

## Pengenalan Citra Kain Tenun Nusa Tenggara Timur Menggunakan *SqueezeNet* dan *Decision Tree*

A G Sooi<sup>1</sup>, F A A Dwiandri<sup>2</sup>

<sup>1-2</sup>Program Studi Ilmu Komputer, Universitas Katolik Widya Mandira

E-mail: adrigabriel@unwira.ac.id<sup>1</sup>, dwiandri1998@gmail.com<sup>2</sup>

**Abstrak.** Pengenalan kain tenun melalui pengolahan citra memiliki nilai tinggi dalam melestarikan warisan budaya dan membantu dalam identifikasi dan klasifikasi produk tekstil tradisional. Untuk tujuan ini, penelitian ini mengusulkan pendekatan yang memanfaatkan pohon keputusan atau *Decision Tree* untuk mengenali gambar kain tenun khas Nusa Tenggara Timur. Efektivitas dalam klasifikasi data dimensi tinggi menjadikannya alat yang ideal untuk memodelkan pola unik yang ada dalam gambar kain tenun. Data set penelitian ini terdiri dari berbagai jenis kain tenun Nusa Tenggara Timur, dan hasil eksperimen menunjukkan keakuratan pendekatan yang kami usulkan dalam mengenali kain-kain ini, mencapai tingkat keberhasilan yang menjanjikan dalam klasifikasi motif dan pola yang kompleks. Temuan ini merupakan kontribusi yang signifikan terhadap pengembangan sistem otomatis untuk mengidentifikasi dan mendokumentasikan kain tenun tradisional, yang pada gilirannya dapat mendukung inisiatif pelestarian budaya dan pertumbuhan industri lokal di Nusa Tenggara Timur.

**Kata kunci:** pengenalan citra kain tenun; *decision tree*; Nusa Tenggara Timur; identifikasi motif dan pola; pelestarian budaya

**Abstract.** The recognition of woven fabrics through image processing has a high value in preserving cultural heritage and assisting in the identification and classification of traditional textile products. To this end, this study proposes an approach that utilizes a Decision Tree (DT) to recognize images of woven fabrics typical of East Nusa Tenggara. DT's effectiveness in high-dimensional data classification makes it an ideal tool for modeling unique patterns present in woven fabric drawings. The dataset consisted of different types of East Nusa Tenggara woven fabrics, and experimental results showed the accuracy of the approach in recognizing these fabrics, achieving promising success rates in the classification of complex motifs and patterns. These findings represent a significant contribution to the development of automated systems for identifying and documenting traditional woven fabrics, which in turn can support cultural preservation initiatives and local industrial growth in East Nusa Tenggara.

**Keywords:** woven fabric recognition; *decision tree*; East Nusa Tenggara; motif and pattern identification; cultural heritage preservation

## 1. Pendahuluan

Pengenalan citra telah menjadi fokus utama dalam berbagai bidang, termasuk pengenalan pola, pengolahan gambar, dan identifikasi objek. Salah satu aplikasi yang semakin berkembang adalah dalam memperkenalkan kain tenun tradisional, suatu aspek penting dari kekayaan budaya yang tersebar di seluruh dunia [1]. Di tengah arus globalisasi dan modernisasi, menjaga warisan budaya seperti kain tenun tradisional menjadi semakin penting. Di Indonesia, khususnya di wilayah Nusa Tenggara Timur, kain tenun memiliki nilai budaya dan sejarah yang sangat dalam [2]. Namun, tantangan muncul dalam mempertahankan praktik tenun tradisional ini di tengah arus perkembangan teknologi dan perubahan sosial [3]. Dalam konteks ini, teknologi pengenalan citra menawarkan solusi yang menarik untuk melestarikan dan mempromosikan kain tenun tradisional, memastikan bahwa warisan budaya yang berharga ini tidak hilang atau terlupakan [4].

Kain tenun tradisional merupakan bagian tak terpisahkan dari identitas budaya suatu masyarakat [5]. Setiap motif dan pola yang dihasilkan dalam kain tenun memiliki makna budaya yang mendalam, menceritakan sejarah, kepercayaan, dan tradisi yang terkandung dalam masyarakat penghasilnya [6]. Namun, dengan adanya tantangan ekonomi, perubahan gaya hidup, dan kurangnya apresiasi terhadap warisan budaya lokal, praktik tenun tradisional sering kali terancam punah [7]. Oleh karena itu, diperlukan upaya yang berkelanjutan untuk mengangkat nilai-nilai kain tenun tradisional, baik sebagai warisan budaya maupun sebagai sumber penghidupan bagi masyarakat pengrajin.

Dalam upaya melestarikan kain tenun tradisional Nusa Tenggara Timur, teknologi menjadi sekutu yang penting. Salah satu pendekatan yang menjanjikan adalah penggunaan metode *Decision Tree* (DT) dalam pengenalan citra. DT adalah algoritma pembelajaran mesin yang telah terbukti efektif dalam klasifikasi data berdimensi tinggi [8]. Dengan menganalisis pola-pola yang terkandung dalam citra kain tenun, DT dapat mengenali dan mengklasifikasikan motif-motif dengan tingkat akurasi yang tinggi. Dengan demikian, penggunaan DT dalam pengenalan citra kain tenun tradisional dapat menjadi langkah penting dalam upaya pelestarian warisan budaya ini.

Penggunaan teknologi pengenalan citra, terutama DT, dalam konteks kain tenun tradisional Nusa Tenggara Timur memiliki potensi besar dalam beberapa aspek. Pertama-tama, teknologi ini dapat membantu dalam proses identifikasi motif dan pola kain tenun secara otomatis. Sebelumnya, proses ini memerlukan pengetahuan yang luas tentang motif-motif tradisional yang dimiliki oleh para ahli atau pengrajin kain tenun. Dengan DT, proses identifikasi ini dapat dilakukan secara cepat dan efisien, menghemat waktu dan upaya, ini terbukti untuk data set dengan karakteristik berpola, DT terbukti mengungguli SVM [9]. Hal ini juga membuka peluang bagi penggunaan teknologi dalam pendokumentasian dan pelestarian kain tenun tradisional. Dengan memiliki sistem otomatis yang dapat mengenali dan mengklasifikasikan motif-motif kain tenun, informasi tentang kain-kain tersebut dapat tersimpan secara digital, memungkinkan akses yang lebih mudah dan pembelajaran lebih lanjut. Penggunaan algoritma bantu dalam pengklasifikasian menggunakan DT dibutuhkan untuk proses menciptakan data set dengan fitur dan *instance* yang dapat diolah pada komputer dengan sumber daya kecil.

Telah cukup banyak penelitian yang menggunakan data set kain tenun dari berbagai daerah untuk melakukan pengenalan menggunakan teknologi kecerdasan buatan dan pembelajaran mesin. Beberapa penelitian terkait untuk ini mencakup penggunaan ragam pengklasifikasi dengan keunggulan dan kekurangannya. Sebagai contoh, Tamara [10] melakukan penelitian tentang kain tenun dari daerah penghasil terkenal, seperti dari Palembang, Sumatera Barat, dan Jawa Barat. Penelitian ini melibatkan klasifikasi berbagai jenis kain, seperti kain songket pandai singkek, kain songket lupus, dan kain tenun lurik, menggunakan metode *Deep Learning* yang disebut *Convolutional Neural Network* (CNN). Penelitian tersebut menunjukkan efektivitas pendekatan CNN untuk klasifikasi pengenalan citra dengan menggunakan Adam *optimizer* dan *epoch* 100, rasio data 80%:20%, ukuran kernel  $3 \times 3$ , dan *learning rate* 0,001. Namun, penelitian ini hanya menghasilkan nilai akurasi 73% dan *error rate* 1,3385.

Salah satu penelitian lainnya dilakukan oleh Wicaksana [11] mengenai Gringsing yang merupakan kain tradisional unik yang eksklusif untuk Desa Tenganan Pegringsingan. Model yang dibangun

menggunakan metode CNN memanfaatkan arsitektur AlexNet. Untuk mengevaluasi performa model, pengujian dilakukan untuk menentukan waktu pelatihan, akurasi, presisi, *recall*, dan nilai *f-measure*. Namun, hasil penelitian menunjukkan bahwa model dapat menyelesaikan 100 pelatihan *epoch* dalam 19,33 jam dengan nilai akurasi 76%, presisi 74,1%, *recall* 72,3%, dan *F-measure* 0,73.

Dalam penelitian lain, Rizki [12] menggunakan model *Faster R-CNN* dengan arsitektur VGG untuk menyelidiki kinerja pengenalan dan klasifikasi motif tenun melayu. Penelitian ini mengevaluasi tingkat akurasi, presisi, dan *recall*. Algoritma deteksi objek *Faster R-CNN* digunakan untuk mengidentifikasi dan mengklasifikasikan pola kain berdasarkan citra digital kain tenun melayu. Penelitian ini menggunakan 100 data set acak, dengan menggunakan *5-fold cross validation* dan pembagian data 80:20 untuk latih dan uji. Namun, hanya menghasilkan akurasi sebesar 82,14%.

Penelitian selanjutnya yang dilakukan oleh Qureshi [13] menggunakan metode deteksi kontur untuk melakukan proses pengenalan citra kain tenun dengan beberapa pengolahan awal yaitu Penajaman kontras, perubahan menjadi *grayscale*, *gaussian low pass filter*. Namun, penelitian tersebut hanya mampu meraih angka akurasi 90%.

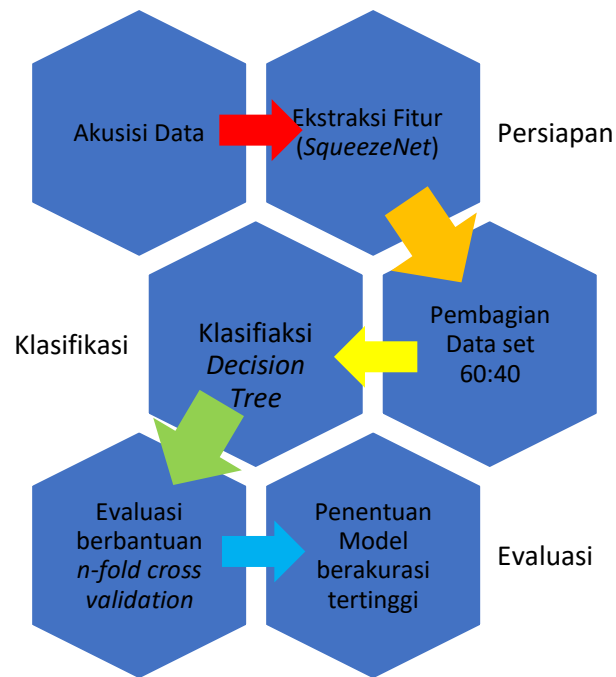
**Tabel 1.** Penelitian Terkait Pengenalan Citra Kain Tenun dan Kontribusi

Peneliti	Metode	Hasil
Tamara [10]	CNN	73%
Wicaksana [11]	CNN	76%
Rizki [12]	Faster R-CNN	82.14%
Qureshi [13]	Resnet50	90%

Merujuk kepada penelitian sebelumnya yang dapat dilihat pada Tabel 1, penelitian sebelumnya hanya menggunakan satu metode. Oleh karena itu, upaya peningkatan dilakukan dengan mengombinasikan pengklasifikasi tradisional seperti DT dengan sebuah pengolahan data set awal yaitu penambahan proses ekstraksi fitur. Proses dimaksud dapat dilakukan menggunakan ragam algoritma. Pada penelitian ini dipilih *squeezenet* yang memiliki kinerja baik dalam beberapa penelitian sebelumnya[15]-[17].

## 2. Metode

Penelitian ini dilakukan menggunakan beberapa tahapan yang terstruktur dan dimulai dari proses akuisisi data. Perangkat akuisisi data adalah kamera digital Samsung SMA217F dan Pengolah Citra menggunakan *Processor Celeron* 1GHZ, RAM 12GB tanpa GPU. Proses akuisisi data dilanjutkan ke tahap berikutnya yaitu ekstraksi fitur. Tahap ini adalah menerjemahkan citra menjadi besaran numerik dalam komposisi baris dan kolom melalui proses ekstraksi fitur. Proses ini menggunakan *SqueezeNet* dan menghasilkan data set berukuran 1000 fitur dan 400 *instance*, dalam empat kelas kain. Kemudian, data set dipisahkan dengan komposisi 60% untuk data latih dan 40% data uji. Disiapkan pengklasifikasi *Decision Tree* (DT) guna memodelkan data set latih dan menggunakan *10-fold cross validation* untuk memeriksa model yang dihasilkan dalam proses pengklasifikasian citra. Evaluasi dilakukan dengan mengubah ukuran *n-fold cross validation* dimulai dari 2,3,5,10 dan 20. Secara garis besar keseluruhan proses dapat dilihat pada Gambar 1.



**Gambar 1.** Aliran Proses Eksperimen

### 2.1. Akuisisi Data

Dengan total citra kain tenun sebanyak 400 dan dikelompokkan dalam empat kelas yaitu kain tenun Flores, Rote, Sumba dan Timor, dengan masing-masing citra sebanyak 100. Ukuran citra yang disiapkan adalah berdimensi 2390 x 3207 *pixel*. Selanjutnya citra direduksi ukurannya menjadi 140 x 360 *pixel* dengan kerapatan 96 dpi. Proses ini dilakukan untuk memangkas waktu pelatihan mengingat tidak tersedianya GPU pada pengolah [14]. Pengaturan variabel pada kamera SAMSUNG SMA217F antara lain adalah *exposure* normal, menggunakan *flash*, ISO-500, *metering mode center weight average*, *focal length 25*, *white balance auto*.

### 2.2. Ekstraksi Fitur

Dalam proses ekstraksi fitur, dilakukan penerjemahan *pixel* gambar menjadi nilai numerik berbentuk 1000 fitur dan 400 *instance*. Hal ini dilakukan untuk membantu pemroses lebih ringan dan cepat dalam melakukan pembelajaran terhadap data set yang telah dikelompokkan dalam kelasnya masing-masing. Pemilihan *SqueezeNet* sebagai sarana proses ekstraksi fitur adalah relatif sedikitnya jumlah fitur yang dihasilkan jika dibandingkan dengan pengekstraksi lainnya seperti *InceptionV3* yang mencapai 2000 atau *VGG16* yang mencapai 4000 fitur [15], [16], [17].

### 2.3. Pembagian Dataset 60:40

Pembagian data set dalam *machine learning* menjadi data latih dan data uji adalah langkah penting dalam persiapan data. Salah satu manfaatnya adalah mencegah *overfitting* [18]. Hal ini menjadi satu tantangan besar dalam mengembangkan model pembelajaran mesin adalah mencegahnya agar tidak terlalu pas ke kumpulan data pelatihan. *Overfitting* terjadi ketika model mempelajari kombinasi bobot yang berkinerja baik pada data pelatihan tetapi gagal untuk menggeneralisasi pada data yang belum pernah dilihatnya [19]. Pembagian data set dengan skala 60:40 didasarkan pada ragam penelitian sebelumnya yang juga melakukan pengolahan citra [15]-[17]. Dengan memisahkan data pengujian, dapat memperkirakan bagaimana model akan berperilaku dengan data yang tidak terlihat [20].

#### 2.4. Klasifikasi Decision Tree

*Decision Tree* adalah algoritma pembelajaran mesin yang digunakan untuk klasifikasi dan regresi. Tahapannya dimulai dari Pohon Keputusan atau *decision tree*, yang merupakan struktur pohon yang terdiri dari simpul dan cabang. Setiap simpul mewakili keputusan berdasarkan fitur-fitur tertentu di mana pohon dibangun dengan membagi data berdasarkan nilai fitur hingga mencapai kondisi berhenti (misalnya, jumlah sampel minimum di simpul). Selanjutnya, tahap *Impurity Measures* mengukur seberapa campur aduk data pada simpul. Metrik *impurity* yang umum digunakan dalam *decision tree* adalah *entropy*, atau mengukur jumlah informasi yang diperlukan untuk menggambarkan data. Berikut ini adalah rumus yang digunakan:

$$Entropy(S) = - \sum_{i=1}^c p_i \log_2(p_i) \quad (1)$$

Di mana:

S = himpunan data

c = jumlah kelas

$p_i$  = proporsi sampel yang termasuk dalam kelas  $i$

Selanjutnya *gini index* digunakan untuk mengukur *impurity* dalam simpul. Nilainya antara 0 dan 1. Rumusnya:

$$Gini Index(S) = 1 - \sum_{i=1}^c p_i^2 \quad (2)$$

Kemudian digunakan *standard deviation reduction* untuk mengukur pengurangan deviasi standar setelah pemisahan simpul. Rumusnya adalah *standard deviation reduction* = standar deviasi awal – standar deviasi setelah pemisahan, di mana standar deviasi awal adalah deviasi standar dari seluruh data sebelum pemisahan, sedangkan standar deviasi setelah pemisahan adalah standar deviasi data berdasarkan fitur tertentu. Jika reduksi standar deviasi tinggi setelah pemisahan, berarti pemisahan fitur tersebut memberikan informasi yang signifikan dan mengurangi ketidakpastian dalam klasifikasi [21].

#### 2.5. N-Fold Cross Validation

*Cross validation* adalah teknik yang digunakan dalam *machine learning* untuk mengevaluasi kinerja model dan memastikan bahwa model yang dibangun dapat menggeneralisasi dengan baik pada data yang belum pernah dilihat sebelumnya. Dalam *cross validation*, data dibagi menjadi beberapa sub set yang saling terpisah. Proses ini memungkinkan untuk melatih dan menguji model berkali-kali dengan menggunakan sub set yang berbeda-beda [22].

Salah satu metode *cross validation* yang umum digunakan adalah *n-fold cross validation*. Pada metode ini, data dibagi menjadi *fold*, di mana N-1 *fold* digunakan sebagai data pelatihan dan 1 *fold* digunakan sebagai data pengujian. Proses ini diulang N kali, sehingga setiap *fold* berfungsi sebagai data pengujian satu kali [23], [24].

#### 2.6. Pemilihan model terbaik

Model dengan akurasi tertinggi pada data pengujian dianggap sebagai model terbaik. Namun, juga perlu memperhatikan metrik lain seperti *precision*, *recall*, dan *F1-score* untuk memastikan bahwa model tidak hanya memiliki akurasi tinggi tetapi juga kinerja yang seimbang. Untuk menghindari *overfitting*, dapat menggunakan teknik validasi silang. Dengan membagi data menjadi beberapa lipatan dan menguji model pada setiap lipatan, estimasi performa yang lebih stabil dapat diperoleh [25].

2.7. Citra Kain Tenun



Gambar 2. Ilustrasi Kain Tenun NTT dari empat pulau besar

Kain tenun yang digunakan sebagai sumber data set terbagi dalam empat kelas menurut pulau-pulau besar di Nusa Tenggara Timur. Keempat pulau tersebut adalah Timor, Flores, Sumba dan Rote. Kain dari ke empat pulau tersebut cukup mendominasi penggunaan di dalam keseharian masyarakat. Berikut perwakilan foto dari keempat kelas kain terlihat pada Gambar 2.

3. Hasil dan Pembahasan

Confusion matrix pada Tabel 2 memperlihatkan hasil klasifikasi berdasarkan empat wilayah geografis kelompok kain tenun, yaitu Flores, Rote, Sumba, dan Timor.

Tabel 2. Confusion Matrix Jumlah Instance

		Prediksi				Total
		Flores	Rote	Sumba	Timor	
Aktual	Flores	57	1	0	0	58
	Rote	3	59	3	1	66
	Sumba	1	2	52	1	56
	Timor	0	1	4	55	60
	Total	61	63	59	57	240

Terdapat 57 sampel yang sebenarnya berasal dari wilayah Flores. Model berhasil mengklasifikasikan 57 sampel dengan benar (*true positive*). Terdapat 1 sampel yang salah diklasifikasikan sebagai wilayah Rote (*false negative*). Rote: terdapat 66 sampel yang sebenarnya berasal dari wilayah Rote. Model berhasil mengklasifikasikan 59 sampel dengan benar (*true positive*). Terdapat 3 sampel yang salah diklasifikasikan sebagai wilayah Flores dan 1 sampel sebagai wilayah Timor (*false positive*). Sumba: terdapat 56 sampel yang sebenarnya berasal dari wilayah Sumba. Model berhasil mengklasifikasikan 52 sampel dengan benar (*true positive*). Terdapat 2 sampel yang salah diklasifikasikan sebagai wilayah Rote dan 1 sampel sebagai wilayah Timor (*false positive*). Timor: terdapat 60 sampel yang sebenarnya berasal dari wilayah Timor.

Model berhasil mengklasifikasikan 55 sampel dengan benar (*true positive*). Terdapat 1 sampel yang salah diklasifikasikan sebagai wilayah Rote (*false positive*) dan 4 sampel sebagai wilayah Sumba (*false negative*). Total: Total keseluruhan sampel yang dianalisis adalah 240.

**Tabel 3.** *Confusion Matrix* Proporsi Prediksi


		Prediksi				Total
		Flores	Rote	Sumba	Timor	
Aktual	Flores	93.4%	1.6%	0%	0%	58
	Rote	4.9%	93.7%	5.1%	1.8%	66
	Sumba	1.6%	3.2%	88.1%	1.8%	56
	Timor	0%	1.6%	6.8%	96.5%	60
	Total	61	63	59	57	240

Berdasarkan hasil yang ditampilkan pada Tabel 3, untuk label Flores, terdapat 58 sampel yang sebenarnya berasal dari wilayah Flores. Model berhasil mengklasifikasikan 54 sampel dengan benar (*true positive*) dan 4 sampel salah diklasifikasikan sebagai wilayah Rote (*false negative*). Akurasi klasifikasi untuk wilayah Flores adalah 93.4%. Selanjutnya, untuk kain dengan label Rote, terdapat 66 sampel yang sebenarnya berasal dari wilayah Rote. Model berhasil mengklasifikasikan 62 sampel dengan benar (*true positive*) dan 4 sampel salah diklasifikasikan sebagai wilayah Sumba (*false positive*). Akurasi klasifikasi untuk wilayah Rote adalah 93.7%. Kemudian kain dengan label Sumba memiliki 56 sampel yang sebenarnya berasal dari wilayah Sumba. Model berhasil mengklasifikasikan 49 sampel dengan benar (*true positive*) dan 7 sampel salah diklasifikasikan sebagai wilayah Timor (*false positive*). Akurasi klasifikasi untuk wilayah Sumba adalah 88.1%. Terakhir adalah kain dengan label Timor memiliki 60 sampel yang sebenarnya berasal dari wilayah Timor. Model berhasil mengklasifikasikan 58 sampel dengan benar (*true positive*) dan 2 sampel salah diklasifikasikan sebagai wilayah Sumba (*false negative*). Akurasi klasifikasi untuk wilayah Timor adalah 96.5%.

**Tabel 4.** *Test & Score*

Model	AUC	CA	F1	Prec	Recall	MCC
<i>Decision Tree</i>	0.959	0.929	0.929	0.930	0.929	0.906

Tabel 4 menunjukkan nilai AUC (*Area Under the Curve*) sebesar 0.959 yang berarti bahwa model memiliki kemampuan yang baik dalam membedakan antara kelas positif dan negatif. Semakin mendekati 1, semakin baik performa model. Selanjutnya, Akurasi (CA) sebesar 0.929 menunjukkan bahwa model berhasil mengklasifikasikan 92.9% data dengan benar. Ini adalah metrik yang umum digunakan untuk mengukur performa secara keseluruhan. Kemudian, F1 *score* sebesar 0.929 menggabungkan presisi dan *recall*. Nilai ini menunjukkan keseimbangan antara ketepatan dan kelengkapan prediksi model. Diikuti oleh nilai Presisi (*Precision*) sebesar 0.930 yang menunjukkan seberapa banyak dari prediksi positif yang benar-benar relevan. Semakin tinggi, semakin sedikit *false positive*. Besaran penilaian berikutnya adalah Recall (sensitivitas) sebesar 0.929 yang mengukur seberapa banyak dari total kasus positif yang berhasil diidentifikasi oleh model. Semakin tinggi, semakin sedikit *false negative*. Yang terakhir, nilai MCC (*Matthews Correlation Coefficient*) sebesar 0.906 menggabungkan semua elemen matriks kebingungan (*true positive*, *true negative*, *false positive*, dan *false negative*). Semakin mendekati 1, semakin baik performa model.



**Gambar 3.** Kurva ROC

Kurva ROC yang terlihat pada Gambar 3 memperlihatkan hasil akurasi tertinggi dicapai untuk citra dari kelompok kain tenun berlabel Flores. Dapat dilihat bahwa angka akurasinya mencapai 96.3%

#### 4. Kesimpulan

Kombinasi antara *SqueezeNet* (sebagai metode ekstraksi fitur) dan *decision tree* (sebagai pengklasifikasi) menghasilkan model dengan akurasi yang lebih tinggi daripada penelitian sebelumnya. Akurasi mencapai 92.9%, menunjukkan kemajuan yang signifikan dalam klasifikasi citra. Penggunaan *n-fold cross validation* memberikan hasil akurasi tertinggi. Teknik ini memastikan bahwa model tidak hanya berkinerja baik pada data pelatihan, tetapi juga dapat menggeneralisasi dengan baik pada data yang belum pernah dilihat sebelumnya. Ketersediaan data set primer kain tenun dari wilayah Nusa Tenggara Timur merupakan aset berharga dalam pengembangan model. Data ini memungkinkan untuk melatih dan menguji model dengan konteks yang relevan. Pengurangan dimensi citra membantu dalam proses pengklasifikasi, terutama ketika sumber daya komputasi terbatas yaitu tanpa GPU. Teknik ini memungkinkan untuk mengurangi kompleksitas model tanpa mengorbankan performa. Penelitian dan pengembangan lanjutan dapat dilakukan dari berbagai hal seperti peningkatan jumlah citra, pengklasifikasian menggunakan ragam metode untuk memperbaiki tingkat akurasi.

#### 5. Ucapan Terima Kasih

Disampaikan ucapan terima kasih kepada Asosiasi Perguruan Tinggi Katolik se-Indonesia yang telah memberikan kesempatan publikasi melalui *event* Seminar Nasional Konstelasi.

#### Referensi

- [1] Y. P. K. Kelen and B. Baso, "Klasifikasi Tenun Timor Menggunakan Metode SVM Berdasarkan Speeded Up Robust Features," *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 10, no. 6, Art. no. 6, Dec. 2023, doi: 10.25126/jtiik.1067625.
- [2] S. Ulfa, T. E. br Sinulingga, and J. Sinulingga, "Kain Tenun Tradisional: Warisan Budaya dan Industri Kreatif," *Jurnal Pendidikan Tambusai*, vol. 7, no. 3, pp. 29709–29715, Dec. 2023, doi: 10.31004/jptam.v7i3.11780.
- [3] O. R. Sutopo, E. Z. L. Astuti, M. P. Kuslarassakti, M. Nurriszky, R. Satriani, and A. DwiPrakoso, "Problematika Regenerasi dalam Praktik Budaya Tenun Lokal di Sejatidesa Yogyakarta," vol. 17, no. 2, 2023.



- [4] N. Insani *et al.*, “Pelestarian Budaya Tenun Ikat Bandar Kidul Melalui Kegiatan Kids Fashion Show Competition,” *satwika*, vol. 2, no. 2, pp. 115–120, Dec. 2022, doi: 10.21009/satwika.020206.
- [5] Guslinda, “Kerajinan Tenun Songket Melayu Riau Untuk Pelestarian Kearifan Lokal,” *Jurnal Pigur*, vol. 2, no. 1, pp. 124–130, 2017.
- [6] N. L. Maulidiyah, “Motif Khas Tenun Ikat Troso Sebagai Sumber Pembelajaran Muatan Lokal Seni Rupa Smp Di Kabupaten Jepara,” *Eduarts Jurnal Pendidikan Seni*, vol. 12, no. 1, pp. 70–83, 2023.
- [7] S. Wening and P. D. A. Kusumadewi, “Tren Berkain Generasi Z: Peluang Pengembangan Industri Kreatif Bidang Busana”, [Online]. Available: <https://journal.uny.ac.id/index.php/ptbb/article/viewFile/68011/20550>
- [8] R. Aprianti, K. Evandari, R. A. Pramunendar, and Moch. Soeleman, “Comparison Of Classification Method On Lombok Songket Woven Fabric Based On Histogram Feature,” in *2021 International Seminar on Application for Technology of Information and Communication (iSemantic)*, Sep. 2021, pp. 196–200. doi: 10.1109/iSemantic52711.2021.9573223.
- [9] K. S. Charan, SP. Chokkalingam, and K. K. Shantha Sundari, “Efficiency of Decision tree algorithm for Brain Tumor MRI Images comparing with SVM Algorithm,” in *2022 14th International Conference on Mathematics, Actuarial Science, Computer Science and Statistics (MACS)*, Nov. 2022, pp. 1–4. doi: 10.1109/MACS56771.2022.10022493.
- [10] T. Shafira and A. Fauzy, “Implementasi Image Classification Menggunakan Metode Convolutional Neural Network (CNN) Pada Citra Kain Tenun,” UII, Jakarta, 2017.
- [11] P. A. Wicaksana, I. M. Sudarma, and D. C. Khrisne, “Pengenalan Pola Motif Kain Tenun Gringsing Menggunakan Metode Convolutional Neural Network Dengan Model Arsitektur Alexnet,” *Jurnal SPEKTRUM*, vol. 6, no. 3, pp. 159–168, Sep. 2019, doi: 10.24843/SPEKTRUM.2019.v06.i03.p23.
- [12] Y. Rizki, R. M. Taufiq, H. Mukhtar, and D. Putri, “Klasifikasi Pola Kain Tenun Melayu Menggunakan Faster R-CNN,” *IT Journal Research and Development*, vol. 5, no. 2, Art. no. 2, Jan. 2021, doi: 10.25299/itjrd.2021.vol5(2).5831.
- [13] M. A. Qureshi, R. A. Butt, M. Z. Arfeen, and N. Akram, “Fully Automatic Weave Identification in Woven Fabrics Using Digital Image Processing,” *Engineering Proceedings*, vol. 20, no. 1, Art. no. 1, 2022, doi: 10.3390/engproc2022020001.
- [14] X. Liang, W. Liu, Y. Zhang, J. Yu, and H. Qu, “Dimensionality-Varied Convolutional Neural Network for Hyperspectral Image Classification With Small-Sized Labeled Samples,” in *2018 9th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS)*, Sep. 2018, pp. 1–5. doi: 10.1109/WHISPERS.2018.8747243.
- [15] C. Y. Jerandu *et al.*, “Image Classification of Decapterus Macarellus Using Ridge Regression,” in *2022 8th International Conference on Education and Technology (ICET)*, Oct. 2022, pp. 81–86. doi: 10.1109/ICET56879.2022.9990820.
- [16] A. J. Lado *et al.*, “Comparison of Neural Network and Random Forest Classifier Performance on Dragon Fruit Disease,” in *2021 International Electronics Symposium (IES)*, Sep. 2021, pp. 287–291. doi: 10.1109/IES53407.2021.9593992.
- [17] S. Soebandhi, A. G. Sooai, K. Kristiningsih, and A. Nugroho, “Multisensory Culinary Image Classification based on SqueezeNet and Support Vector Machine,” presented at the The Information Technology International Seminar, Batu Malang: IEEE, Oct. 2023. [Online]. Available: <http://2023.itisconf.org/>
- [18] K. Sanjar, A. Rehman, A. Paul, and K. JeongHong, “Weight Dropout for Preventing Neural Networks from Overfitting,” in *2020 8th International Conference on Orange Technology (ICOT)*, Dec. 2020, pp. 1–4. doi: 10.1109/ICOT51877.2020.9468799.
- [19] R. Kinoyama, E. A. M. Perez, and H. Iba, “Preventing Overfitting of LSTMs using Ant Colony Optimization,” in *2021 10th International Congress on Advanced Applied Informatics (IIAI-AAI)*, Jul. 2021, pp. 343–350. doi: 10.1109/IIAI-AAI53430.2021.00061.

- [20] Z. Biczó, S. Szénási, and I. Felde, “Safe Overfitting of Boosted Tree Algorithm in Heat Transfer Modeling,” in *2022 IEEE 20th Jubilee World Symposium on Applied Machine Intelligence and Informatics (SAMI)*, Mar. 2022, pp. 000379–000382. doi: 10.1109/SAMI54271.2022.9780808.
- [21] L. Alzubaidi *et al.*, “Review of deep learning: concepts, CNN architectures, challenges, applications, future directions,” *Journal of Big Data*, vol. 8, no. 1, p. 53, Mar. 2021, doi: 10.1186/s40537-021-00444-8.
- [22] A. G. Sooai, “Seleksi Fitur untuk Pengenalan Gestur Tangan 3D secara Dinamis pada Interaksi Benda Virtual Menggunakan Hybrid GMM,” doctoral, Institut Teknologi Sepuluh Nopember, Surabaya, 2020. Accessed: Jul. 04, 2023. [Online]. Available: <https://repository.its.ac.id/81786/>
- [23] A. G. Sooai, A. N. Rumaksari, K. Khamid, N. Z. Fanani, S. Sumpeno, and M. H. Purnomo, “Deteksi Gestur Lengan Dinamis pada Lingkungan Virtual Tiga Dimensi Koleksi Warisan Budaya,” *Jurnal Nasional Teknik Elektro dan Teknologi Informasi*, vol. 7, no. 4, Art. no. 4, Nov. 2018.
- [24] A. G. Sooai, K. Yoshimoto, H. Takahashi, S. Sumpeno, and M. H. Purnomo, “Dynamic Hand Gesture Recognition on 3D Virtual Cultural Heritage Ancient Collection Objects Using k-Nearest Neighbor,” 2018.
- [25] N. M. R. Mamulak, P. A. Nani, and A. G. Sooai, *Deteksi Anomali dan Pembelajaran Mesin*, 1st ed. Sleman: Karya Bakti Makmur, 2021.