

## **HYBRID ALGORITMA CONVOLUTIONAL NEURAL NETWORK DENGAN SUPPORT VECTOR MACHINE UNTUK KLASIFIKASI JENIS TENUN TIMOR**

**Budiman Baso<sup>\*1</sup>, Risald<sup>2</sup>, Nurul Huda<sup>3</sup>**

1,2,3Universitas Timor, Kabupaten Timor Tengah Utara

Email: <sup>1</sup>budimanbaso@gmail.com, <sup>2</sup>risaldsyarifuddin@gmail.com, <sup>3</sup>nurulhuda@unimor.ac.id

<sup>\*</sup>Penulis Korespondensi

(Naskah masuk: 13 Februari 2024, diterima untuk diterbitkan: 08 Desember 2025)

### **Abstrak**

Setiap wilayah di Pulau Timor memiliki motif khas pada tenunnya yang mencerminkan keberagaman budaya setempat, penelitian ini mendalamai keragaman motif kain tenun di Pulau Timor, di mana setiap wilayah memiliki karakteristik motif yang mencerminkan kekayaan budaya lokal. Motif dan proses pembuatan tenun menjadi cerminan dari jenis dan asal usul setiap kain tenun di pulau ini. Terdapat tantangan dalam membedakan kain tenun Timor yang sangat bervariasi, terutama karena kemiripan motif yang bisa muncul di wilayah yang berbeda. Dengan menyadari kompleksitas ini, penelitian ini bertujuan mengatasi kesulitan tersebut dengan mengusulkan penggunaan Pendekatan hybrid algoritma memadukan keunggulan ekstraksi fitur *Convolutional Neural Network* (CNN) dalam mengidentifikasi corak motif atau tekstur kain tenun dengan keahlian *Support Vector Machine* (SVM) dalam klasifikasi. Dengan demikian, SVM dapat membantu mengurangi risiko *overfitting* yang mungkin terjadi pada model CNN, sambil meningkatkan akurasi klasifikasi pada dataset kain tenun. Hasil eksperimen menunjukkan bahwa pendekatan hybrid ini melampaui kinerja algoritma klasifikasi CNN secara mandiri. Metode SVM *multi class One Vs One* (OVO) dengan kernel RBF pada model hybrid mencapai performa terbaik dengan tingkat akurasi mencapai 98,95%, presisi 99,03%, recall 98,95%, dan F1-Score 98,99%. Selain itu, waktu komputasi yang lebih efisien, menunjukkan keunggulan pendekatan ini dalam menangani masalah klasifikasi multi class pada dataset citra tenun Timor.

**Kata kunci:** *Klasifikasi, Tenun Timor, Convolutional Neural Network (CNN), Support Vector Machine (SVM).*

## **HYBRID ALGORITHM OF A CONVOLUTIONAL NEURAL NETWORK WITH A SUPPORT VECTOR MACHINE FOR THE CLASSIFICATION OF THE TYPE OF TIMOR WEAVING FEATURES**

### **Abstract**

*Each region on Timor Island has a distinctive motif in its weaving that reflects the diversity of local culture, this research explores the diversity of woven fabric motifs on Timor Island, where each region has a characteristic motif that reflects the richness of local culture. The motifs and weaving process are a reflection of the type and origin of each woven fabric on the island. There are challenges in distinguishing Timor's highly varied woven fabrics, especially due to the similarity of motifs that can appear in different regions. Recognising this complexity, this research aims to overcome this difficulty by proposing the use of a hybrid approach that combines the advantages of Convolutional Neural Network (CNN) feature extraction in identifying the motif pattern or texture of woven fabrics with the expertise of Support Vector Machine (SVM) in classification. Thus, SVM can help reduce the risk of overfitting that may occur in CNN models, while improving classification accuracy on woven fabric datasets. Experimental results show that this hybrid approach surpasses the performance of the CNN classification algorithm independently. The SVM multi-class One Vs One (OVO) method with RBF kernel in the hybrid model achieves the best performance with 98.95% accuracy, 99.03% precision, 98.95% recall, and 98.99% F1-Score. In addition, the computation time is more efficient, showing the superiority of this approach in handling multi-class classification problems on ci datasets.*

**Keywords:** *Classification, Timor Weaving, Convolutional Neural Network (CNN), Support Vector Machine (SVM).*

## 1. PENDAHULUAN

Timor merupakan salah satu pulau yang terbagi atas dua negara dengan luas pulaunya sekitar 30.777 km<sup>2</sup>. di sebelah timur pulau Timor merupakan wilayah Negara Timor leste sedangkan di sebelah timur barat pulau Timor merupakan wilayah Negara Kesatuan Republik Indonesia, wilayahnya masuk kedalam provinsi Nusa Tenggara Timur (NTT). Pulau Timor dikenal sebagai penghasil cendana, namun tidak hanya cendana saja pulau ini juga dikenal kaya akan budaya, salah satunya adalah budaya menenun.

Menenun adalah teknik sederhana dalam pembuatan kain secara tradisional pada masyarakat Timor, yaitu dengan menggabungkan benang secara bersilang secara bergantian antara benang lusi dan pakan. Dilihat dari teknik pembuatannya tenun Timor dihasilkan dengan cara Futsus (Ikat), Buna (Talik) yaitu dilakukan dengan anyaman sehingga tampak sepadan dikedua sisi dan terakhir adalah Lotis (Sotis) merupakan kain tenun dengan gaya sulam. Dari ketiga teknik yang digunakan akan menghasilkan motif yang sangat beragam yang dapat menunjukkan jenis dan asal dari tenun Timor (Siombo, 2019).

Kain tenun merupakan tradisi secara turun temurun yang hingga kini masih tetap hidup di Timor tepatnya di provinsi Nusa Tenggara Timur (NTT). Beragamnya jenis kain tenun di Timor menyebabkan sulit dalam membedakan antara jenis kain tenun dan asalnya oleh sebagian orang, setiap wilayah dipulau Timor memiliki motif kain tenunnya masing-masing yang menggambarkan budaya setempat (Tallo, 2003). Terdapat motif kain tenun yang terlihat mirip akan tetapi memiliki jenis yang berbeda. Setiap motif dan proses pembuatan tenun di pulau Timor dapat menggambarkan jenis dan asal dari tenun tersebut. Sehingga untuk membedakan kain tenun Timor secara visual dapat dilihat dari corak motif atau tekstur yang terkandung pada kain tenun Timor.

Karakteristik dari setiap kain tenun Timor memiliki perbedaan dan beragam, ini disebabkan karena proses cara pembuatan dan bahan yang digunakan beraneka ragam dan berbeda-beda. Seperti pada tenun Timor yang dibuat dengan teknik futsus memiliki degradasi pada motif yang dihasilkan, adapun tenun yang dihasilkan dengan teknik Buna dan Sotis juga memiliki karakternya sendiri, karakter yang ada dapat menjadi ciri khas pada tenun namun dapat menjadi persoalan ketika akan dilakukan proses pengenalan pola motifnya dengan menggunakan sistem. Dibutuhkan percobaan dalam mendapatkan algoritma yang mampu berjalan secara optimal dalam proses pengenalan pola motif tenun sesuai dengan karakteristiknya (Baso dan Suciati, 2020).

Dengan memanfaatkan teknologi dibidang pengolahan citra dan visi komputer setiap jenis kain tenun Timor dapat dikenali dengan menggunakan teknik pengenalan pola berbasis citra. Untuk menghasilkan sistem yang dapat dengan baik mengenali setiap jenis tenun Timor dilihat dari pola motifnya dibutuhkan algoritma yang tepat dalam

mengenali motif tenun sesuai dengan karakteristik data tenun.

Penelitian yang membahas mengenai klasifikasi motif tenun Timor dengan teknik *machine learning* telah dilakukan oleh (Kelen and Baso, 2023), dengan mengimplementasikan algoritma klasifikasi *multi class SVM* berdasarkan fitur citra tenun yang telah diekstrak menggunakan metode *Speeded Up Robust Feature* (SURF) dengan representasi fitur *Bag of Visual Words* (BoVW), proses klasifikasi dilakukan pada 7 kelas motif citra tenun Timor. Pada percobaan yang dilakukan, algoritma klasifikasi *multi class SVM* yaitu metode *One Versus All* (OVA) menggunakan kernel linear mendapatkan hasil terbaik dengan nilai *Accuracy* mencapai 98,10%.

Berikutnya (Prayoga, dkk., 2023), melakukan klasifikasi citra batik Yogyakarta menggunakan arsitektur *Convolutional Neural Network*. Sebanyak 600 citra batik digunakan dalam penelitiannya, terdiri dari 3 motif berbeda seperti kawung, ceplok, dan parang. Berdasarkan percobaan yang dilakukan, diperoleh akurasi terbaik sebesar 87,83%. Keberhasilan ini diperoleh dari arsitektur CNN yang menggunakan total 9 lapisan pada proses ekstraksi ciri, komposisi arsitektur ini mencakup 6 lapisan konvolusi dan 3 lapisan subsampling.

Penelitian yang menggunakan algoritma *Convolutional Neural Network* (CNN) untuk klasifikasi motif batik dilakukan oleh (Maulana, dkk., 2023), Penelitian ini menggunakan teknik *Deep Learning*, dengan menggunakan model CNN untuk mengekstraksi data citra batik dua dimensi. Pada penelitiannya data citra sebanyak 1320 digunakan sebagai data latih dengan 80 data validasi, dan 120 data uji. Hasil pengujian klasifikasi pada keempat kelas motif batik yang digunakan mencapai 70% (*passing grade*) pada salah satu kelas maka dapat diklasifikasikan sebagai salah satu dari kelas tersebut.

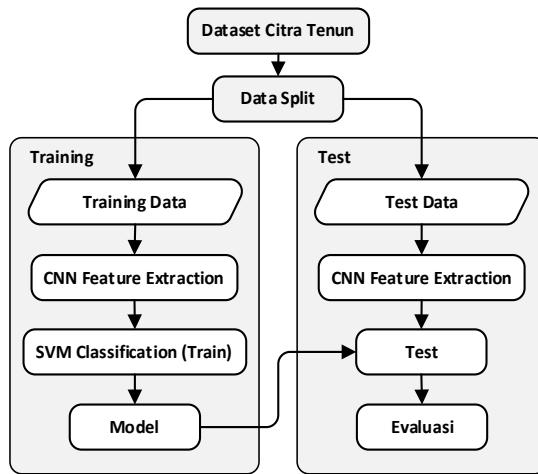
Dalam penelitiannya (Ilahi, dkk., 2022), dengan pendekatan *deep learning* berbasis *Convolutional Neural Network* (CNN), digunakan untuk klasifikasi 5 jenis motif batik, yaitu; ceplok, kawung, lereng, nitik, dan parang, dalam pengujinya memperoleh hasil akurasi sebesar 96%. Selanjutnya penggunaan *Convolutional Neural Network* untuk klasifikasi lima jenis motif batik juga telah dilakukan (Meranggi, dkk., 2022), dengan menerapkan arsitektur ResNet-18 dalam pengujinya, diperoleh hasil akurasi terbaik sebesar 88,88%.

Pada penelitian (Kadyanan, 2022) telah berhasil mengimplementasikan metode *Convolutional Neural Network* dalam pengenalan kain Endek Bali, dengan melakukan perubahan parameter pada nilai *learning rate* dan nilai batas minimum perubahan *error threshold* selama proses pelatihan data, hal ini mempengaruhi terjadinya perbedaan nilai *cross entropy* yang dihasilkan. Sehingga pada penelitian memperoleh nilai akurasi sebesar 80% dalam pengenalan kain Endek Bali.

Dengan merujuk pada penelitian-penelitian sebelumnya yang telah mengimplementasikan algoritma klasifikasi untuk pengenalan pola pada kain tradisional tenun dan batik, pada penelitian ini mengadopsi pendekatan yang menggabungkan keunggulan *Convolutional Neural Network* (CNN) dalam mengekstraksi fitur dari citra kain tradisional dengan kemampuan *Support Vector Machine* (SVM) dalam melakukan klasifikasi berdasarkan fitur-fitur yang telah diekstraksi. Menggunakan SVM dalam tahap klasifikasi dapat memberikan peningkatan signifikan terutama dalam menangani masalah klasifikasi citra yang kompleks, seperti pada jenis-jenis tenun Timor. SVM dikenal sebagai algoritma klasifikasi yang kuat dan mampu menangani dataset dengan dimensi tinggi serta memberikan performa yang baik dalam mengenali pola-pola yang kompleks. Integrasi kekuatan CNN dan SVM diharapkan dapat mengoptimalkan kinerja sistem dalam mengenali dan mengklasifikasikan motif-motif tenun Timor dengan lebih akurat dan efisien.

## 2. METODE PENELITIAN

Metodologi penelitian yang dilakukan terdiri dari pengumpulan dataset citra tenun Timor, split dataset, ekstraksi fitur citra, pembentukan model klasifikasi (training), dan testing. Langkah terakhir adalah perhitungan performa (evaluasi). Gambar 1 menunjukkan alur metode penelitian.



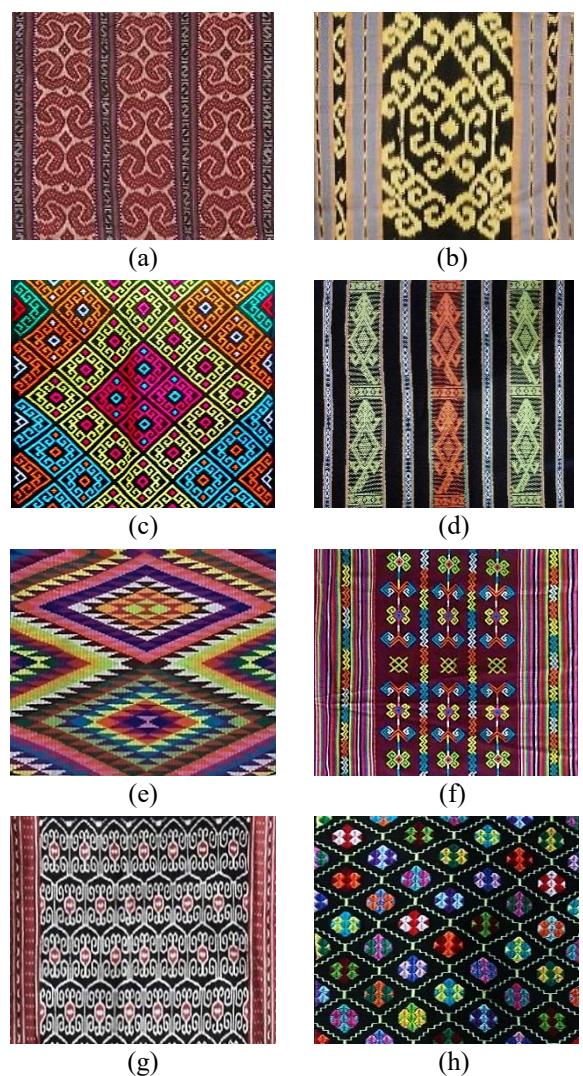
Gambar 1. Alur metode penelitian

Dalam pendekatan ini, CNN digunakan untuk mengekstraksi fitur-fitur dari citra tenun Timor. Fitur-fitur yang diekstraksi oleh CNN dari setiap citra tenun kemudian disusun menjadi vektor fitur yang merepresentasikan setiap gambar. Selanjutnya proses pelatihan dengan algoritma SVM, bertujuan untuk memisahkan dan mengklasifikasikan vektor-vektor fitur yang dihasilkan oleh CNN ke dalam kelas-kelas yang sesuai dengan jenis tenun Timor sehingga menghasilkan model pelatihan. Langkah terakhir adalah melakukan evaluasi, model hasil pelatihan kemudian dievaluasi menggunakan data validasi atau uji untuk mengukur kinerjanya. Selain itu, terdapat

kemungkinan pengaturan parameter pada kedua algoritma, baik CNN maupun SVM, untuk meningkatkan akurasi dan performa klasifikasi.

### 2.1. Dataset

Dataset yang digunakan dalam penelitian ini adalah citra tenun Timor yang terdiri dari delapan kelas motif tenun Timor yaitu Kaimafafa, Kemak, Buna, Kauniki, Naisa, Nunkolo, Biboki, dan Weulun. Sebanyak 960 dataset citra tenun Timor dengan 8 kelas motif yang digunakan pada penelitian ini. Gambar 2 menunjukkan data tenun Timor dari masing-masing kelas motif.

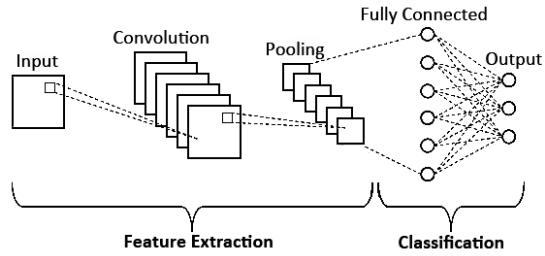


Gambar 2. Ragam motif tenun Timor,  
(a) Kaimafafa, (b) Kemak, (c) Buna, (d) Kauniki,  
(e) Naisa, (f) Nunkolo, (g) Biboki, (h) Weulun.

### 2.2. Convolutional Neural Network (CNN)

*Convolutional Neural Network* (CNN) merupakan algoritma *Deep learning* karena memiliki struktur yang dalam. Algoritma CNN merupakan hasil dari pengembangan *Multilayer Perceptron* (MLP) yang memungkinkan untuk melakukan pengolahan data dua dimensi sehingga algoritma ini

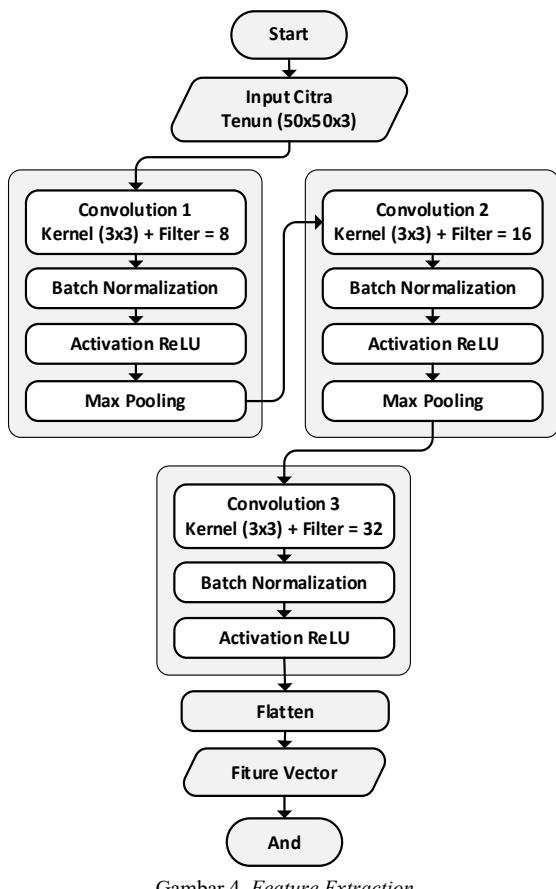
dapat digunakan dalam pengelolahan data citra. Arsitektur dari CNN secara umum dibagi menjadi 2 bagian besar, yaitu bagian *Feature Extraction* dan bagian *Classification* (Hakim, dkk., 2023). Contoh arsitektur CNN dapat diilustrasikan pada Gambar 3.



Gambar 3. Arsitektur CNN

### 2.2.1. Feature Extraction

*Feature extraction* mempunyai lapisan yang terdiri dari *Convolutional layer*, *Activation function ReLU* dan *Pooling layer* yang bekerja secara bertahap untuk menangkap pola dan fitur-fitur penting dari data citra, membentuk representasi yang semakin abstrak. Gambar 4 menampilkan proses *feature extraction* arsitektur CNN yang digunakan dalam penelitian ini.



Gambar 4. Feature Extraction

*Feature extraction* melibatkan serangkaian lapisan yang bertugas menerjemahkan input menjadi fitur-fitur numerik berdasarkan karakteristik unik dari inputan citra, atau dapat dikatakan sebuah proses yang bertujuan mengekstraksi fitur penting dari data input.

Dalam penelitian ini, *feature extraction* pada arsitektur CNN memiliki tiga lapisan konvolusi dalam proses pengambilan dan peningkatan fitur-fitur penting dari citra input. Lapisan pertama adalah lapisan input (*input layer*), ukuran citra inputan adalah 50x50 piksel dengan 3 saluran warna (RGB). Selanjutnya lapisan konvolusi (*convolutional layer*) terdiri dari 3 lapisan konvolusi berturut-turut dengan setiap lapisan konvolusi diikuti oleh *batch normalization* dan aktivasi ReLU. Setiap lapisan konvolusi memiliki jumlah filter yang berbeda yaitu 8, 16, dan 32 filter menggunakan ukuran kernel sama yaitu 3x3. Dalam implementasi, digunakan dua lapisan *max pooling*, masing-masing dengan jendela ukuran 2x2 dan pergeseran (stride) sebesar 2. *Max pooling* digunakan untuk mengurangi dimensi spasial dan kompleksitas model.

Dengan menambahkan lapisan konvolusi, model dapat menangkap fitur-fitur yang semakin abstrak dan kompleks. Pentingnya melakukan *batch normalization* dapat membantu mengurangi ketergantungan terhadap inisialisasi bobot dan mempercepat pelatihan. Ini membantu memastikan bahwa distribusi input ke setiap lapisan konvolusi tetap stabil selama pelatihan. Proses ini dilakukan secara berurutan melalui lapisan-lapisan konvolusi, menghasilkan representasi fitur-fitur semakin kompleks dari gambar input. Representasi-fitur ini kemudian dapat digunakan untuk proses selanjutnya seperti klasifikasi atau deteksi objek dalam jaringan saraf yang lebih lanjut atau dengan menggunakan metode klasifikasi tambahan seperti *Support Vector Machine* (SVM).

#### a. Convolutional Layer

*Convolutional layer* adalah salah satu lapisan utama dalam arsitektur CNN, lapisan ini berfungsi mengekstrak fitur-fitur penting dari citra input. Bagian ini menggunakan filter atau kernel untuk melakukan operasi konvolusi pada citra input. Filter ini bergerak ke seluruh bagian citra dan mengekstraksi berbagai fitur penting dari citra. Filter bergerak melalui citra dengan langkah (*stride*) tertentu, yang mengatur seberapa jauh filter bergeser setiap kali melakukan konvolusi (Antoni, dkk., 2023).

$$\text{Output} = \frac{W - F + 2P}{S} + 1 \quad (1)$$

Rumus (1) di atas digunakan untuk menghitung dimensi spasial dari volume output. Hyperparameter yang terlibat mencakup ukuran volume input (*W*), ukuran filter (*F*), nilai Stride (*S*) yang menentukan seberapa besar filter bergerak melalui citra input, dan jumlah zero padding (*P*) yang menunjukkan seberapa banyak nilai nol yang ditambahkan di sekitar tepi citra.

Selama proses konvolusi, filter mengumpulkan informasi lokal dari setiap bagian citra, dan hasilnya disebut *feature map* (Putri, dkk., 2021). *Feature map* ini merupakan peta aktivasi yang mencerminkan lokasi dan kekuatan deteksi filter pada citra input, menunjukkan di mana pola atau fitur khusus terdeteksi.

### b. Batch Normalization

*Batch normalization* digunakan dalam *deep learning* untuk meningkatkan kecepatan dan stabilitas pelatihan model. Ini dilakukan dengan normalisasi output dari lapisan sebelum ke fungsi aktivasi. Tujuannya adalah untuk membuat distribusi nilai-nilai yang dikirim dari satu lapisan ke lapisan berikutnya menjadi lebih stabil dengan cara normalisasi output untuk setiap batch data yang diproses melalui lapisan tersebut. Hal ini membantu mengurangi masalah seperti gradien yang terlalu besar atau terlalu kecil, yang dapat menghambat proses pembelajaran (Norhikmah, dkk., 2022).

*Batch normalization* dilakukan dengan mengubah nilai-nilai input dari suatu lapisan sehingga rata-rata mendekati nol dan standar deviasi mendekati satu. Setelah normalisasi, dilakukan penyesuaian ulang menggunakan parameter skala dan geser sebelum hasilnya diteruskan ke fungsi aktivasi. Dengan cara ini, *Batch Normalization* membantu jaringan saraf belajar lebih stabil dan efisien, mempercepat proses pelatihan (Purnomo dan Tjandrasa, 2020). Berikut adalah rumus dari *Batch normalization*:

Perhitungan normalisasi:

$$\hat{x}_i = \frac{x_i - \mu_B}{\sqrt{\sigma_B^2 + \epsilon}} \quad (2)$$

$\hat{x}_i$  = Normalisasi dari elemen  $x_i$

$\mu_B$  = Rata-rata mini-batch untuk elemen  $x_i$  diseluruh dimensi.

$\sigma_B^2$  = Variansi mini-batch untuk elemen  $x_i$  diseluruh dimensi.

$\epsilon$  = Konstanta kecil yang meningkatkan stabilitas numerik jika variansi sangat kecil.

Penyesuaian dan Penskalaan:

$$y_i = \gamma \hat{x}_i + \beta \quad (3)$$

$y_i$  = Hasil akhir setelah menyesuaikan dan penskalaan.

$\gamma$  = Parameter skala yang dapat dipelajari.

$\beta$  = Parameter pergeseran yang dapat dipelajari.

Kedua rumus ini menjelaskan bagaimana *Batch normalization* menormalkan input dengan mengurangkan rata-rata mini-batch dan membaginya dengan deviasi standar mini-batch. Selanjutnya, hasilnya dapat disesuaikan dan diskalakan dengan parameter yang dapat dipelajari ( $\gamma$ ) dan ( $\beta$ ) untuk mempertahankan fleksibilitas dalam pelatihan jaringan saraf (Purnomo dan Tjandrasa, 2021).

### c. Activation Function

*Activation function* merupakan fungsi matematis yang menentukan apakah neuron dalam jaringan akan diaktifkan atau tidak, berdasarkan pada tingkat aktivitas internal yang dihasilkan oleh fungsi penjumlahan di dalam neuron (*summation function*).

Fungsi ini menggambarkan hubungan antara input yang diterima dan output yang dihasilkan, bisa berbentuk *linear* atau *non-linear* (Akil, 2023).

Pada penelitian ini, fungsi aktivasi ReLU yang digunakan karena kecepatan komputasinya dan kemampuannya menangani masalah gradien yang hilang dalam *deep networks*. *Rectified Linear Unit* (ReLU) adalah fungsi aktivasi yang umum digunakan dalam algoritma CNN. ReLU mengubah nilai input *neuron* atau *feature map* yang dihasilkan dari *convolution layer* ke dalam range 0 hingga infinity. Secara matematis, fungsi aktivasi ReLU didefinisikan sebagai berikut:

$$F(x) = \max(0, x) \quad (4)$$

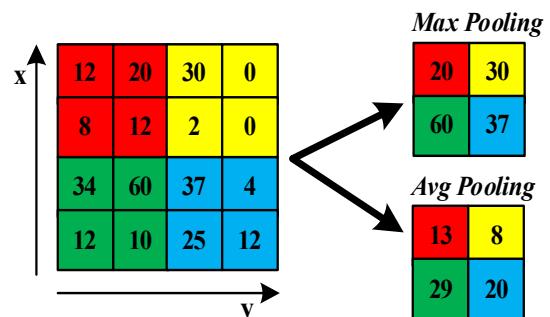
$F(x)$  = nilai dari ReLU activation

$x$  = nilai matrix dari citra

Dalam istilah yang lebih sederhana, jika nilai masukan ( $x$ ) positif, ReLU akan menjaga nilainya, tetapi jika nilai masukan  $x$  negatif, ReLU akan mengubahnya menjadi 0. ReLU memperkenalkan unsur non-linearitas, memungkinkan jaringan saraf untuk memahami pola yang lebih kompleks. Selain itu, ReLU membantu mencegah masalah vanishing gradient selama pelatihan (Tena, dkk., 2023).

### d. Pooling Layer

*Pooling* atas *subsampling* adalah proses pengurangan ukuran matriks dengan menggunakan operasi *pooling* atau mengurangi dimensi dari representasi yang dihasilkan. Hal ini biasanya dilakukan melalui teknik seperti *max pooling* atau *average pooling* (Nurjannah, dkk., 2022). Pada prinsipnya *pooling layer* terdiri dari sebuah filter dengan ukuran dan stride tertentu yang akan bergeser pada seluruh area *feature map*. Berikut ini merupakan gambar operasi *max pooling* dan *average pooling*.



Gambar 5. Max Pooling dan Average Pooling

Tujuan dari *pooling layer* adalah untuk mengurangi dimensi dari *feature map* melalui *downsampling*, yang membantu mempercepat komputasi karena jumlah parameter yang perlu diperbarui menjadi lebih sedikit. Hal ini juga dapat membantu mengatasi *overfitting* dengan melakukan reduksi pada jumlah parameter dan fokus pada fitur-fitur yang paling penting dari data (Bowo, dkk., 2020).

### 2.2.2 Classification

Bagian ini merupakan akhir dari jaringan CNN terdiri dari *fully connected layers* dan *softmax layer*, bertugas dalam melakukan klasifikasi atau prediksi terhadap kelas-kelas yang diinginkan berdasarkan representasi fitur yang diekstraksi sebelumnya (Maulana, dkk., 2023).

#### a. Fully-Connected Layer

*Feature map* yang dihasilkan setelah melalui lapisan konvolusi memiliki bentuk array multidimensional. Oleh karena itu, *feature map* tersebut harus mengalami proses *flatten* sebelum masuk ke lapisan *fully connected*. Proses *flatten* ini bertujuan untuk mengubah bentuk fitur (*reshape feature map*) menjadi vektor satu dimensi, sehingga dapat dijadikan input untuk lapisan *fully connected*. Proses ini mempersiapkan fitur-fitur untuk masuk ke lapisan *fully connected* (Putri, dkk., 2021).

*Fully connected layer* beroperasi dengan melakukan proses perkalian matriks, dimana setiap *neuron* dalam *layer* ini terhubung sepenuhnya ke semua *neuron* di *layer* sebelumnya. Biasanya, *fully connected layer* digunakan pada dua lapisan terakhir dari arsitektur *neural network* untuk tujuan klasifikasi (Peryanto, dkk., 2020). Untuk menghasilkan probabilitas kelas pada hasil output, seringkali diterapkan fungsi *softmax* pada *fully connected layer*. Fungsi *softmax* memungkinkan interpretasi probabilitas kelas pada tugas klasifikasi multikelas (Herdianto dan Nasution, 2023).

### 2.3. Support Vector Machine (SVM)

Pada algoritma *Support Vector Machine* (SVM), poin utamanya adalah bagaimana mengoptimalkan *hyperplane* yang berfungsi sebagai batas pemisah antara *support vector* pada setiap kelas. SVM sejatinya merupakan *hyperplane* linear yang bekerja hanya pada data yang dapat dipisahkan secara linear. Pada data yang distribusi kelasnya tidak linear, pendekatan Kernel akan digunakan pada fitur data awal dataset (Dewi, dkk., 2020). Pada SVM biasanya terdapat fungsi Kernel yaitu *Linear* (3), *Polynomial* (4), dan *RBF* (5), fungsi Kernel dapat dilihat pada persamaan berikut;

$$K(x_i, x_j) = x_i \cdot x_j \quad (5)$$

$$K(x_i, x_j) = (x_i \cdot x_j + c)^d \quad (6)$$

$$K(x_i, x_j) = \exp\left(\frac{\|x_i \cdot x_j\|^2}{2\sigma^2}\right) \quad (7)$$

SVM merupakan algoritma *machine learning* yang hanya dapat mengklasifikasikan dua kelas (klasifikasi biner) secara linear, dalam mengimplementasikan *multi class* (lebih dari dua kelas) SVM menggunakan dua pendekatan metode untuk klasifikasi *multi class* yaitu *One Versus One* (OVO) dan *One Versus All* (OVA) (Ramadhani, dkk.,

2020). Konsep dari *One Versus One* (OVO) adalah membangun dan menggabungkan beberapa pengklasifikasi biner, sedangkan konsep *One Versus All* (OVA) yaitu secara langsung mempertimbangkan semua data dalam satu formulasi optimasi (Nurkholis, dkk., 2022).

Pendekatan dari metode *One Versus One* (OVO) yaitu memberikan label positif pada salah satu kelas dan negatif pada kelas lainnya. Selanjutnya pada semua kelas, metode klasifikasi yang sama diterapkan dan membuat model klasifikasi berdasarkan data latih. Hasil dari metode tersebut adalah model klasifikasi multipel biner. Pendekatan *One Versus All* OVA pertamakali diperkenalkan oleh Clark dan Boswell pada tahun 1991 dalam (Meidianingsih, 2022). Proses training pada OVA lebih sederhana dengan hanya membagi jumlah proses training menjadi N model, sedangkan pendekatan OVO harus membagi jumlah proses training menjadi  $\frac{N(N-1)}{2}$  model. Pendekatan OVO diperkenalkan oleh Knerr et al. pada tahun 1990 dalam (Meidianingsih, 2022).

Pada penelitian ini parameter dari algoritma SVM yang diujicobakan adalah jenis kernel seperti linear, polynomial dan RBF. Sedangkan metode multi class yang digunakan yaitu *One Versus One* (OVO) dan *One Versus All* (OVA).

### 2.5. Perhitungan Performa

Pada tahapan ini dilakukan perhitungan performa dari algoritma CNN, dan hybrid algoritma CNN dan SVM. Performa yang dihitung adalah *Accuracy*, *Precision*, *Recall*, dan *F1-Score* (Blasch, dkk., 2021). Ditunjukkan pada persamaan (7), (8), (9), dan (10). TP adalah *True Positive*, TN adalah *True Negative*, FP adalah *False Positive*, dan FN adalah *False Negative* (Rahmad, 2020).

$$\text{Accuracy} = \frac{TP+TN}{TP+FP+FN+TN} \quad (8)$$

$$\text{Precision} = \frac{TP}{TP+FP} \quad (9)$$

$$\text{Recall} = \frac{TP}{TP+FN} \quad (10)$$

$$\text{F1 Score} = 2 * \frac{\text{Precision} * \text{Recall}}{\text{Precision} + \text{Recall}} \quad (11)$$

### 3. HASIL DAN PEMBAHASAN

Dalam rangka melakukan klasifikasi tenun Timor berbasis citra, langkah pertama yang dilakukan adalah tahapan *preprocessing*, yang melibatkan penyesuaian ukuran dataset citra tenun dengan melakukan resize. Selanjutnya, pendekatan yang diadopsi menggabungkan keunggulan *Convolutional Neural Network* (CNN) untuk mengekstraksi fitur dari citra kain tradisional, dengan memanfaatkan kemampuan *Support Vector Machine* (SVM) dalam melakukan klasifikasi berdasarkan fitur-fitur yang telah diekstraksi tersebut.

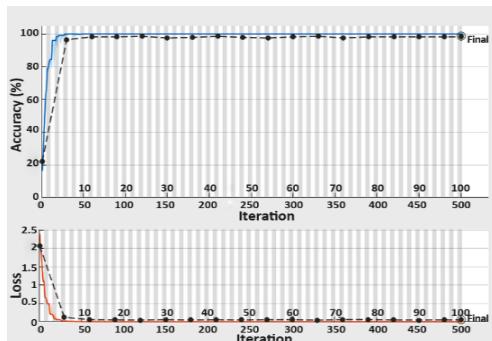
### 3.1. Hasil Klasifikasi CNN

Tabel 3 menunjukkan hasil performa dari algoritma CNN secara mandiri, adapun jumlah *epochs* adalah parameter yang diujicobakan, semakin banyak jumlah epochs diberikan akan meningkatkan waktu komputasi.

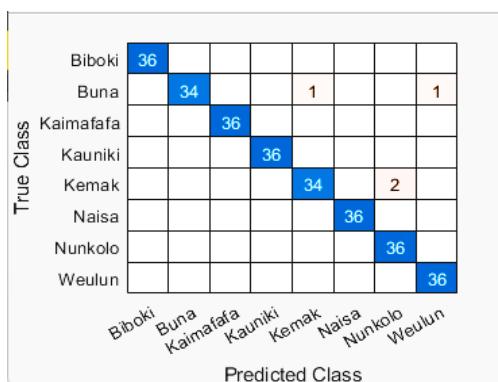
Tabel 3. Performa CNN

Metrik	Epochs				
	10	25	50	75	100
Accuracy	97,57	97,92	98,26	98,61	98,61
Precision	97,59	97,94	98,28	98,62	98,64
Recall	97,56	97,91	98,26	98,61	98,61
F1-score	97,58	97,93	98,27	98,62	98,62
Waktu Komputasi	10,46	22,57	48,12	65,28	82,24

Berdasarkan perhitungan performa yang dilakukan, algoritma CNN dengan dengan nilai *epochs* 100 memperoleh performa baik pada percobaan yang dilakukan, dengan tigkat *Accuracy* sebesar 98,61%, *Precision* 98,64%, *Recall* 98,61% dan *F1-Score* mencapai 98,62%. Hasil yang diperoleh meningkat seiring dengan peningkatan jumlah *epochs*, namun menyebabkan waktu komputasi menjadi lama seiring dengan jumlah epochs. Penting untuk dicatat bahwa pada *epochs* 100, tidak terlihat perbedaan yang signifikan dalam performa jika dibandingkan dengan epochs sebelumnya. Hal ini menunjukkan bahwa pada titik ini, peningkatan performa tidak begitu besar dan mungkin ada nilai epochs yang optimal untuk model ini.



Gambar 6. Grafik Training Model CNN Epoch 100



Gambar 7. Confusion Matrix Hasil Klasifikasi Algoritma CNN

### 3.2. Hasil Klasifikasi Hybrid CNN dengan SVM

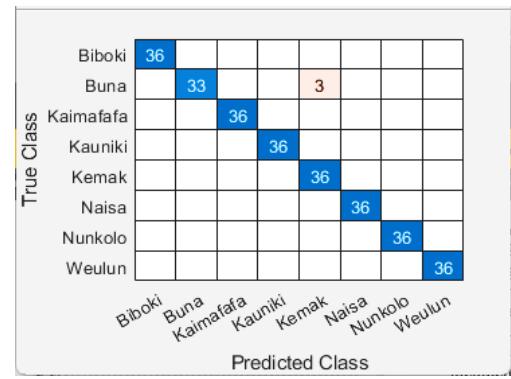
Tabel 4 menunjukkan performa dari hybrid algoritma CNN dan SVM. SVM dengan kernel *RBF* memiliki performa terbaik jika dibandingkan dengan kernel lain. Semua metric performa dari kernel *Radial Basis Function (RBF)* mengungguli kernel yang lain.

Tabel 4. Performa Hybrid CNN dan SVM

No	Metrik	Multi class SVM		
		One Versus One (OVO)	One Versus All (OVA)	Kernel
1	Accuracy	98,61	97,91	<i>Linear</i>
	Precision	98,64	97,96	
	Recall	98,61	97,91	
	F1-score	98,62	97,93	
2	Accuracy	98,61	98,61	<i>Polynomial</i>
	Precision	98,62	98,62	
	Recall	98,61	98,61	
	F1-score	98,62	98,62	
3	Accuracy	98,95	98,61	<i>RBF</i>
	Precision	99,03	98,64	
	Recall	98,95	98,61	
	F1-score	98,99	98,62	

Pada proses klasifikasi tenun Timor dengan menggunakan hybrid algoritma CNN dan SVM, parameter yang diujicobakan pada proses klasifikasi pelatihan model adalah jenis kernel yang digunakan pada SVM, sedangkan metode *multi class SVM* yang digunakan adalah metode *One Versus One (OVO)* dan *One Versus All (OVA)*. Hasil pengujian menggunakan metode SVM *multi class One Versus One (OVO)* dengan kernel *RBF* memperoleh hasil terbaik pada penelitian ini, dengan tigkat *Accuracy* diperoleh mencapai 98,95%, *Precision* 99,03%, *Recall* 98,95% dan *F1-Score* sebesar 98,99%, dengan waktu komputasi 10,96 menit, hal ini menunjukkan bahwa model dapat dengan baik mengklasifikasikan data uji.

Algoritma SVM *musli class One Versus One (OVO)* berdasarkan fitur dari CNN adalah pendekatan yang digunakan untuk menangani masalah klasifikasi *multi class* pada penelitian ini. Hasil klasifikasi yang diperoleh dari algoritma SVM *multi class One Versus One (OVO)* dengan kernel *RBF* memperoleh hasil yang terbaik pada penelitian ini jika dibandingkan dengan algoritma klasifikasi CNN secara mandiri.



Gambar 8. Confusion Matrix Hasil Hybrid CNN dan SVM

### 3.3. Pembahasan

Secara substansi, pendekatan hybrid ini tidak hanya meningkatkan akurasi klasifikasi, tetapi juga menunjukkan potensi penerapan yang lebih luas dalam pelestarian budaya melalui digitalisasi motif tenun Timor. Interpretasi hasil menunjukkan bahwa kombinasi CNN dan SVM *multi class One Versus One* (OVO) mampu mengatasi kompleksitas pola motif tenun yang bervariasi. Implikasi dari penelitian ini memperkuat pentingnya adopsi teknologi kecerdasan buatan untuk membantu identifikasi, dokumentasi, dan klasifikasi kekayaan budaya lokal secara efisien. Ke depan, pendekatan ini dapat menjadi landasan dalam pengembangan sistem pengenalan motif otomatis, digitalisasi katalog motif tenun daerah, serta platform edukatif dan promosi produk tenun khas perbatasan, khususnya di wilayah Nusa Tenggara Timur.

## 4. KESIMPULAN

Dalam konteks klasifikasi 8 kelas motif tenun Timor, pendekatan hybrid menggunakan algoritma CNN untuk ekstraksi fitur dan SVM *multi class* untuk klasifikasi citra tenun terbukti memberikan hasil yang baik dibandingkan dengan menggunakan algoritma klasifikasi CNN secara mandiri. Pendekatan SVM *multi class One Versus One* (OVO) dengan kernel RBF pada hybrid model terbukti efektif dalam menangani masalah klasifikasi *multi class* pada dataset tenun. Selain itu, metode ini menunjukkan waktu komputasi yang lebih efisien yakni 10,96 menit, dan memperoleh performa terbaik dengan tingkat *Accuracy* sebesar 98,95%, *Precision* 99,03%, *Recall* 98,95%, dan *F1-Score* 98,99%. Kombinasi antara CNN dan SVM membawa manfaat, dengan CNN efektif dalam mengekstraksi fitur spasial dari data citra Tenun dan SVM memberikan kestabilan dan performa yang baik dalam proses klasifikasi. Penelitian ini memberikan kontribusi dalam pengembangan metode klasifikasi motif tenun Timor yang dapat digunakan sebagai dasar untuk pelestarian dan pemahaman lebih lanjut terhadap warisan budaya yang diceritakan melalui kain tenun di Pulau Timor.

## DAFTAR PUSTAKA

- AKIL, I. 2023. Komparasi Fungsi Aktivasi Neural Network Pada Data Time Series. *INTI Nusa Mandiri*, 18(1), pp. 78–83. doi: 10.33480/inti.v18i1.4288.
- NURJANNAH, A. F., KURNIASARI, A. S. D., SARI, Z., dan AZHAR, Y. 2022. Pneumonia Image Classification Using CNN with Max Pooling and Average Pooling. *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, 6(2), pp. 330–338. doi: 10.29207/resti.v6i2.4001.
- ANTONI, A., ROHANA, T., dan PRATAMA, A. R. 2023. Implementasi Algoritma Convolutional Neural Network Untuk Klasifikasi Citra Kemasan Kardus Defect dan No Defect', *Building of Informatics, Technology and Science (BITS)*, 4(4), pp. 1941–1950. doi: 10.47065/bits.v4i4.3270.
- BASO, B. dan SUCIATI, N. 2020. Temu Kembali Citra Tenun Nusa Tenggara Timur menggunakan Eskstraksi Fitur yang Robust terhadap Perubahan Skala, Rotasi, dan Pencahayaan. *Jurnal Teknologi Informasi dan Ilmu Komputer*, 7(2), p. 349. doi: 10.25126/jtiik.2020722002.
- BLASCH, E., VAKIL, A., LI, J., dan EWING, R. 2021. Multimodal Data Fusion Using Canonical Variates Analysis Confusion Matrix Fusion. *IEEE Aerospace Conference Proceedings*, 2021-March. doi: 10.1109/AERO50100.2021.9438445.
- BOWO, T. A., SYAPUTRA, H., dan AKBAR, M. 2020. Penerapan Algoritma Convolutional Neural Network Untuk Klasifikasi Motif Citra Batik Solo. *Journal of Software Engineering Ampera*, 1(2), pp. 82–96. doi: 10.51519/journalsea.v1i2.47.
- HAKIM, L., RAHMANTO, R., KRISTANTO, S.P., dan YUSUF, D. 2023. Klasifikasi Citra Motif Batik Banyuwangi Menggunakan Convolutional Neural Network. *Jurnal Teknoinfo*, 17(1), p. 203. doi: 10.33365/jti.v17i1.2342.
- HERDIANTO, H. dan NASUTION, D. 2023. Implementasi Metode Cnn Untuk Klasifikasi Objek. *METHOMIKA Jurnal Manajemen Informatika dan Komputerisasi Akuntansi*, 7(1), pp. 54–60. doi: 10.46880/jmika.vol7no1.pp54-60.
- ILAHI, M. W., APRIYANI, C. N., DESIANI, A., GOFAR, N., ANDRIANI, Y., dan HALIM, M. R. 2022. Classification of Geometric Batik Motif Typical of Indonesian Using Convolutional Neural Network. *Jurnal Teknik Informatika*, 15(1), pp. 91–100. doi: 10.15408/jti.v15i1.24968.
- KADYANAN, I. G. A. G. A. 2022. Pengembangan Aplikasi Deep Learning untuk Identifikasi Kain Endek Bali. *Jurnal Ilmu Komputer*, 14(1), pp. 32–39.
- KELEN, Y. P. K. dan BASO, B. 2023. Klasifikasi Tenun Timor Menggunakan Metode SVM Berdasarkan Speeded Up Robust Features. *Jurnal Teknologi Informasi dan Ilmu Komputer*, 10(6), pp. 1353–1360. doi: 10.25126/jtiik.1067625.
- MAULANA, I., SASTYPRATIWI, H., MUHARDI, H., SAFRIADI, N., dan SUJAINI, H. 2023. Implementasi Convolutional Neural Network ( CNN ) untuk Klasifikasi Motif Batik pada Aplikasi Computer Vision Berbasis Android',

- 9(3), pp. 384–393.
- MEIDIANINGSIH, Q. 2022. Analisis Perbandingan Performa Metode Ensemble Dalam Menangani Imbalanced Multi-Class. *Jurnal Aplikasi Statistika & Komputasi Statistik*, pp. 13–21.
- MERANGGI, D. G. T., YUDISTIRA, N. dan SARI, Y. A. 2022. Batik Classification Using Convolutional Neural Network with Data Improvements. *International Journal on Informatics Visualization*, 6(1), pp. 6–11. doi: 10.30630/joiv.6.1.716.
- NORHIKMAH, -, LUTFHI, A. dan RUMINI. 2022. The Effect of Layer Batch Normalization and Dropout of CNN model Performance on Facial Expression Classification. *JOIV: International Journal on Informatics Visualization*, 6(2–2), p. 481. doi: 10.30630/joiv.6.2-2.921.
- NURKHOLIS, A., ALITA, D. dan MUNANDAR, A. 2022. Comparison of Kernel Support Vector Machine Multi-Class in PPKM Sentiment Analysis on Twitter. *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, 6(2), pp. 227–233. doi: 10.29207/resti.v6i2.3906.
- PERYANTO, A., YUDHANA, A., dan UMAR, R. 2020. Klasifikasi Citra Menggunakan Convolutional Neural Network dan K Fold Cross Validation. *Journal of Applied Informatics and Computing*, 4(1), pp. 45–51. doi: 10.30871/jaic.v4i1.2017.
- PRAYOGA, MAIMUNAH, SUKMASETYA, P., YUDIANTO, M.R.A., dan HASANI, R.A. 2023. Arsitektur Convolutional Neural Network untuk Model Klasifikasi Citra Batik Yogyakarta. *Journal of Applied Computer Science and Technology*, 4(2), pp. 82–89. doi: 10.52158/jacost.v4i2.486.
- PURNOMO, A. dan TJANDRASA, H. 2020. Epileptic Seizure Classification using Deep Batch Normalization Neural Network. *Lontar Komputer : Jurnal Ilmiah Teknologi Informasi*, 11(3), p. 124. doi: 10.24843/lkjiti.2020.v11.i03.p01.
- PURNOMO, A. dan TJANDRASA, H. 2021. Improved Deep Learning Architecture With Batch Normalization for Eeg Signal Processing. *JUTI: Jurnal Ilmiah Teknologi Informasi*, 19(1), p. 19. doi: 10.12962/j24068535.v19i1.a1023.
- RAHMAD, F. 2020 Performance Comparison of Anti-Spam Technology Using Confusion Matrix Classification.
- RAMADHANI, ARNIA, F. dan MUHARAR, R. 2020. Klasifikasi Otomatis Motif Tekstil Menggunakan Support Vector Machine Multi Kelas. *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIK)*, 7(1), pp. 99–108. doi: 10.25126/jtiik.202071428.
- DEWI, N. R., GUNADI, I. A., dan INDRAWAN, G. 2020. Detection of Class Regularity with Support Vector Machine methods'. *Lontar Komputer : Jurnal Ilmiah Teknologi Informasi*, 11(1), p. 20. doi: 10.24843/LKJITI.2020.v11.i01.p03.
- SIOMBO, M. R. 2019. Kearifan Lokal Dalam Proses Pembuatan Tenun Ikat Timor (Studi Pada Kelompok Penenun Di Atambua-Ntt). *Bina Hukum Lingkungan*, 4(1), p. 97. doi: 10.24970/bhl.v4i1.88.
- TALLO, E. C. 2003. Pesona tenun Flobamora', pp. 1–163.
- TENA, S., HARTANTO, R. dan ARDIYANTO, I. 2023. Content-Based Image Retrieval for Traditional Indonesian Woven Fabric Images Using a Modified Convolutional Neural Network Method. *Journal of Imaging*, 9(8). doi: 10.3390/jimaging9080165.
- PUTRI, Y. A., AZHAR, Y., dan MINARNO, A. E. 2021. Klasifikasi Jenis Batik Menggunakan Algoritma Convolutional Neural Network. *Jurnal Reppositor*, 3(2), pp. 199–206. doi: 10.22219/repositor.v3i2.1201.

*Halaman ini sengaja dikosongkan*