

Klasifikasi Motif Batik Menggunakan *Convolutional Neural Network (CNN)* dengan *Otsu thresholding* dan *Median filter*

Adithya Kusuma Whardana¹, Umar Alfaruq Abdul Aziz²

Universitas Tanri Abeng^{1,2}

adithya@tau.ac.id¹, umar.alfaruq@student.tau.ac.id²

Diterima : 25 April 2025

Disetujui : 26 Mei 2025

Abstrak— Batik merupakan warisan budaya Indonesia yang telah diakui secara global, namun keragaman motifnya seringkali sulit dikenali oleh masyarakat awam. Penelitian ini bertujuan untuk mendukung pelestarian batik serta mempermudah klasifikasi motif dengan pendekatan berbasis ciri geometris dan non-geometris menggunakan metode *Convolutional Neural Network (CNN)*. Data citra batik dikumpulkan dari internet dan hasil pemotretan di Museum Batik TMII, lalu dikategorikan dan diproses melalui tahap pra-proses, termasuk konversi ke grayscale, segmentasi menggunakan metode Otsu untuk memisahkan motif dari latar, serta peningkatan kualitas citra menggunakan *median filter*. Klasifikasi dilakukan menggunakan CNN dengan 3600 iterasi dan batch size 20. Hasil eksperimen menunjukkan akurasi sebesar 85,36%, dengan rata-rata presisi 86,76% dan recall 87,36%, serta waktu pelatihan selama 11 menit 41 detik. Hasil ini menunjukkan bahwa pendekatan CNN dengan *preprocessing Otsu thresholding* dan *median filter* tidak hanya mampu meningkatkan akurasi klasifikasi motif batik, tetapi juga memberikan efisiensi waktu pelatihan. Sistem ini berpotensi diterapkan dalam *platform digital* edukatif atau museum interaktif untuk mengenalkan kekayaan batik kepada generasi muda secara otomatis dan sistematis.

Keywords — Klasifikasi Citra Batik, CNN, Otsu , Median filter, Image Processing.


I. INTRODUCTION

Batik merupakan salah satu warisan budaya Indonesia yang memiliki nilai seni tinggi serta kekayaan motif dan warna yang mencerminkan identitas kultural bangsa. Keberadaannya tidak hanya bernilai estetis, tetapi juga merepresentasikan tradisi turun-temurun dari para leluhur. UNESCO telah mengakui batik sebagai warisan budaya tak benda dunia dalam ranah pendidikan, ilmu pengetahuan, dan kebudayaan, menjadikannya simbol identitas nasional serta media diplomasi budaya Indonesia di kancah internasional [20]. Berawal dari tradisi membatik di wilayah Jawa Tengah, kerajinan ini kemudian menyebar dan berkembang di berbagai daerah di Indonesia, masing-masing menghadirkan corak

dan gaya yang dipengaruhi oleh seni dan budaya lokal [11].

Batik Indonesia memiliki kekayaan motif yang sangat beragam dan mencerminkan ciri khas budaya dari berbagai daerah di Nusantara. Secara umum, motif batik dapat diklasifikasikan ke dalam dua kategori utama, yaitu motif geometris dan motif non-geometris. Seperti ditampilkan pada Gambar 1, motif geometris umumnya memiliki pola dasar berupa bentuk-bentuk yang terstruktur seperti garis lurus, sudut, serta pola simetris yang berulang. Sebaliknya, motif non-geometris disusun dari ornamen-ornamen yang terinspirasi dari alam dan budaya, seperti bentuk tumbuhan, hewan, bangunan candi, meru, maupun simbol filosofis seperti pohon hayat, dengan susunan yang cenderung

tidak beraturan dan tidak mengikuti bentuk geometris tertentu [12].



Gambar 1. Batik Geometris dan non geometris.

Selain memiliki keragaman motif yang tinggi, setiap daerah di Nusantara juga menghadirkan corak batik yang khas, seperti Batik Kawung Kuno, Batik Parang, Batik Mega Mendung, Batik Cendrawasih, dan Batik Betawi. Keanekaragaman ini mencerminkan kekayaan budaya Indonesia, namun di sisi lain menjadi tantangan tersendiri bagi masyarakat awam dalam mengidentifikasi dan mengenali motif-motif batik secara akurat [1]. Ketidaktahuan ini dapat menimbulkan risiko kesalahan dalam interpretasi makna atau asal-usul batik. Oleh karena itu, penelitian yang berfokus pada pengembangan sistem identifikasi dan klasifikasi motif batik menjadi sangat penting sebagai langkah strategis dalam pelestarian budaya dan penguatan identitas nasional [2]. Pengolahan citra batik merupakan tahap penting dalam meningkatkan akurasi sistem klasifikasi. Dua teknik utama yang sering digunakan dalam pengolahan ini adalah ekstraksi fitur dan klasifikasi. Proses ekstraksi bertujuan untuk memperoleh informasi penting dari citra yang kemudian dijadikan parameter dalam proses pengambilan keputusan klasifikasi [1].

Pemanfaatan kecerdasan buatan, khususnya dalam pengolahan dan klasifikasi citra batik, telah menunjukkan perkembangan yang signifikan. Budiman et al. [2] melakukan penelitian segmentasi citra tenun menggunakan metode *Otsu thresholding* dan membandingkannya dengan skenario yang menggabungkan *Otsu thresholding* dan *median filter*. Hasilnya menunjukkan bahwa penggunaan *median filter* mampu menurunkan nilai *Relative Absolute Error* (RAE) rata-rata menjadi 0,34%

dan *Mean Error* (ME) menjadi 0,55%, lebih rendah dibandingkan skenario tanpa *median filter* yang memiliki RAE rata-rata sebesar 0,36%. Dalam bidang klasifikasi motif, Maulida [3] berhasil mengembangkan sistem klasifikasi untuk kain Sasirangan dan batik dengan tingkat akurasi sebesar 91,84%. Penelitian lain oleh Bowo et al. [4], yang menggunakan 745 citra uji dengan distribusi 96 hingga 127 gambar per kelas, berhasil memperoleh akurasi klasifikasi sebesar 95%. Sementara itu, penelitian oleh Malika dan Widodo [5] yang menerapkan algoritma CNN untuk klasifikasi batik, menunjukkan akurasi sebesar 80% pada data uji, memperkuat efektivitas pendekatan deep learning dalam pengolahan citra batik. Berdasarkan uraian yang telah dijelaskan sebelumnya, algoritma *Convolutional Neural Network* (CNN) terbukti memiliki kemampuan yang baik dalam melakukan klasifikasi citra batik. Oleh karena itu, dalam penelitian ini, menggunakan klasifikasi motif batik Nusantara dengan fokus pada empat jenis motif, yaitu Batik Betawi, Batik Cendrawasih, Batik Parang, dan Batik Mega Mendung. Selain pendekatan teknis, penting pula memahami asal-usul dan karakteristik masing-masing motif batik. Batik Betawi berasal dari Jakarta dengan warna cerah dan ornamen yang menggambarkan budaya Betawi. Batik Cendrawasih menggambarkan burung Cendrawasih sebagai simbol keindahan dan berasal dari Papua. Batik Parang berasal dari Jawa dan dikenal dengan pola diagonal menyerupai ombak, menggambarkan kekuatan dan kesinambungan. Sedangkan Batik Mega Mendung dari Cirebon menampilkan motif awan berlapis dengan nuansa kebijaksanaan dan ketenangan. Keempat motif ini tidak hanya berbeda secara visual tetapi juga secara filosofis dan budaya, sehingga menambah tantangan dalam klasifikasi berbasis citra.

Proses klasifikasi dilakukan menggunakan algoritma CNN yang didahului oleh tahapan segmentasi citra dengan metode *Otsu thresholding* dan peningkatan kualitas citra menggunakan *median filter*.

II. LITERATUR REVIEW

Penelitian yang dilakukan oleh Azmi et al. [6] membahas penerapan algoritma *Convolutional Neural Network* (CNN) dalam proses klasifikasi motif Batik Tanah Liat yang berasal dari Sumatera Barat. Studi ini memanfaatkan arsitektur CNN yang diimplementasikan menggunakan bahasa pemrograman Python dengan bantuan pustaka TensorFlow. Sebanyak 400 citra batik digunakan sebagai dataset, yang kemudian diklasifikasikan ke dalam empat kelas dan dibagi menjadi data latih dan data uji dengan rasio 80:20. Hasil pelatihan menunjukkan tingkat akurasi sebesar 98,75% pada data latih dan 62,5% pada data uji. Evaluasi kinerja dilakukan melalui analisis visual berupa grafik hasil pelatihan serta pengujian langsung terhadap citra batik. Berdasarkan hasil tersebut, disimpulkan bahwa implementasi CNN mampu mengidentifikasi motif Batik Tanah Liat dengan tingkat akurasi yang baik dan menunjukkan potensi dalam pengembangan sistem klasifikasi batik berbasis citra digital [6].

Penelitian mengenai klasifikasi motif batik sebagai bagian dari seni visual Indonesia telah dilakukan dengan menerapkan algoritma *Convolutional Neural Network* (CNN) dalam rangka pengenalan motif menggunakan pendekatan kecerdasan buatan. Dalam eksperimen yang menggunakan dataset sebanyak 120 citra batik dari tiga kelas, model CNN dasar menunjukkan akurasi rata-rata sebesar 65%. Ketika metode ini dikombinasikan dengan praproses citra berupa konversi ke grayscale, akurasi meningkat menjadi 70%, menunjukkan peningkatan sebesar 5%. Temuan ini menunjukkan bahwa penambahan grayscale berkontribusi positif terhadap peningkatan performa klasifikasi. Penelitian ini memiliki signifikansi penting dalam mendukung pengenalan motif batik, terutama mengingat banyaknya variasi motif yang seringkali sulit diidentifikasi secara visual oleh masyarakat umum [8].

Sebuah studi mengenai segmentasi citra tenun Timor membandingkan dua pendekatan berbeda dalam penerapan metode *Otsu thresholding*. Pada skenario pertama, segmentasi dilakukan


hanya dengan metode *Otsu thresholding*, sedangkan skenario kedua menggabungkan metode tersebut dengan penggunaan *median filter* sebagai upaya reduksi *noise*. Hasil evaluasi menunjukkan bahwa kombinasi metode Otsu dan *median filter* menghasilkan performa yang lebih baik, ditandai dengan nilai rata-rata Relative Absolute Error (RAE) sebesar 0,34% dan nilai rata-rata Mean Error (ME) sebesar 0,55%. Sebaliknya, segmentasi tanpa reduksi *noise* hanya menghasilkan RAE rata-rata sebesar 0,36%. Temuan ini menunjukkan bahwa penggunaan *median filter* dapat meningkatkan kualitas segmentasi citra secara signifikan [9].

Pemilihan keempat motif ini Batik Betawi, Cendrawasih, Parang, dan Mega Mendung didasarkan pada popularitas, ketersediaan dataset, serta representasi dua kategori besar batik: geometris dan non-geometris. Batik Parang dan Mega Mendung cenderung memiliki pola geometris yang terstruktur, sedangkan Batik Betawi dan Cendrawasih mewakili motif non-geometris dengan ornamen naturalistik dan simbolik.

III. METODOLOGI

A. Metode

Dalam melaksanakan penelitian klasifikasi motif batik, seluruh proses dilakukan secara sistematis melalui tahapan-tahapan yang dirancang secara terstruktur dan terencana. Tahapan metodologi yang diterapkan dijelaskan secara rinci dalam bab ini, sebagaimana ditunjukkan pada Gambar 2 yang menggambarkan alur penelitian.



Gambar 2. Tahap Penelitian.

Secara umum, penelitian ini terdiri dari empat tahap utama, yaitu: studi pustaka yang mencakup kajian teori mengenai klasifikasi citra dan pengolahan motif batik berbasis *Convolutional Neural Network* (CNN) [1,2]; pengumpulan


dataset batik dari berbagai sumber representatif, baik melalui pencarian daring maupun dokumentasi lapangan [3]; praproses citra yang meliputi konversi ke grayscale, segmentasi menggunakan metode *Otsu thresholding*, serta peningkatan kualitas citra dengan *median filter* [4,9]; dan implementasi model CNN untuk pelatihan serta klasifikasi motif batik [5–7]. Seluruh tahapan ini disusun dengan mengacu pada pendekatan metodologis yang telah terbukti efektif dalam penelitian-penelitian sebelumnya terkait klasifikasi citra berbasis kecerdasan buatan.

Berdasarkan Gambar 2, tahapan awal dalam penelitian ini dimulai dengan proses pengumpulan citra motif batik yang terdiri dari dua kategori utama, yaitu motif geometris dan non-geometris [1]. Proses pengumpulan data dilakukan melalui dua metode, yaitu pencarian citra batik dari internet serta dokumentasi langsung menggunakan kamera ponsel di Museum Batik TMII [3]. Setelah data terkumpul, tahap selanjutnya adalah praproses citra (preprocessing), yang mencakup pengubahan ukuran citra (resize) serta konversi format dari RGB menjadi grayscale [8]. Citra *grayscale* kemudian diproses menggunakan metode *Otsu thresholding* untuk memisahkan objek motif dari latar belakang [4,9]. Untuk meningkatkan kualitas hasil segmentasi, metode Otsu juga dikombinasikan dengan *median filter* sebagai teknik reduksi *noise* [2,4]. Hasil citra yang telah diproses selanjutnya digunakan pada tahap pelatihan dan klasifikasi menggunakan algoritma *Convolutional Neural Network* (CNN), yang telah terbukti efektif dalam pengenalan motif batik pada berbagai studi sebelumnya [5,7]. Tahap akhir dari proses ini adalah pengujian model CNN guna mengevaluasi kinerja sistem dalam mengklasifikasikan motif batik berdasarkan citra yang telah diproses.

B. Dataset.

Pada Tahap ini menjelaskan penggunaan dari dataset yang digunakan dari penelitian ini. Pada gambar 3 merupakan flowchart dari penggunaan dataset dalam penelitian ini.

Pada Gambar 3 merupakan Flowchart Pengumpulan Dataset menjelaskan alur pengumpulan Data set dilakukan dengan 2 cara yaitu Data set Realtime dan Data set open-source.



Gambar 3. Flowchart Pengumpulan dataset.


Pada tahap pengumpulan *dataset* secara real-time, citra motif batik diambil menggunakan kamera handphone Vivo Y22 dari berbagai jenis motif yang dipamerkan di Museum Batik TMII pada waktu siang hari untuk mendapatkan pencahayaan alami yang optimal. Setelah pengambilan gambar, citra-citra yang dihasilkan dievaluasi secara manual guna memilih gambar dengan kualitas visual yang baik, seperti ketajaman, kontras, dan kejelasan motif. Hanya citra yang memenuhi kriteria tersebut yang digunakan dalam proses klasifikasi ke dalam dua kategori utama, yaitu motif geometris dan non-geometris [1,3]. Berdasarkan hasil seleksi, diperoleh sebanyak 72 citra yang layak digunakan sebagai *dataset* dalam proses pelatihan dan pengujian model klasifikasi batik berbasis *Convolutional Neural Network* (CNN) [5]. Pada gambar 4 merupakan dataset realtime yang diambil dari museum.



Gambar 4. Dataset Realtime


Selain pengumpulan data secara real-time, penelitian ini juga memanfaatkan dataset sekunder yang diperoleh dari repositori daring Kaggle dan github [27]. Penggunaan dataset

berbasis internet ini bertujuan untuk meningkatkan jumlah dan variasi citra motif batik dalam proses pelatihan model klasifikasi. Setiap citra dari sumber daring tersebut diseleksi secara manual berdasarkan kualitas visual dan kejelasan motif yang ditampilkan. Hanya gambar dengan resolusi tinggi dan representasi motif yang jelas yang digunakan dalam proses klasifikasi ke dalam kategori geometris dan non-geometris. Berdasarkan hasil seleksi, diperoleh sebanyak 742 citra yang dinyatakan layak untuk digunakan dalam pelatihan dan pengujian model klasifikasi berbasis CNN. Pada gambar 5 menunjukkan dataset batik yang diperoleh dari sumber internet.



Gambar 5. Dataset Online.

Pada Gambar 6 ditunjukkan alur dari proses pengelompokan dataset yang akan digunakan dalam penelitian ini. Seluruh citra batik yang telah dikumpulkan, baik dari hasil pengambilan data secara real-time maupun dari sumber daring, terdiri dari berbagai macam motif seperti Motif A, Motif B, Motif C, hingga Motif D dan lainnya.



Gambar 6. Alur pengelompokan dataset.

Setiap motif tersebut kemudian dianalisis dan dikelompokkan berdasarkan karakteristik visualnya ke dalam dua kategori utama, yaitu kelas geometris dan kelas non-geometris. Motif-motif yang memiliki pola dasar berbentuk simetris, berulang, atau terstruktur secara geometris seperti garis, sudut, atau bentuk

simetris dimasukkan ke dalam kelas geometris. Sebaliknya, motif-motif yang didominasi oleh bentuk alami atau tidak beraturan seperti flora, fauna, bangunan budaya, dan ornamen filosofis lainnya, diklasifikasikan sebagai kelas non-geometris. Kedua kategori tersebut kemudian digabungkan dalam satu kesatuan dataset yang siap digunakan untuk proses pelatihan dan klasifikasi menggunakan algoritma CNN.

Dataset yang digunakan dalam penelitian ini terdiri dari berbagai motif batik yang dikelompokkan ke dalam satu kelas berdasarkan karakteristik jenis motif. Pengelompokan ini bertujuan untuk mengamati distribusi variasi motif dalam masing-masing kelas, baik geometris maupun non-geometris. Struktur dan alur pengelompokan *dataset* divisualisasikan pada Gambar 6, sedangkan rincian jumlah citra yang diperoleh dari pengambilan data secara real-time dan dari sumber daring disajikan pada Tabel 1. Rincian jumlah Dataset, yang memberikan informasi komposisi dari dataset yang digunakan dalam penelitian ini.

Tabel 1. Rincian Jumlah Dataset


No	Data	Geo	NonGeo	Jumlah
1	Museum Batik TMII	36	36	72
2	Kaggle	100	150	250
3	Github	271	221	492
	jumlah	407	407	814

Tabel 1 menyajikan rincian jumlah *dataset* citra batik yang digunakan dalam penelitian, yang dikategorikan ke dalam dua jenis utama, yaitu motif geometris (Geo) dan non-geometris (NonGeo). Data diperoleh dari tiga sumber berbeda, yaitu dokumentasi langsung di Museum Batik TMII, serta sumber daring dari Kaggle dan GitHub. Dari Museum Batik TMII, diperoleh 72 citra, terdiri dari 36 motif geometris dan 36 non-geometris. Sumber dari Kaggle terdiri dari 250 citra, dengan citra 100 batik geometris dan 150 non-geometris.

Sementara itu, GitHub terdapat data citra batik dengan total 492 citra yang terdiri dari 271 motif batik geometris dan 221 motif non-geometris. Secara keseluruhan, jumlah total citra yang digunakan dalam penelitian ini adalah sebanyak 814 citra batik, dengan masing-masing kategorie geometris dan non geometris yaitu masing-masing 407 citra geometris dan 407 citra non-geometris. Distribusi yang proporsional ini bertujuan untuk memastikan performa klasifikasi CNN dapat dievaluasi secara adil pada kedua kelas motif.

C. Preprocessing

Pada Tahap ini menjelaskan preprocessing yang dilakukan pada penelitian ini.



Gambar 7. alur preprocessing.


Gambar 7 menunjukkan alur proses preprocessing citra yang diimplementasikan dalam penelitian ini sebelum dilakukan pelatihan model klasifikasi. Proses dimulai dari tahap awal, yaitu pemberian input berupa citra motif batik. Tahapan pertama adalah resize, di mana ukuran citra disesuaikan untuk menyeragamkan dimensi dan mempermudah proses komputasi selanjutnya. Setelah itu, citra yang telah diubah ukurannya dikonversi dari format warna RGB ke grayscale guna menyederhanakan informasi warna menjadi skala keabuan, sehingga fokus analisis beralih ke pola dan tekstur.

Langkah berikutnya adalah segmentasi citra menggunakan metode *Otsu thresholding*, yang berfungsi untuk memisahkan area objek (motif batik) dari latar belakang secara otomatis berdasarkan distribusi intensitas piksel [4]. Setelah objek berhasil dipisahkan, citra kemudian ditingkatkan kualitasnya menggunakan *median filter*, yang bertujuan mengurangi *noise* atau gangguan visual lain yang dapat mengganggu akurasi klasifikasi [2,9].

Hasil akhir dari seluruh tahapan ini disebut sebagai hasil preprocessing, yaitu citra yang telah siap untuk digunakan dalam pelatihan model klasifikasi dengan algoritma CNN. Proses berakhir pada tahap penyimpanan atau pemrosesan lanjut dari citra yang telah diproses pada tahap sebelumnya.

D. Resize Gambar.

Pada tahapan awal *preprocessing*, citra yang dikumpulkan dari berbagai sumber memiliki ukuran yang bervariasi, sehingga diperlukan proses resizing untuk menyeragamkan dimensi setiap citra. Penyeragaman ukuran ini bertujuan agar data yang digunakan dalam proses pelatihan memiliki konsistensi struktural, serta memudahkan pemrosesan pada model klasifikasi berbasis CNN. Gambar 8 memperlihatkan hasil *dataset* yang telah melalui proses resizing, di mana salah satu citra dengan ukuran asli 203×248 piksel diubah menjadi 512×512 piksel untuk menyesuaikan dengan arsitektur input pada model CNN.



Gambar 8. Proses Citra batik yang sudah di resize.

Pada Gambar 8 memperlihatkan hasil transformasi ukuran citra batik dari resolusi awal 203×248 piksel menjadi 512×512 piksel. Proses *resizing* ini dilakukan sebagai bagian dari tahap *preprocessing* guna memastikan setiap citra memiliki dimensi yang seragam sebelum dimasukkan ke dalam model klasifikasi CNN. Penyeragaman dimensi ini penting untuk menghindari ketidaksesuaian ukuran input antar citra yang dapat menyebabkan gangguan pada arsitektur jaringan saraf konvolusional, khususnya pada lapisan input [2].

Ukuran 512×512 piksel dipilih sebagai standar karena dianggap cukup representatif dalam mempertahankan detail visual dari motif batik, sambil tetap mempertahankan efisiensi

komputasi dalam proses pelatihan. Resolusi ini juga selaras dengan studi terdahulu yang merekomendasikan penggunaan dimensi seragam dalam skala menengah (antara 224×224 hingga 512×512 piksel) untuk menjaga keseimbangan antara kualitas fitur dan waktu komputasi [26].

E. RGB to gray

Setelah proses *resizing*, citra kemudian dikonversi ke dalam format derajat keabuan (grayscale) menggunakan fungsi RGB to Gray. Fungsi ini berperan untuk mengubah citra berwarna yang terdiri atas tiga saluran warna (Red, Green, Blue) menjadi citra dengan satu saluran intensitas keabuan. Transformasi ini dilakukan untuk meningkatkan efisiensi pemrosesan data serta mengurangi kompleksitas komputasi. Pada citra grayscale, setiap piksel hanya merepresentasikan satu nilai intensitas, sehingga proses segmentasi selanjutnya, seperti *thresholding*, dapat dilakukan secara lebih sederhana dan cepat. Gambar 9 memperlihatkan contoh *dataset* setelah dikonversi ke grayscale, yang menunjukkan hasil perubahan dari citra berwarna ke bentuk keabuan yang siap diproses lebih lanjut dalam tahapan *preprocessing*.



Gambar 9. Citra RGB ke grayscale.


Pada gambar 9 menunjukkan transformasi citra motif batik dari citra berwarna (RGB) menjadi citra dalam format skala keabuan (grayscale). Proses ini dilakukan setelah citra di-*resize* ke ukuran 512×512 piksel. Konversi dari RGB ke grayscale bertujuan untuk menyederhanakan representasi data visual dengan mengurangi kompleksitas saluran warna menjadi hanya satu saluran intensitas. Hal ini

penting untuk efisiensi pemrosesan data dalam sistem klasifikasi berbasis pembelajaran mesin.

Dalam citra grayscale, nilai intensitas pada tiap piksel mewakili derajat kecerahan, sehingga tetap mempertahankan informasi kontur dan struktur motif batik secara efektif [3]. Penggunaan grayscale juga sangat direkomendasikan dalam sistem berbasis deep learning karena dapat mengurangi beban komputasi tanpa mengorbankan kualitas fitur yang dibutuhkan untuk segmentasi atau klasifikasi lebih lanjut [13]. Tahapan ini menjadi fondasi penting dalam proses *preprocessing* sebelum diterapkan metode seperti *Otsu thresholding* atau pelatihan CNN.

F. Segmentasi Otsu thresholding

Tahapan selanjutnya dalam proses *preprocessing* adalah penerapan metode *Otsu thresholding* terhadap citra yang telah dikonversi ke dalam format grayscale. *Otsu thresholding* merupakan metode segmentasi berbasis histogram yang secara otomatis menentukan nilai ambang (threshold) optimal dengan menganalisis distribusi intensitas piksel pada citra. Tujuan utama dari metode ini adalah untuk memisahkan area objek dengan latar belakang secara efisien dan akurat, sehingga citra terbagi menjadi dua kelas piksel: piksel objek (biasanya direpresentasikan dalam warna putih) dan piksel latar belakang (warna hitam), atau sebaliknya [4]. Penggunaan metode ini sangat sesuai untuk citra batik, yang memiliki variasi kontras motif yang cukup kompleks. Pada gambar 10 menunjukkan citra yang sudah diproses ke dalam citra *otsu thresholding*.



Gambar 10 Proses citra Batik grayscale ke *otsu thresholding*.

Gambar 10 memperlihatkan perbandingan antara citra motif batik dalam format grayscale (kiri) dan hasil segmentasinya menggunakan metode *Otsu thresholding* (kanan). Pada citra grayscale, informasi visual masih ditampilkan dalam berbagai tingkat intensitas keabuan yang merepresentasikan variasi motif secara halus. Setelah diproses dengan *Otsu thresholding*, citra tersebut dikonversi menjadi citra biner hitam-putih, di mana objek utama (motif batik) dan latar belakang berhasil dipisahkan secara jelas. Konversi ini bertujuan untuk menyederhanakan informasi visual dan meningkatkan fokus terhadap pola motif, sehingga mempermudah tahap klasifikasi selanjutnya dalam sistem berbasis CNN.

G. Median filter

Setelah citra mengalami proses segmentasi menggunakan metode *Otsu thresholding*, tahap selanjutnya adalah penerapan *median filter* sebagai teknik peningkatan kualitas citra. *Median filter* berfungsi untuk mereduksi *noise* atau gangguan yang masih terdapat pada hasil segmentasi, sehingga batas-batas objek motif menjadi lebih halus dan terdefinisi dengan baik. Penggunaan filter ini juga bertujuan untuk menjaga keutuhan struktur motif sekaligus meningkatkan akurasi pada tahap klasifikasi selanjutnya. Gambar 11. Merupakan citra hasil pengolahan gabungan antara *Otsu thresholding* dan *median filter*, yang menunjukkan peningkatan kejernihan citra dan pengurangan elemen-elemen yang tidak diinginkan.

Median filter merupakan teknik penyaringan non-linear yang banyak digunakan dalam pemrosesan citra digital untuk mengurangi gangguan visual berupa *noise*, khususnya jenis *salt-and-pepper* yang sering muncul setelah segmentasi [26]. Dalam penelitian ini, *median filter* diterapkan setelah proses segmentasi menggunakan metode *Otsu thresholding*, dengan tujuan untuk memperhalus hasil segmentasi dan menjaga integritas kontur motif batik. Teknik ini bekerja dengan menggantikan nilai suatu piksel berdasarkan nilai median dari piksel-piksel di sekitarnya dalam jendela tertentu, sehingga


mampu mereduksi *noise* tanpa mengaburkan batas-batas objek utama [6].



Gambar 11. Citra Batik dengan *Median filter*.

Penggunaan *median filter* terbukti efektif dalam berbagai studi pengolahan citra batik karena dapat meningkatkan kualitas visual citra sebelum diklasifikasikan oleh model CNN, serta menjaga akurasi sistem terhadap motif yang kompleks dan detail [21]. Dalam penelitian ini, CNN digunakan sebagai metode utama untuk melatih model klasifikasi citra motif batik. Pelatihan model bertujuan untuk mengoptimalkan parameter jaringan guna meningkatkan kemampuan prediksi terhadap data yang telah melalui tahap *preprocessing*. Variabel terikat yang diamati dalam proses ini meliputi nilai akurasi rata-rata pengenalan citra, tingkat kesalahan (error rate), jumlah epoch, dan durasi waktu pelatihan. Sementara itu, variabel bebas yang diatur secara eksperimental mencakup jumlah epoch dan nilai *learning rate*, yang memengaruhi laju konvergensi Alur dalam proses pembaruan bobot jaringan [5], [7], [14]. Penyesuaian terhadap kedua parameter ini dilakukan untuk memperoleh konfigurasi pelatihan yang optimal, sehingga model CNN mampu memberikan performa klasifikasi yang maksimal terhadap motif batik yang telah dikelompokkan ke dalam kelas geometris dan non-geometris. Pada gambar 12 merupakan alur pelatihan CNN.

Gambar 12 menggambarkan arsitektur proses pelatihan model klasifikasi citra batik menggunakan metode *Convolutional Neural Network* (CNN). Proses dimulai dari input citra batik yang telah melalui tahap *preprocessing*, baik untuk motif geometris maupun non-geometris. Selanjutnya, data citra tersebut dibagi menjadi dua subset, yaitu data pelatihan



Gambar 12. Arsitektur CNN

(training) dan data pengujian (testing) untuk mendukung validasi kinerja model.

Pada tahap pelatihan, arsitektur CNN terdiri atas beberapa lapisan inti. Dimulai dari image input layer yang menerima citra dalam format piksel sebagai masukan. Kemudian, citra diproses melalui serangkaian lapisan konvolusi (conv) untuk mengekstraksi fitur lokal dari motif batik. Setiap lapisan konvolusi diikuti oleh batch normalization yang bertujuan untuk menstabilkan dan mempercepat pelatihan jaringan, serta ReLU (Rectified Linear Unit) sebagai fungsi aktivasi non-linear yang memperkenalkan non-linearitas ke dalam model. Setelah itu, diterapkan lapisan max pooling untuk mereduksi dimensi fitur dan memperkuat informasi utama dari motif.

Setelah beberapa blok konvolusi dan pooling, jaringan dilanjutkan ke fully connected layer (fc) yang berperan sebagai lapisan klasifikasi. Output dari lapisan ini kemudian masuk ke lapisan softmax, yang mengubah output menjadi probabilitas antar kelas, dan terakhir ke lapisan klasifikasi (class output layer) yang menentukan kelas akhir dari motif batik yang dikenali.

Hasil akhir dari proses ini adalah output berupa prediksi kelas motif batik, apakah tergolong geometris atau non-geometris, dengan tingkat akurasi yang bergantung pada parameter pelatihan seperti jumlah epoch, learning rate, serta jumlah data latih yang digunakan. Rumus persamaan CNN ditunjukkan pada persamaan (1).

Rumus di atas merepresentasikan proses konvolusi dua dimensi antara citra masukan I dan kernel filter K . Hasil konvolusi ditandai dengan $S(i,j)$, yang merupakan nilai output pada posisi (i,j) . Operasi ini dilakukan dengan cara menggeser kernel di sepanjang citra masukan dan menghitung hasil perkalian elemen demi elemen yang dijumlahkan untuk menghasilkan satu nilai output.

IV. HASIL DAN EVALUASI

Bagian ini menyajikan hasil dan evaluasi dari keseluruhan tahapan yang telah dilakukan dalam penelitian, mencakup proses *preprocessing* citra serta klasifikasi motif batik menggunakan algoritma CNN. Metode *preprocessing* yang diterapkan melibatkan segmentasi citra menggunakan teknik *Otsu thresholding* dan peningkatan kualitas citra dengan *median filter*, yang bertujuan untuk memperjelas kontur motif dan meminimalkan gangguan visual. Evaluasi hasil kemudian difokuskan pada kinerja model klasifikasi CNN dalam mengenali dan membedakan motif batik berdasarkan kategori geometris dan non-geometris, dengan mengacu pada metrik performa seperti akurasi, tingkat kesalahan, serta waktu pelatihan.

A. Hasil Implementasi CNN

Tahapan ini merupakan bagian dari evaluasi eksperimental terhadap metode yang diusulkan, dengan fokus pada pengujian pengaruh variasi nilai learning rate (LR) terhadap kinerja model klasifikasi. Sebanyak sepuluh skenario pelatihan dilakukan dengan

menggunakan nilai learning rate yang berbeda-beda dalam rentang 0 hingga 1. Learning rate merupakan parameter penting yang mengatur besarnya langkah pembaruan bobot selama proses pelatihan; semakin besar nilai learning rate, maka semakin besar pula perubahan bobot yang terjadi dalam satu iterasi pembelajaran. Pada percobaan ini, jumlah *epoch* ditetapkan sebanyak 20, dengan ukuran *mini-batch* sebesar 20. Setiap konfigurasi nilai learning rate akan dievaluasi berdasarkan dua metrik utama, yaitu tingkat akurasi hasil klasifikasi dan waktu pelatihan yang dibutuhkan. Tujuan dari eksperimen ini adalah untuk mengidentifikasi nilai learning rate yang optimal, yakni yang mampu menghasilkan akurasi tinggi dengan efisiensi waktu pelatihan yang baik.

Tabel 2 Hasil *training* berdasarkan *learning rate*.

No	LR	Epoch	Time	Validasi Acc
1	0.009	20	2 min 31 sec	76.61%
2	0.007	20	1 min 43 sec	60.98%
3	0.001	20	2 min 9 sec	81.71%
4	0.01	20	2 min 23 sec	79.27%
5	0.03	20	2 min 27 sec	50.00%
6	0.07	20	2 min 28 sec	50.00%
7	0.1	20	2 min 17 sec	50.00%
8	0.3	20	2 min 21 sec	50.00%
9	0.5	20	2 min 23 sec	50.00%
10	1	20	2 min 18 sec	50.00%

Pada Tabel 2 menunjukkan hasil pelatihan model CNN yang dilakukan dengan berbagai nilai learning rate (LR), di mana setiap eksperimen dijalankan dengan jumlah epoch yang sama, yaitu 20. Pada penelitian ini, hasil yang dicatat meliputi waktu pelatihan dan akurasi validasi untuk setiap nilai learning rate yang diuji. Berdasarkan hasil percobaan, nilai learning rate yang lebih kecil, seperti 0.001, menghasilkan akurasi validasi tertinggi, yaitu 81.71%, meskipun waktu pelatihan sedikit lebih lama, yaitu 2 menit 9 detik. Uji coba nilai learning rate yang lebih besar, seperti 0.3, 0.5, dan 1, tidak

memberikan peningkatan signifikan dalam akurasi validasi, dengan hasil 50% dan waktu pelatihan sekitar 2 menit 20 detik. Hasil ini menunjukkan bahwa pemilihan nilai learning rate yang tepat memiliki dampak besar terhadap performa model, baik dari segi akurasi maupun efisiensi waktu pelatihan.

Pada penelitian ini, dilakukan tiga tahapan pelatihan dengan parameter yang berbeda untuk mengukur performa model CNN dalam mengklasifikasikan motif batik.

Dari pelatihan pertama, kedua dan ketiga dalam penggunaan rumus yang menggambarkan bagaimana hasil dari confusion matrix digunakan untuk menghitung kinerja model dalam mengenali motif batik pada masing-masing kelas geometris dan non-geometris. Evaluasi ini memberikan wawasan mendalam tentang keakuratan dan kemampuan model dalam mengklasifikasikan motif batik sesuai dengan kelas yang ditetapkan. Persamaan (2) merupakan formulasi dalam menentukan akurasi dalam keseluruhan pelatihan yang dilakukan. Persamaan (3) formulasi untuk menentukan presisi keseluruhan uji coba pelatihan pertama, kedua dan ketiga. Persamaan (4) dan (5) formulasi dari recall dalam penelitian ini. Sedangkan persamaan (6) merupakan formulasi untuk menghitung F1 score pada penelitian yang dilakukan.

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (2)$$

$$Precision = \frac{TP}{TP+FP} \quad (3)$$

$$Recall = \frac{TP}{TP+FN} \quad (4)$$

$$Recall(\%) = Recall \times 100 \quad (5)$$

$$F1Score = \frac{2 \times Pre. \times Rec.}{Pre. + Rec.} \quad (6)$$

Berdasarkan formulasi yang ada pada persamaan (2), persamaan (3), persamaan (4), persamaan (5), dan persamaan (6). Yang akan

digunakan untuk uji coba keseluruhan evaluasi dan hasil dalam penggunaan CNN yang dilakukan pada penelitian ini.

Pada pelatihan pertama, dengan menggunakan data set yang telah diproses sebelumnya, nilai learning rate ditetapkan sebesar 0.001, batch size 64, dan jumlah epoch sebanyak 50. Hasil dari pelatihan ini menunjukkan akurasi pelatihan sebesar 100%, dengan akurasi validasi mencapai 80.49%. Proses ini memakan waktu 120 menit 7 detik.

		True Class	
		geo	Negatif
kelas aktual	Geo	34	7
	nongeo	7	34

Gambar 13. Confussion matrik pelatihan pertama.

No	LR	Epoch	BS	Waktu	Akurasi Validasi	Akurasi training	Presisi geo	Presisi non geo	Recall geo	Recall non geo	Rata-rata presisi	Rata-rata recall	F1-score
1	0,001	50	64	120 m 7 d	80.49%	100%	80.49%	80.49%	80.49%	80.49%	80.49%	80.49%	80.49%
2	0,001	100	64	216 m 55 d	82.93%	100%	82.93%	82.93%	82.93%	82.93%	82.93%	82.93%	82.93%
3	0,001	100	20	11 m 41 d	85.36%	100%	93.93%	79.59%	79.60%	95.11%	86.76%	87.36%	87.05%

Tabel 3. Hasil dan Evaluasi Pelatihan Model .

Berdasarkan confusion matrix yang terlampir, pada kelas geometris, prediksi benar mencapai 33 dari 41 data, dan pada kelas non-geometris juga tercatat 33 prediksi benar dari total 41 data. Hasil evaluasi ini menunjukkan bahwa model berhasil mengidentifikasi sebagian besar motif dengan akurasi yang memadai. Pada gambar 13 menunjukkan confusion matrik pada pelatihan pertama yang dilakukan.

Pada pelatihan kedua, parameter yang digunakan sama dengan pelatihan pertama, namun jumlah epoch ditingkatkan menjadi 100. Hasil pelatihan ini menunjukkan akurasi pelatihan sebesar 100% dan akurasi validasi meningkat menjadi 82.93%. Waktu yang dibutuhkan untuk pelatihan adalah 216 menit 55 detik. Berdasarkan confusion matrix yang ditampilkan pada Gambar 14 pada kelas geometris, model berhasil memprediksi 34 data benar dari 41 data, sedangkan untuk kelas non-geometris, model memprediksi 34 data benar dari 41 data. Hasil ini memberikan evaluasi yang lebih baik dibandingkan dengan pelatihan pertama, dengan rata-rata presisi dan recall yang lebih tinggi, masing-masing sebesar 82.93%.

Pada gambar 14 menunjukkan confusion matrik yang dilakukan pada pelatihan kedua.

		True Class	
		geo	nongeo
kelas aktual	Geo	33	8
	nongeo	8	33

Gambar 14. Confussion matrik pelatihan kedua.

Pada pelatihan ketiga, dengan parameter learning rate 0.001 dan batch size 20, jumlah epoch ditetapkan sebanyak 100. Hasil pelatihan ini menunjukkan akurasi pelatihan sebesar 100%, dengan akurasi validasi mencapai 85.37%, dan proses pelatihan selesai dalam waktu 11 menit 41 detik. Berdasarkan confusion matrix pada Gambar 15, pada kelas geometris, model memprediksi 31 data benar dari 41 data, sedangkan pada kelas non-geometris, model memprediksi 39 data benar dari 41 data. Evaluasi ini menunjukkan peningkatan yang signifikan pada recall dan presisi, dengan rata-rata presisi mencapai 86.76% dan recall 87.36%. F1-Score yang dihasilkan sebesar 87.05%, menunjukkan bahwa model ini memiliki performa terbaik di antara tiga percobaan yang

dilakukan. Pada gambar 15 merupakan confusion matrik pada pelatihan ketiga.

Pada Tabel 3 menyajikan hasil dan evaluasi dari tiga tahapan pelatihan model CNN yang dilakukan dengan berbagai parameter, termasuk nilai learning rate, jumlah epoch, dan batch size yang berbeda. Tabel ini menunjukkan akurasi pelatihan, akurasi validasi, serta metrik evaluasi seperti presisi, recall, dan F1-Score untuk setiap konfigurasi pelatihan yang diuji, memberikan gambaran jelas mengenai kinerja model dalam klasifikasi motif batik. Hasil yang tercatat pada tabel ini digunakan untuk mengevaluasi efektivitas parameter yang dipilih dalam memaksimalkan performa model.

		True Class	
		geo	Negatif
kelas aktual	Geo	31	10
	nongeo	2	39

Gambar 15. Confusion Matrik pelatihan ketiga

Berdasarkan hasil pelatihan, ditemukan bahwa motif batik geometris seperti Parang dan Mega Mendung cenderung lebih mudah dikenali dan diklasifikasikan oleh model CNN karena pola yang terstruktur dan berulang. Sebaliknya, motif non-geometris seperti Cendrawasih dan Betawi, yang memiliki ornamen tidak beraturan dan kontur kompleks, menyebabkan peningkatan waktu pemrosesan serta penurunan akurasi pada learning rate tertentu. Hal ini menunjukkan bahwa struktur motif mempengaruhi performa model, terutama pada nilai learning rate tinggi yang cenderung tidak stabil.

III. KESIMPULAN DAN SARAN

Berdasarkan hasil pelatihan dan evaluasi model CNN dalam klasifikasi motif batik, dapat disimpulkan bahwa konfigurasi dengan learning rate 0.001, epoch 100, dan batch size 20 memberikan hasil yang paling optimal, dengan akurasi validasi mencapai 85.36%, rata-rata presisi sebesar 86.76%, dan rata-rata recall sebesar 87.36%. Model ini juga menunjukkan waktu pelatihan yang lebih efisien, yaitu 11 menit

41 detik, dibandingkan dengan konfigurasi lainnya. Hasil evaluasi metrik lainnya, seperti F1-Score, menunjukkan bahwa model ini mampu memberikan keseimbangan yang baik antara presisi dan recall, menghasilkan F1-Score sebesar 87.05%. Dengan demikian, model CNN yang diterapkan dalam penelitian ini dapat diandalkan untuk melakukan klasifikasi motif batik dengan tingkat akurasi yang tinggi dan efisiensi waktu yang baik.

Berdasarkan distribusi jumlah citra, motif geometris dari GitHub (271 citra) menjadi kategori dengan jumlah data terbanyak, sedangkan motif non-geometris dari Kaggle (150 citra) menjadi penyumbang terbesar dari kategori tersebut. Hal ini menunjukkan bahwa motif geometris lebih umum digunakan dan tersedia secara daring, sehingga dapat memengaruhi bias klasifikasi pada model CNN.

Meskipun hasil yang diperoleh sudah cukup baik, penelitian lebih lanjut dapat dilakukan dengan menguji variasi parameter lain, seperti ukuran batch yang lebih besar atau optimasi tambahan pada arsitektur CNN, seperti penerapan teknik regularisasi untuk mengurangi overfitting. Selain itu, untuk meningkatkan akurasi lebih lanjut, dapat dilakukan dengan menggunakan data augmentation untuk memperkaya variasi data dan meningkatkan kemampuan generalisasi model. Penelitian selanjutnya juga dapat mengeksplorasi penggunaan transfer learning dengan memanfaatkan model *pre-trained* yang dapat mempercepat konvergensi dan meningkatkan kinerja dalam klasifikasi motif batik.

DAFTAR PUSTAKA

- [1] Adhinata, Faisal Dharma, Ariq Cahya Wardhana, Dioviando Putra Rakhmadani, and Akhmad Jayadi. 2020. "Peningkatan Kualitas Citra pada Citra Digital Gelap." *Jurnal E-Komtek (Elektro-Komputer-Teknik)* 4(2): 136–44.
- [2] Aditya, M Rizky Vira, Nyayu Latifah Husni, Destra Andika Pratama, and Ade Silvia. "Penerapan Sistem Pengolahan Citra Digital Pendeteksi Warna pada Starbot." 14(02).
- [3] Alfayat, M. P., & Wardhana, A. K. (2024). Deteksi Dini Alzheimer Pada Otak Dengan Kombinasi Metode. *Scan: Jurnal Teknologi Informasi dan Komunikasi*, 19(1).
- [4] Annisa, Selly, Zulkarnain Lubis, and Ayu Najmita. 2020. "Perancangan Aplikasi Jaringan Syaraf Tiruan Untuk Pedeteksi Keaslian Uang Kertas." 5.

- [5] Bariyah, Taufiqotul, Mohammad Arif Rasyidi, and Ngatini Ngatini. 2021. "Convolutional Neural Network untuk Metode Klasifikasi Multi-Label pada Motif Batik." *Techno.Com* 20(1): 155–65.
- [6] Baso, Budiman, Darsono Nababan, and Renaldi Yulvengki Kolloh. 2022. "Segmentasi Citra Tenun Menggunakan Metode Otsu Thresholding dengan Median filter." 5.
- [7] Bowo, Tungki Ari, Hadi Syaputra, and Muhamad Akbar. 2020. "Penerapan Algoritma Convolutional Neural Network Untuk Klasifikasi Motif Citra Batik Solo." *Journal of Software Engineering Ampera* 1(2): 82–96.
- [8] Brian, Thomas. 2017. "Analisis Learning Rates Pada Algoritma Backpropagation Untuk Klasifikasi Penyakit Diabetes." *EduTic - Scientific Journal of Informatics Education* 3(1).
- [9] Chyan, Phie. 2017. "Penerapan Image Enhancement Algorithm Untuk Meningkatkan Kualitas Citra Tak Bergerak." 12.
- [10] Fonda, Hendry. 2020. "KLASIFIKASI BATIK RIAU DENGAN MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORKS." *Jurnal Ilmu Komputer* 9(1): 7–10a.
- [11] Hakim, Lutfi Maulana. 2018. "Batik Sebagai Warisan Budaya Bangsa dan Nation Brand Indonesia." *Nation State Journal of International Studies* 1(1): 61–90.
- [12] Hardiyanto, Denny, Samuel Kristiyana, Didi Kurniawan, and Dyah Anggun Sartika. 2019. "Klasifikasi Motif Citra Batik Yogyakarta Menggunakan Metode Adaptive Neuro Fuzzy Inference System." *Setrum : Sistem Kendali-Tenaga-elektronika-telekomunikasi-komputer* 8(2): 229.
- [13] Hermawan, H., & Whardana, A. K. (2024). Hemorrhage Segmentation on Retinal Images for Early Detection of Diabetic Retinopathy. *JEECS (Journal of Electrical Engineering and Computer Sciences)*, 9(2), 127-138.
- [14] Hossain, Md. Anwar, and Md. Shahriar Alam Sajib. 2019. "Classification of Image using Convolutional Neural Network (CNN)." *Global Journal of Computer Science and Technology*: 13–18.
- [15] Ihdal, Ihdalhubbi Maulida. 2021. "Klasifikasi Kain Khas Batik Dan Kain Khas Sasirangan Dengan Menggunakan Metode Convolutional Neural Network." *Jurnal Teknologi Informasi Universitas Lambung Mangkurat (JTIULM)* 6(1): 25–30.
- [16] Kühl, Niklas, Max Schemmer, Marc Goutier, and Gerhard Satzger. 2022. "Artificial Intelligence and Machine Learning." *Electronic Markets* 32(4): 2235–44.
- [17] Mahesh, Batta. 2018. "Machine Learning Algorithms - A Review." 9(1).
- [18] Malika, Muna, and Edy Widodo. 2021. "Implementasi Deep Learning Untuk Klasifikasi Gambar Menggunakan Convolutional Neural Network (Cnn) Pada Batik Sasambo." *Pattimura Proceeding: Conference of Science and Technology*.
- [19] Minaee, Shervin et al. 2021. "Image Segmentation Using Deep Learning: A Survey." *IEEE Transactions on Pattern Analysis and Machine Intelligence*: 1–1.
- [20] Natalia, Dewa Ayu Widia Natalia, I Dewa Ayu Made Budhyani, and Made Diah Angendari. 2019. "Batik Bali Pada Industri Sari Amerta Batik Collection Di Desa Batubulan Kecamatan Sukawati Kabupaten Gianyar." *Jurnal BOSAPARIS: Pendidikan Kesejahteraan Keluarga* 9(2): 76.
- [21] Noor, Alam et al. 2020. "Median filters combined with denoising Convolutional Neural Network for Gaussian and impulse noises." *Multimedia Tools and Applications* 79(25–26): 18553–68.
- [22] Sari, Indah Eka Yulia, Mhd Furqan, and Sriani Sriani. 2020. "Penerapan Metode Otsu dalam Melakukan Segmentasi Citra pada Citra Naskah Arab." *MATRIK : Jurnal Manajemen, Teknik Informatika dan Rekayasa Komputer* 20(1): 59–72.
- [23] Sarker, Iqbal H. 2021. "Machine Learning: Algorithms, Real-World Applications and Research Directions." *SN Computer Science* 2(3): 160.
- [24] Siaulhak, S. (2023). Sistem Klasifikasi Buah Jagung Dengan Menggunakan Metode Image Processing Pengelolaan Citra Digital. *D'compute: Jurnal Ilmiah Teknologi Informasi dan Ilmu Komputer*, 13(2), 33-41.
- [25] Xu, Shuyuan et al. 2021. "Computer Vision Techniques in Construction: A Critical Review." *Archives of Computational Methods in Engineering* 28(5): 3383–97.
- [26] Yuwono, Bambang. 2015. "Image Smoothing Menggunakan Mean Filtering, Median filtering, Modus Filtering Dan Gaussian Filtering." *Telematika* 7(1).
<http://jurnal.upnyk.ac.id/index.php/telematika/article/view/416> (December 13, 2023).
- [27] Dionisius Dh. *Indonesian Batik Motifs Dataset*. Kaggle. [Online]. Available: <https://www.kaggle.com/dionisiusdh/indonesian-batik-motifs/data>