sempurna yang identik sehingga tidak perlu ditampilkan secara terpisah.



**Gambar 6.** Perbandingan Confusion Matrix: LDA + Random Forest (a) akurasi 95.14% dan LDA + SVM (b) akurasi 100.00% pada kondisi 4 data training per kelas dan 12 data testing per kelas

Gambar 6 menampilkan dua confusion matrix secara berdampingan. Gambar 6(a) merupakan hasil kombinasi LDA + Random Forest (akurasi 95.14%, 4 data training per kelas, 12 data testing per kelas), sedangkan Gambar 6(b) merupakan hasil kombinasi LDA + SVM (akurasi 100.00%, 4 data training per kelas, 12 data testing per kelas). Kedua kombinasi ini dipilih karena merepresentasikan kontras tertajam dalam seluruh hasil penelitian. Pada confusion matrix LDA + SVM (kanan), diagonal biru pekat yang seragam mengindikasikan klasifikasi sempurna tanpa confusion antar 60 kelas. Sebaliknya, pada confusion matrix LDA + Random Forest (kiri), terdapat beberapa off-diagonal entries yang tersebar di berbagai posisi (sekitar 35 dari 720 sampel test), bukan terkonsentrasi pada pasangan kelas tertentu. Pola sebaran ini mengindikasikan bahwa kesalahan klasifikasi bukan disebabkan oleh ambiguitas antara kelas-kelas spesifik, melainkan oleh keterbatasan arsitektur Random Forest dalam memanfaatkan ruang fitur LDA yang berdimensi rendah dan highly optimized. Delapan kombinasi lainnya yang mencapai akurasi 100% menunjukkan pola confusion matrix diagonal sempurna yang identik dengan LDA + SVM, sehingga tidak perlu ditampilkan secara terpisah.

### 3.4 Perbandingan dengan State-of-the-Art

Hasil penelitian menunjukkan peningkatan signifikan dibandingkan penelitian sebelumnya pada dataset Batik Nitik 960. Tabel 2 menyajikan perbandingan dengan state-of-the-art methods.

**Tabel 2.** Perbandingan dengan State-of-the-Art

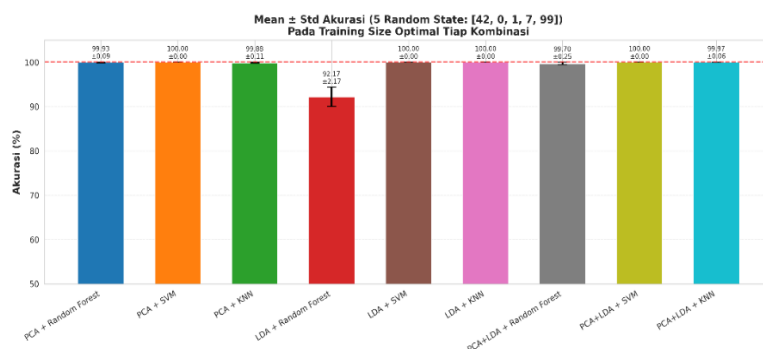
Penelitian	Metode	Akurasi (%)	Keterangan
Minarno et al. (2023)	GLCM + Classifier	53.00	Handcrafted texture
Minarno et al. (2023)	MTCD + Classifier	53.00	Multi-texton features
Suprpto et al. (2025)	BSIF + Random Forest	77.50	Without augmentation
Suprpto et al. (2025)	BSIF + RF + Flip Aug.	97.70	With flip augmentation
Penelitian ini (2026)	SqueezeNet + LDA + SVM	100.00	4 training/class, fixed feature extraction
Penelitian ini (2026)	SqueezeNet + Best 8 Comb.	100.00	8/9 combinations

Tabel 2 menunjukkan peningkatan signifikan dari metode sebelumnya. Minarno et al. [4] dengan handcrafted features (GLCM, MTCD) hanya mencapai 53%, mengindikasikan fitur tekstur statistik tidak cukup diskriminatif. Suprpto et al. [5] dengan BSIF mencapai 77.50% tanpa augmentasi dan 97.70% dengan flip augmentation. Metode yang diusulkan mencapai 100% tanpa augmentasi dengan 8 dari 9 kombinasi, menunjukkan keunggulan hierarchical features dari SqueezeNet dibandingkan handcrafted features. Efisiensi data training sangat tinggi (4-7 sampel per kelas) dibandingkan metode berbasis augmentasi.

Keunggulan metode diusulkan dapat diatribusikan kepada: (1) SqueezeNet yang dilatih pada ImageNet menghasilkan deep features yang jauh lebih kaya dan diskriminatif dibandingkan handcrafted features, (2) kombinasi optimal dimensionality reduction dan classifier memungkinkan pemanfaatan efisien fitur yang diekstraksi, dan (3) supervised dimensionality reduction (LDA) mengoptimalkan separabilitas kelas. Implikasi praktis mencakup kelayakan untuk aplikasi autentikasi batik, quality control produksi, dan automated cataloging dengan requirement training data minimal (4 sampel per kelas)

### 3.5 Analisis Stabilitas Model

Untuk memvalidasi bahwa hasil akurasi tinggi bukan merupakan artefak dari satu partisi data tertentu, dilakukan evaluasi menggunakan 5 random state berbeda [42, 0, 1, 7, 99] pada training size optimal tiap kombinasi.



**Gambar 7.** Statistical Analysis mean std

Gambar 7 menunjukkan hasil Mean ± Std akurasi dari kelima random state tersebut. Delapan kombinasi model mencapai mean akurasi  $\geq 99,70\%$  dengan standar deviasi sangat kecil ( $\leq 0,25\%$ ), bahkan empat kombinasi (PCA+SVM, LDA+SVM, LDA+KNN, PCA+LDA+SVM) mencapai mean=100,00%  $\pm$  0,00%, membuktikan bahwa hasil akurasi bersifat stabil dan konsisten lintas partisi data. Satu-satunya pengecualian tetap LDA+Random Forest dengan mean 92,17%  $\pm$  2,17%, mengkonfirmasi bahwa ketidakstabilannya bukan disebabkan oleh bias satu random state, melainkan memang merupakan karakteristik inheren kombinasi tersebut

### 3.6 Analisis Inference Time

Seluruh kombinasi model diukur inference time-nya per citra pada kondisi akurasi terbaik masing-masing. Tabel 3 menyajikan hasil pengukuran tersebut.

**Tabel 3.** Inference Time

Kombinasi Model	Inference Time per Citra (ms)
LDA + KNN	0,0130
PCA + KNN	0,0326
PCA+LDA + KNN	0,0271
PCA+LDA + Random Forest	0,0690
LDA + SVM	0,0761
PCA+LDA + SVM	0,0978
PCA + Random Forest	0,1424
PCA + SVM	0,1620
LDA + Random Forest	0,1727

Berdasarkan Tabel 3, seluruh kombinasi model mampu melakukan inferensi dalam rentang 0,013 ms hingga 0,173 ms per citra, jauh di bawah ambang batas kelayakan real-time. Kombinasi tercepat adalah LDA+KNN (0,013 ms), sedangkan kombinasi dengan pipeline lengkap PCA+LDA+KNN mencapai 0,027 ms. Bahkan kombinasi terlambat, yaitu LDA+Random Forest (0,173 ms), tetap memenuhi syarat kecepatan untuk aplikasi praktis. Hasil ini mengkonfirmasi bahwa seluruh pipeline SqueezeNet+reduksi dimensi+classifier layak diimplementasikan dalam skenario autentikasi batik real-time.

Meski demikian, penelitian ini masih memiliki satu keterbatasan yang perlu diakui: seluruh eksperimen dilakukan pada dataset benchmark yang dikumpulkan dalam kondisi terkontrol, sehingga performa pada kondisi real-world dengan variasi pencahayaan ekstrem, oklusi parsial, atau kualitas citra rendah belum divalidasi. Hal ini menjadi arah konkret untuk penelitian lanjutan

### 3.5 Pembahasan

Hasil eksperimen menunjukkan pendekatan fixed feature extraction menggunakan SqueezeNet, di mana bobot jaringan dibekukan dan output-nya digunakan langsung sebagai vektor fitur mampu mencapai performa klasifikasi sempurna pada dataset Batik Nitik 960. SqueezeNet yang dilatih pada ImageNet berhasil mengekstrak fitur highly discriminative meskipun domain batik nitik berbeda dari object recognition membuktikan bahwa generalisasi fitur CNN bersifat lintas domain. Low-level dan mid-level features seperti edge detectors dan texture patterns yang dipelajari pada dataset general dapat diaplikasikan secara efektif ke domain klasifikasi batik nitik. Fire modules dalam SqueezeNet efektif mengompresi informasi visual sambil mempertahankan representational power, menghasilkan 1000 fitur yang cukup untuk membedakan 60 kelas motif.

Performa superior LDA dan PCA+LDA mengkonfirmasi pentingnya supervised dimensionality reduction untuk classification tasks. LDA dengan explicitly maximizing between-class to within-class scatter ratio menghasilkan proyeksi optimal untuk separability, memungkinkan SVM dan KNN melakukan decision dengan minimal training samples. PCA tetap valuable sebagai preprocessing dalam PCA+LDA pipeline untuk noise reduction dan menghindari singularity issues. Perbedaan performa antar classifier memberikan insight bahwa SVM dan KNN lebih cocok untuk ruang fitur hasil dimensionality reduction, sedangkan Random Forest memerlukan feature space dengan sufficient variability untuk feature subsampling.

Perfect classification pada 8 kombinasi menunjukkan tidak ada systematic confusion antar specific class pairs, mengindikasikan semua 60 motif memiliki distinguishable visual characteristics. Spread pattern of misclassifications pada LDA + Random Forest mengkonfirmasi issue terletak pada model limitation rather than class ambiguity. Kontribusi penelitian ini mencakup demonstrasi efektivitas *deep feature extraction* berbasis CNN dari domain umum ke domain budaya, khususnya batik nitik, yang membuktikan bahwa generalisasi fitur visual bersifat lintas domain secara efektif. Analisis komparatif yang komprehensif terhadap sembilan kombinasi model *dimensionality reduction* dan *classifier* memberikan wawasan mendalam mengenai karakteristik ruang fitur yang dihasilkan SqueezeNet. Penelitian ini sekaligus menetapkan *state-of-the-art* baru untuk dataset Batik Nitik 960 dan memvalidasi bahwa *fixed feature extraction* berbasis CNN unggul secara signifikan dibandingkan *handcrafted features* bahkan dalam kondisi data latih yang sangat terbatas, sehingga relevan untuk diterapkan dalam sistem autentikasi dan preservasi warisan budaya.

## 4. KESIMPULAN

Penelitian ini berhasil mengembangkan metode klasifikasi motif batik nitik menggunakan ekstraksi fitur berbasis SqueezeNet yang dikombinasikan dengan dimensionality reduction (PCA, LDA, atau PCA+LDA) dan tiga classifier (Random Forest, SVM, KNN). Dari 9 kombinasi yang dievaluasi secara sistematis, 8 kombinasi mencapai akurasi 100% pada test set dataset Batik Nitik 960, dengan kombinasi paling efisien (LDA+SVM, LDA+KNN, PCA+LDA+SVM, PCA+LDA+KNN) hanya memerlukan 4 sampel training per kelas tanpa penambahan teknik augmentasi data eksternal. Hasil ini melampaui state-of-the-art sebelumnya secara signifikan (GLCM/MTC: 53%, BSIF tanpa augmentasi: 77.50%, BSIF dengan augmentasi flip: 97.70%). Metode ini menggunakan SqueezeNet sebagai fixed feature extractor tanpa fine-tuning, sehingga tidak memerlukan komputasi pelatihan ulang jaringan dan tetap feasible pada lingkungan dengan sumber daya komputasi terbatas. Tingginya akurasi yang dicapai pada benchmark ini dapat dikaitkan dengan kemampuan representasi deep features SqueezeNet yang dilatih pada ImageNet dalam menghasilkan cluster fitur yang well-separated untuk 60 kelas batik nitik, bahkan tanpa fine-tuning domain-specific. Hal ini menunjukkan bahwa generalisasi fitur CNN lintas domain dari object recognition ke domain budaya tekstil bersifat efektif untuk dataset yang memiliki struktur visual well-defined. Namun perlu ditekankan bahwa evaluasi dilakukan pada dataset benchmark terkontrol dengan fixed partisi data, sehingga hasil ini mencerminkan performa dalam kondisi ideal. Validasi pada kondisi real-world dengan variasi kualitas citra yang lebih luas tetap diperlukan sebelum deployment praktis. Penelitian selanjutnya disarankan untuk: (1) menguji robustness metode pada citra dengan kondisi real-world seperti pencahayaan rendah, blur, dan oklusi parsial; (2) mengeksplorasi arsitektur CNN yang lebih modern seperti EfficientNet, MobileNetV3, atau Vision Transformer sebagai alternatif feature extractor; dan (3) mengembangkan sistem end-to-end berbasis mobile atau web untuk mendukung praktisi batik,

kollektor, dan museum dalam identifikasi dan dokumentasi motif batik nitik sebagai bagian dari preservasi warisan budaya Indonesia.

## REFERENCES

- [1] M. M. A. Wona *et al.*, “Klasifikasi Batik Indonesia Menggunakan Convolutional Neural Network ( CNN ),” *J. REKAYASA Teknol. Inf.*, vol. 7, no. 2, pp. 172–179, 2023, doi: <http://dx.doi.org/10.30872/jurti.v7i2.13694>.
- [2] D. Y. Lutfi Hakim, Hadi Rizaldi Rahmanto, Sepyan Purnama Kristanto, “Klasifikasi Citra Motif Batik Banyuwangi Menggunakan Convolutional Neural Network,” *J. TEKNOINFO*, vol. 17, pp. 203–211, 2023, doi: <https://doi.org/10.33365/jti.v17i1.2342>.
- [3] T. A. Ida Wahidah, Hadian Mandala Putra, Suhartini, “Analisa Komparatif Klasifikasi Citra Sayuran dengan Algoritma Support Vector Machine dan Convolutional Neural Network Ida,” *Infotek J. Inform. dan Teknol.*, vol. 9, no. 1, pp. 12–23, 2026, doi: <https://dx.doi.org/10.29408/jit.v9i1.32791>.
- [4] A. E. Minarno and H. A. Nugroho, Indah Soesanti, “Batik Nitik 960 Dataset for Classification, Retrieval, and Generator,” *DATA*, vol. 8, pp. 1–10, 2023, doi: <https://doi.org/10.3390/data8040063>.
- [5] A. R. M. Suprpto, Meilany Nonsi Tentua, “Optimizing nitik batik classification through comparative analysis of image augmentation,” *IAES Int. J. Artif. Intell.*, vol. 14, no. 5, pp. 3970–3981, 2025, doi: [10.11591/ijai.v14.i5.pp3970-3981](https://doi.org/10.11591/ijai.v14.i5.pp3970-3981).
- [6] D. C. Fauzan Muhammad, Aniati Murni Arimurthy, “Transfer Learning dengan Metode Fine Tuning pada Model Network VGG16 dan ResNet50,” *Indones. J. Comput. Sci.*, vol. 12, no. 1, pp. 361–374, 2023, doi: <https://doi.org/10.33022/ijcs.v12i1.3130>.
- [7] B. Falahkhi, E. F. Achmal, M. Rizaldi, and R. Rizki, “Perbandingan Model AlexNet dan ResNet dalam Klasifikasi Citra Bunga Memanfaatkan Transfer Learning,” *J. Ilmu Komput. Agri-Informatika*, vol. 9, pp. 70–78, 2022, doi: [10.29244/jika.9.1.70-78](https://doi.org/10.29244/jika.9.1.70-78).
- [8] M. V. Lau, A. D. Handayani, M. Y. Widodo, and R. I. Handayani, “Implementasi Metode Random Forest untuk Klasifikasi Sampah Organik dan Anorganik Berbasis Citra Digital,” *J. Artif. Intell. Digit. Bus.*, vol. 4, no. 4, pp. 400–406, 2025, doi: <https://doi.org/10.31004/riggs.v4i4.3410>.
- [9] J. Harmoko, K. Munibah, and M. Ardiansyah, “Klasifikasi Penutupan / Penggunaan Lahan Dari Citra Landsat 8 Dengan Pendekatan Random Forest Dan Support Vector Machine Di Kabupaten Sumedang , Jawa Barat,” *J. Ilmu Tanah dan Lingkung.*, vol. 27, pp. 24–31, 2025, doi: <http://dx.doi.org/10.29244/jitl.27.1.24-31>.
- [10] I. Z. Nisa, S. N. Endah, P. S. Sasongko, and R. Kusumaningrum, “Klasifikasi Citra Sampah Menggunakan Support Vector Machine Dengan Ekstraksi Fitur Gray Level Co-Occurrence Matrix Dan Color Moments,” *J. Teknol. Inf. dan Ilmu Komput.*, vol. 9, no. 5, pp. 921–930, 2022, doi: [10.25126/jtiik.202294868](https://doi.org/10.25126/jtiik.202294868).
- [11] F. Hasyim, K. Malik, and F. Rizal, “Implementasi Algoritma Convolutional Neural Networks ( CNN ) Untuk Klasifikasi Batik,” *J. Kecerdasan Buatan, Komputasi dan Teknol. Inf.*, vol. X, no. X, pp. 40–47, 2021, doi: <https://doi.org/10.33650/coreai.v2i2.3365>.
- [12] M. Rizki, P. Idris, D. Azhar, A. Ghifari, G. P. Mindara, and E. P. Giri, “Klasifikasi Motif Batik Indonesia Menggunakan Deep Learning Berbasis Convolutional Neural Network ( CNN ),” *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 10, no. 1, pp. 1140–1147, 2026, doi: <https://doi.org/10.36040/jati.v10i1.16917>.
- [13] A. Mufidatuzzainiya and M. Faisal, “Penggunaan Teknik Transfer Learning pada Metode CNN untuk Pengenalan Tanaman Bunga,” *JISKA (Jurnal Inform. Sunan Kalijaga)*, vol. 10, no. 2, pp. 195–206, 2025, doi: <https://doi.org/10.14421/jiska.2025.10.2.195-206>.
- [14] M. Salman, I. Musyaffa, N. Yudistira, and M. Arif, “IndoHerb : Indonesia Medicinal Plants Recognition using Transfer Learning and Deep Learning,” *Helion a Cell Press J.*, vol. 10, no. 23, pp. 1–34, 2024, doi: [10.1016/j.helion.2024.e40606](https://doi.org/10.1016/j.helion.2024.e40606).
- [15] A. A. Siregar and D. D. I. S., “Klasifikasi Batik Parang Menggunakan Convolutional Neural Network ( CNN ),” *Pop. J. Penelit. Mhs.*, vol. 3, no. 1, pp. 62–69, 2024, doi: <https://doi.org/10.58192/populer.v3i1.1666>.
- [16] K. Azmi and S. Defit, “Implementasi Convolutional Neural Network ( CNN ) Untuk Klasifikasi Batik Tanah Liat Sumatera Barat,” *J. Unitek*, vol. 16, no. 1, pp. 2580–2582, 2023, doi: <https://doi.org/10.52072/unitek.v16i1.504>.
- [17] E. W. Muna Malika, “Implementasi Deep Learning Untuk Klasifikasi Gambar Menggunakan Convolutional Neural Network (CNN) Pada Batik Sasambo,” pp. 335–340, 2021, doi: <https://doi.org/10.30598/PattimuraSci.2021.KNMX.335-340>.
- [18] N. Febriani, S. Yunidar, R. A. Hidayat, and G. Amor, “Klasifikasi Citra Satelit dengan Metode Random Forest Untuk Observasi Dinamika Lanskap Ekosistem Kabupaten Sijunjung,” *El-Jughrafiyah*, vol. 2, no. 02, pp. 75–81, 2022, doi: <http://dx.doi.org/10.24014/jej.v2i2.18730>.
- [19] R. Amalia and P. Rosyani, “Klasifikasi Citra Menggunakan Metode Random Forest dan Sequential Minimal Optimization ( SMO ) Image Classification Using Random Forest Method and Sequential Minimal Optimization ( SMO ),” *JUSTIN (Jurnal Sist. dan Teknol. Informasi)*, vol. 09, no. 2, pp. 132–134, 2021, doi: [10.26418/justin.v9i2.44120](https://doi.org/10.26418/justin.v9i2.44120).
- [20] Y. Radhinal, A. P. Abdi, and D. N. A. Ahmad, “Klasifikasi Tutupan Lahan Perkotaan Menggunakan Citra Satelit Sentinel-2 dan Pendekatan Machine Learning Algoritma Random Forest (Studi Kasus: Kota Palu),” *J. Kolaboratif Sains*, vol. 8, no. 8, pp. 5275–5283, 2025, doi: <https://doi.org/10.56338/jks.v8i7.8301>.
- [21] W. A. Raina Rahmawati Fitri, Asriyanik, “Penggunaan Random Forest Dalam Sistem Klasifikasi Kecemasan Pada Generasi Z,” *JITET (Jurnal Inform. dan Tek. Elektro Ter.)*, vol. 13, no. 3, pp. 561–571, 2025, doi: <http://dx.doi.org/10.23960/jitet.v13i3.6905> PENGGUNAAN.
- [22] K. A. Satria and I. W. Supriana, “Perbandingan CNN dan SVM untuk Klasifikasi Citra Rempah Indonesia,” *JNATIA (Jurnal Nas. Teknol. Inf. dan Apl.)*, vol. 4, pp. 395–400, 2026, doi: <https://doi.org/10.24843/JNATIA.2026.v04.i02.p17>.
- [23] I. M. G. S. Putu Prianka Vedanty, Made Windu Antara Kesiman, “Pengaruh Data Augmentasi Pada Identifikasi Penyakit Daun Tanamann Obat Menggunakan K-Nearest Neighbor,” *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 9, no. 2, pp. 2094–2100, 2025, doi: <https://doi.org/10.36040/jati.v9i2.12961>