

# Verifikasi Kualitas Gambar Dengan Algoritma Support Vector Machine (SVM) Untuk Studi Kasus Ulos Batak Toba

Arlinta Christy Barus<sup>\*1</sup>, Teamsar Muliadi Panggabean<sup>2</sup>, Devi Pakpahan<sup>3</sup>, Sapto Gokma Dominggus Sirait<sup>4</sup>

<sup>1,2,3</sup>Institut Teknologi Del

E-mail: <sup>\*1</sup>arlinta@del.ac.id, <sup>2</sup>teamsar.panggabean@del.ac.id, <sup>3</sup>ifs15015@students.del.ac.id, <sup>4</sup>ifs15032@students.del.ac.id

## Abstrak

Verifikasi kualitas gambar pada aplikasi DiTenun sebelumnya dilakukan menggunakan algoritma Fast Four Transform (FFT) dan Principle Component Analysis (PCA). Pada penelitian ini dilakukan verifikasi kualitas gambar menggunakan algoritma Support Vector Machine (SVM) untuk dapat digunakan pada aplikasi DiTenun. SVM digunakan untuk membentuk model klasifikasi kualitas gambar ke dalam kategori baik dan buruk. Algoritma SVM yang digunakan adalah non-linear SVM dengan kernel yang berbeda, yaitu kernel gaussian rbf, polynomial, dan sigmoid. Sebelum dilakukan klasifikasi, terlebih dahulu gambar dilabeli menjadi dua label yaitu kualitas baik dan kualitas buruk dengan menggunakan metode cohen kappa.

Klasifikasi kualitas gambar dilakukan berdasarkan fitur tekstur gambar, yaitu fitur contrast, dissimilarity, homogeneity, energy, dan correlation yang diperoleh menggunakan metode Grey Level Co-occurrence Matrix (GLCM). Pada dataset berupa fitur-fitur tekstur gambar diterapkan data preprocessing seperti data integration, custom transformation, dan data reduction. Penentuan kombinasi fitur dan jumlah fitur agar diperoleh model klasifikasi dengan akurasi tertinggi dilakukan menggunakan metode chi square.

Data pada penelitian ini dibagi menjadi train set dan test set dengan perbandingan sebesar 80:20. Penilaian performansi model adalah berdasarkan akurasi, precision, recall, dan F1-Score yang diperoleh melalui confusion matrix. Hasil penelitian ini adalah model hasil penggunaan SVM dengan kernel gaussian rbf yang memiliki performansi paling baik dibandingkan dengan penggunaan kernel polynomial dan sigmoid. Model terbaik tersebut termasuk dalam kategori good classification. Dari hasil tersebut maka dapat disimpulkan bahwa pendekatan machine learning khususnya dengan algoritma SVM efektif dan dapat digunakan untuk verifikasi kualitas gambar pada aplikasi DiTenun.

**Kata Kunci**— klasifikasi, kualitas gambar, cohen kappa, tekstur, SVM, kernel

## 1. PENDAHULUAN

Ulos merupakan salah satu hasil budaya dari Sumatera Utara yang dihasilkan dengan cara ditenun oleh penenun tradisional [22]. Ulos secara umum dihasilkan dengan mengikuti pola ulos yang digambar secara manual. Pada penelitian yang dilakukan oleh Arlinta dkk [1], dihasilkan aplikasi DiTenun yang dapat digunakan untuk menghasilkan motif ulos baru dari suatu ulos yang selanjutnya dikristik sehingga dapat digunakan menjadi acuan bagi penenun.

Pada aplikasi DiTenun, verifikasi kualitas gambar telah dikembangkan menggunakan algoritma Fast Fourier Transform (FFT) dan Principle Component Analysis (PCA)[18]. Pada penelitian ini, peneliti bermaksud untuk melakukan klasifikasi kualitas gambar ulos dengan pendekatan learning sesuai saran penelitian sebelumnya.

Algoritma yang digunakan pada penelitian ini adalah Support Vector Machine (SVM). Penulis memilih menggunakan algoritma SVM dikarenakan SVM sebagai algoritma machine learning bekerja dengan prinsip Struktural Risk Minimization (SRM) untuk menemukan garis hyperplane terbaik untuk memisahkan dua kelas pada input space [7]. Selain itu, SVM pada dasarnya digunakan untuk klasifikasi data terhadap 2 (dua) kategori atau kelas sehingga sesuai dengan penelitian ini yang mengklasifikasikan kualitas gambar ulors terhadap kategori baik dan buruk.

Pada penelitian ini, algoritma SVM yang digunakan adalah non-linear SVM, dimana algoritma non-linear SVM dapat memisah class data yang terpisah secara non-linear. Selain itu, non-linear SVM dapat digunakan untuk dataset berdimensi tinggi (dataset dengan lebih dari dua fitur). Pada non-linear SVM dibutuhkan trik kernel untuk menentukan pemisah class data pada data non-linear.

Kernel yang digunakan pada penelitian ini adalah kernel yaitu gaussian rfb, polynomial, dan sigmoid. Penggunaan ketiga kernel tersebut adalah mengikuti penelitian sebelumnya yang mengatakan bahwa ketiga kernel tersebut adalah kernel yang umum digunakan dalam non-linear SVM [20]. Penelitian ini bertujuan untuk menentukan penggunaan kernel SVM mana yang lebih baik untuk dapat digunakan dalam memverifikasi kualitas gambar ulos pada aplikasi DiTenun. Selain itu, penelitian ini juga bertujuan untuk menentukan apakah dengan pendekatan learning dapat efektif mengklasifikasikan kualitas gambar ulor ke dalam kategori baik dan buruk. Pada penelitian ini dianalisis penggunaan algoritma SVM dengan fungsi kernel yang berbeda dalam hal melakukan verifikasi kualitas gambar pada aplikasi DiTenun, dan penelitian ini tidak bermaksud untuk meningkatkan kualitas dari suatu gambar..

## 2. METODE PENELITIAN

Cohen kappa merupakan teknik untuk mengevaluasi kesepakatan di antara beberapa rater dalam menilai suatu objek [15] [4]. Penilaian yang diterapkan pada cohen kappa merupakan penilaian secara subjectif dan bersifat kategori. Pada cohen kappa umumnya digunakan dua rater dan dua kategori. Kemungkinan kesepakatan untuk dua rater ditunjukkan pada Tabel 1 berikut.

Tabel 1. Kesepakatan dua rater.

		Rater 2		
		$P_2^* = 0$	$P_2^* = 1$	
Rater 1	$P_1^* = 0$	$P_{00}$	$P_{01}$	$P_{0.}$
	$P_1^* = 1$	$P_{10}$	$P_{11}$	$P_{1.}$
		$P_{.0}$	$P_{.1}$	1

Untuk mencari koefisien cohen kappa digunakan persamaan berikut.

$$K = \frac{P_o - P_e}{1 - P_e} \quad (1)$$

Dengan

$$P_o = \frac{n_{11} + n_{00}}{n} \quad (2)$$

$$P_e = \left( \frac{n_{0.}}{n} \right) \left( \frac{n_{.0}}{n} \right) + \left( \frac{n_{1.}}{n} \right) \left( \frac{n_{.1}}{n} \right) \quad (3)$$

K adalah koefisien cohen kappa,  $P_o$  merupakan proporsi kesepakatan teramati,  $P_e$  merupakan proporsi kesepakatan harapan dan 1 adalah konstanta. Kategori tingkat kesepakatan rater ditunjukkan pada Tabel 2 berikut.

Tabel 2. Tingkat Kesepakatan Rater

Kappa	Kesepakatan
0.00 – 0.20	Tidak Cukup ( <i>insufficient</i> )
0.21 – 0.40	Memuaskan ( <i>satisfactory</i> )
0.41 – 0.60	Cukup ( <i>sufficient</i> )
0.61 – 0.80	Baik ( <i>good</i> )
0.81 – 1.00	Baik Sekali ( <i>Excellent</i> )

Data yang digunakan oleh penulis sebagai objek penelitian pada Tugas Akhir ini adalah gambar ulos. Data ulos yang digunakan terdiri dari 8 (delapan) jenis ulos Batak Toba yaitu: Ragi Idup, Ragi Hotang, Sadum, Bintang Maratur, Mangiring, Sibolang, Harungguan, dan Sitolutuho.

Gambar ulos yang digunakan pada penelitian ini berasal dari data pada penelitian sebelumnya tentang verifikasi kualitas gambar [18]. Jumlah data asal yang digunakan pada penelitian ini adalah sebanyak 329 gambar. Gambar tersebut telah dikategorikan secara manual ke dalam kategori gambar dengan kualitas baik dan buruk. Jumlah gambar dengan kategori kualitas baik adalah sebanyak 169 dan kategori kualitas buruk sebanyak 160 gambar.

### 3. HASIL DAN PEMBAHASAN

#### 3.1. Data Preparation

Pada subbab ini dijelaskan mengenai implementasi, hasil, dan pembasan yang dilakukan pada tahap data preparation. Data preparation pada penelitian ini meliputi image augmentation, penerapan cohen kappa, dan feature extraction yang dijelaskan lebih rinci pada subbab berikut..

##### 3.1.1. Image Aumentation

Image augmentation dilakukan untuk memperbanyak jumlah data gambar. Pada penelitian ini, image augmentation untuk gambar asal yang memiliki label buruk dilakukan dengan menerapkan penambahan contrast, blur, noise, dan rescale pada setiap gambar. Image augmentation untuk gambar asal yang memiliki label baik dilakukan dengan menerapkan penambahan noise dan rescale pada setiap gambar. Dari proses image augmentation diperoleh jumlah keseluruhan gambar sebanyak 1307 gambar. Keseluruhan data gambar tersebut dilabeli dengan menerapkan metode cohen kappa yang dijelaskan pada subbab berikut.

##### 3.1.2. Cohen Kappa

Penerapan cohen kappa pada penelitian ini menggunakan dua rater. Rater tersebut melakukan penilaian kualitas gambar ulos secara manual terhadap kualitas baik dan buruk. Berikut ini disajikan persentase penilaian gambar oleh rater pada Gambar 4 berikut.



Gambar 4. Persentasi Hasil Penilaian Rater

Berdasarkan penilaian yang dilakukan oleh rater kelompok 1 (satu) jumlah gambar baik yang disepakati sebanyak 362 gambar, jumlah gambar buruk yang disepakati sebanyak 842 gambar, dan jumlah gambar yang tidak disepakati sebanyak 103 gambar. Representasi jumlah gambar yang dinilai oleh rater ditunjukkan pada Tabel 6 berikut.

Tabel 6. Penilaian Oleh Rater

		Rater A		Jumlah
		Buruk	Baik	
Rater B	Buruk	$(P_{00})$ = 842	$(P_{01})$ = 49	$(P_{0.})$ = 891
	Baik	$(P_{10})$ = 54	$(P_{11})$ = 362	$(P_{1.})$ = 416
Jumlah		$(P_{.0})$ = 896	$(P_{.1})$ = 411	1307

Berdasarkan perhitungan Kohen kappa menggunakan persamaan (1), (2), dan (3) pada subbab 2.5, didapat koefisien kappa sebesar 0.8176. Nilai koefisien kappa tersebut termasuk ke dalam kategori Baik Sekali (Excellent). Karena kategori tingkat kesepakatan rater yang diperoleh telah memenuhi harapan penulis, maka gambar yang digunakan untuk membentuk model klasifikasi adalah 362 gambar dengan label baik dan 842 gambar dengan label buruk sehingga total keseluruhan gambar adalah sebanyak 1204 gambar.

### 3.1.3. Feature Extraction

Features extraction yang dilakukan pada penelitian adalah ekstraksi fitur tekstur. Metode yang digunakan untuk ekstraksi fitur ini adalah metode GLCM seperti yang dijelaskan pada subbab 2.6. Feature extraction dilakukan terhadap keseluruhan data hasil penerapan cohen kappa. Fitur yang dapat diperoleh oleh penulis dari proses feature extraction ini adalah fitur contrast, dissimilarity, homogeneity, energy, dan correlation. Berikut beberapa hasil dari feature extraction tersebut disajikan dalam Tabel 7 berikut.

Tabel 7. Hasil Feature Extraction

Con trast	Dis			Cor
	Simi larity	Homo geneity	E nergy	Rela tion
3252.371	40.963	0.039	0.010	0.259
1111.123	22.200	0.066	0.012	0.605
1457.430	27.859	0.041	0.009	0.590

	Dis			Cor	
Con	Simi	Homo	E	Rela	
trast	larity	geneity	nergy	tion	
1637.845	30.571	0.036	0.008	0.584	
4148.840	44.640	0.032	0.007	0.315	

Dari hasil feature extraction tampak bahwa nilai dari setiap fitur yang dihasilkan memiliki rentang angka yang berbeda-beda. Hal tersebut dapat mengakibatkan data membentuk distribusi yang kurang baik sehingga memungkinkan model yang dibentuk memiliki performa yang kurang baik juga. Untuk menangani hal tersebut dilakukan data custom transformation dengan cara data normalization dan transformasi logaritma agar dihasilkan data dengan distribusi yang lebih normal.

### 3.2. Data Preprocessing

Untuk menangani permasalahan pada data hasil feature extraction dilakukan data custom transformation melalui data normalization dan transformasi logaritma. Berikut beberapa hasil dari custom transformation disajikan dalam Tabel 8 berikut.

Tabel 8. Hasil Custom Transformation.

	Dis	Homo	E	Cor
Contrast	similarity	geneity	nergy	relation
0.958	0.966	0.017	0.005	0.274
0.826	0.806	0.056	0.008	0.655
0.860	0.865	0.018	0.004	0.640
0.874	0.889	0.012	0.002	0.634
0.988	0.989	0.006	0.002	0.343

Pada hasil dari proses custom transformation ditunjukkan bahwa nilai dari dari keseluruhan fitur telah memiliki skala yang sama dan telah memiliki rentang nilai dari 0-1.

Feature selection yang digunakan pada penelitian ini yaitu menggunakan algoritma chi square seperti yang dijelaskan pada subbab 2.6. Jumlah fitur yang diperoleh dari proses feature extraction adalah sebanyak lima fitur yaitu contrast, dissimilarity, homogeneity, energy, dan correlation. Feature selection diterapkan pada kombinasi 4 fitur, 3 fitur, dan 2 fitur. Untuk kombinasi 5 dan 1 jumlah fitur tidak digunakan karena jumlah fitur maksimal adalah 5 fitur dan minimal menggunakan 2 fitur. Berikut hasil dari feature selection untuk setiap kombinasi jumlah fitur.

1. Untuk 4 jumlah fitur yang paling relevan adalah fitur contrast, dissimilarity, homogeneity dan correlation.
2. Untuk 3 jumlah fitur yang paling relevan adalah contrast, dissimilarity, dan homogeneity.
3. Untuk 2 jumlah fitur jumlah fitur yang paling relevan adalah contrast dan dissimilarity.


Dari hasil feature selection tersebut, dapat disimpulkan bahwa fitur berdasarkan ukuran relevansinya dari yang tertinggi hingga terendah adalah contrast, dissimilarity, homogeneity, correlation, dan energy. Hasil feature selection yang diperoleh digunakan dalam pembentukan model klasifikasi. Pembentukan model juga dilakukan dengan 5 jumlah fitur.

### 3.3. Akurasi Model

Berikut ini dijelaskan dan ditampilkan akurasi pembentukan model yang dilakukan terhadap kernel gaussian rbf, polynomial, dan sigmoid untuk setiap jumlah fitur yang digunakan. Fitur yang digunakan adalah fitur sesuai hasil feature selection yang telah dijelaskan pada subbab 3.1.3.

#### 3.3.1. Hasil Kernel Gaussian RBF

Pada Gambar 5 berikut ditampilkan akurasi train dari model yang telah dibentuk dengan menggunakan kernel gaussian rbf untuk setiap penggunaan jumlah fitur hasil feature selection.

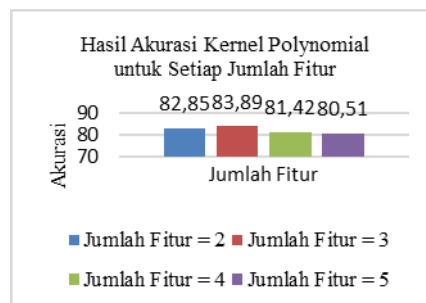


Gambar 5. Hasil Akurasi Menggunakan Kernel Gaussian RBF untuk Setiap Jumlah Fitur

Berdasarkan hasil yang diperoleh dapat disimpulkan bahwa untuk penggunaan kernel gaussian rbf didapat akurasi tertinggi pada penggunaan 5 jumlah fitur yaitu sebesar 84.97%, dan fitur yang digunakan adalah contrast, dissimilarity, homogeneity, energy, dan correlation.

#### 3.3.2. Hasil Kernel Polynomial

Pada Gambar 6 berikut ditampilkan akurasi train dari model yang telah dibentuk dengan menggunakan kernel polynomial untuk setiap penggunaan jumlah fitur hasil feature selection.

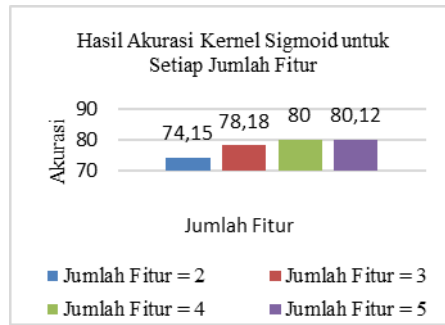


Gambar 6. Hasil akurasi kernel polynomial setiap jumlah fitur

Berdasarkan hasil yang diperoleh dapat disimpulkan bahwa untuk penggunaan kernel gaussian rbf didapat akurasi tertinggi pada penggunaan 3 jumlah fitur yaitu 83.89%, dan fitur yang digunakan adalah contrast, dissimilarity, dan homogeneity.

#### 3.3.3. Hasil Kernel Sigmoid

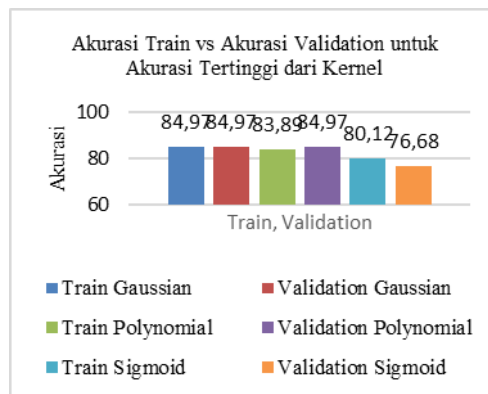
Pada Gambar 7 berikut ditampilkan akurasi train dari model yang telah dibentuk dengan menggunakan kernel sigmoid untuk setiap penggunaan jumlah fitur hasil feature selection.



Gambar 7. Hasil Akurasi Menggunakan Kernel Polynomial untuk Setiap Jumlah Fitur

Berdasarkan hasil yang diperoleh dapat disimpulkan bahwa untuk penggunaan kernel gaussian rbf didapat akurasi tertinggi pada penggunaan 5 jumlah fitur yaitu 80.12%, dan fitur yang digunakan adalah contrast, dissimilarity, homogeneity, energy dan correlation.

Berikut ini pada Gambar 8 disajikan nilai akurasi tertinggi dari model yang telah dibentuk dengan setiap kernel pada setiap penggunaan jumlah fitur hasil feature selection. Pada Gambar 8 berikut juga ditampilkan akurasi validation pada setiap model untuk mengidentifikasi keadaan overfitting maupun underfitting.



Gambar 8. Akurasi Train dan Akurasi Validation Kernel

Pada grafik di atas ditunjukkan bahwa tidak ada akurasi validation yang signifikan lebih rendah dari akurasi train pada setiap model. Hal tersebut berarti tidak ada model yang mengalami overfitting. Hasil yang diperoleh juga menunjukkan bahwa tidak ada akurasi model dengan performansi yang termasuk dalam kategori fail classification. Hal tersebut berarti tidak ada model yang mengalami underfitting. Ketiga model tersebut memiliki performansi yang termasuk dalam kategori good classification, yang artinya ketiga model tersebut sudah dapat melakukan klasifikasi kualitas gambar dengan baik. Penilaian performansi tersebut mengacu pada tingkat performansi model yang dijelaskan pada Tabel 5 di subbab 2.9.

Berikut ini pada Tabel 9 ditampilkan nilai akurasi, precision, recall, dan F1 score dari model dengan akurasi tertinggi pada setiap kernel.


Tabel 9. Akurasi, Precision, Recall, dan F1 Score dari Model dengan Akurasi Tertingginya

Kernel	Akurasi	Precision	Recall	F1 Score
Gaussian RBF	84.97	85	85	85

Kernel	Akurasi	Precision	Recall	F1 Score
Polynomial	83.89	84	84	84
Sigmoid	80.12	80	80	79

Performansi dari model umumnya dilihat dari nilai akurasi model, namun nilai precision, recall, dan F1 score tetap perlu dipertimbangkan. Pada Tabel 10 di atas ditunjukkan bahwa nilai precision, recall, dan F1 score dari setiap kernel tidak memiliki perbedaan yang signifikan dari nilai akurasinya. Nilai precision, recall, dan F1 score tersebut juga masih dalam satu kategori berdasarkan kategori performansi model pada Tabel 5 di subbab 2.10. Kategori yang didapat adalah kategori good classification. Nilai akurasi, precision, recall, dan F1 score dari model menunjukkan bahwa proses pembelajaran menggunakan data train sudah akurat untuk membentuk model klasifikasi.

Berikut ini pada Gambar 9 ditampilkan nilai akurasi dari setiap kernel dengan akurasi tertinggi berdasarkan penggunaan jumlah fitur.



Gambar 9. Akurasi Setiap Kernel dengan Akurasi Tertingginya berdasarkan Penggunaan Jumlah Fitur

Dari ketiga model tersebut, model terbaik dengan akurasi tertinggi didapat dari penggunaan kernel gaussian rbf yaitu 84.97%. Fitur yang digunakan untuk model tersebut adalah 5 (lima) fitur yaitu contrast, dissimilarity, homogeneity, energy, dan correlation.

### 3.4. Pengujian Data Baru

Pengujian data baru dilakukan pada model yang memiliki akurasi tertinggi berdasarkan penggunaan jumlah fitur untuk setiap kernel. Berikut disajikan hasil pengujian data baru untuk model setiap model tersebut pada Tabel 10.

Tabel 10. Hasil Pengujian

Kernel	Akurasi	Precision	Recall	F1 Score
Gaussian RBF	92.94	93	93	93
Polynomial	88.9	90	89	89
Sigmoid	80.08	83	80	81

Pada Tabel 10 di atas ditunjukkan bahwa nilai precision, recall, dan F1 score dari setiap kernel tidak memiliki perbedaan yang signifikan terhadap nilai akurasinya. Nilai precision, recall, dan F1 score tersebut masih dalam satu kategori yaitu kategori good classification. Nilai akurasi, precision, recall, dan F1 score dari model menunjukkan bahwa proses pembelajaran menggunakan data train sudah akurat dalam pembentukan model sehingga mampu

mengklasifikasikan data baru dengan kategori akurasi yang sama yaitu kategori good classification.

Dari pengujian yang dilakukan, akurasi tertinggi yang diperoleh adalah 92.94% yakni menggunakan kernel gaussian rbf. Kernel terbaik yang didapat dari akurasi model dan akurasi pengujian model dengan data baru adalah sama, yaitu model dengan menggunakan kernel gaussian rbf menggunakan 5 jumlah fitur yaitu contrast, dissimilarity, homogeneity, energy, dan correlation. Dari hal tersebut dapat disimpulkan bahwa proses learning dalam pembentukan model menggunakan kernel gaussian rbf lebih baik daripada menggunakan kernel polynomial dan sigmoid.

Akurasi model tertinggi diperoleh melalui penggunaan algoritma SVM dengan kernel gaussian rbf. Akurasi model yang diperoleh adalah sebesar 84.97% dan termasuk dalam kategori good classification sesuai dengan harapan peneliti untuk dapat digunakan dalam verifikasi kualitas gambar pada aplikasi DiTenun. Berdasarkan hal tersebut dapat disimpulkan bahwa penggunaan machine learning khususnya dengan algoritma SVM pada penelitian ini sudah efektif dalam melakukan klasifikasi kualitas gambar ulos.

#### 4. KESIMPULAN

Berdasarkan penelitian yang telah dilakukan oleh penulis dapat diambil kesimpulan sebagai berikut:

1. Perbandingan akurasi ketiga kernel dilakukan untuk menentukan kernel SVM yang lebih baik dalam melakukan klasifikasi gambar ulos. Dari hasil penelitian diperoleh bahwa penggunaan kernel gaussian RBF pada SVM memiliki akurasi yang lebih tinggi dibandingkan dengan penggunaan kernel polynomial, dan sigmoid. Akurasi model yang diperoleh untuk penggunaan kernel gaussian rbf, polynomial, dan sigmoid secara berurut yaitu 84.97%, 83.89%, dan 80.12%.
2. Akurasi kernel gaussian rbf sebagai kernel terbaik yang diperoleh yaitu sebesar 84.97% termasuk ke dalam kategori good classification. Berdasarkan kategori performansi model tersebut dapat disimpulkan bahwa penggunaan pendekatan machine learning khususnya algoritma SVM kernel gaussian rbf dapat efektif mengklasifikasikan kualitas gambar ulos. Oleh karena itu model yang dihasilkan dapat digunakan pada aplikasi DiTenun untuk mengklasifikasikan gambar berdasarkan kualitas ke dalam kategori baik dan buruk.
3. Pengujian terhadap model dari penggunaan kernel gaussian rbf dan penggunaan 5 fitur (contrast, dissimilarity, homogeneity, energy, dan correlation) diperoleh bahwa jumlah gambar yang dapat diverifikasi dengan benar adalah 224 gambar dari 241 gambar dengan persentase 92.94%. Hasil tersebut menunjukkan bahwa klasifikasi gambar berdasarkan kualitas dapat dilakukan dengan optimal.
4. Penggunaan 5 jumlah fitur yang terdiri dari fitur contrast, dissimilarity, homogeneity, energy, dan correlation memiliki akurasi tertinggi untuk kernel gaussian rbf dan polynomial dibandingkan jika menggunakan jumlah fitur yang lain. Sedangkan pada penggunaan kernel sigmoid, akurasi tertinggi didapat dari penggunaan 3 fitur, yaitu fitur contrast, dissimilarity, dan homogeneity. Dari hasil tersebut dapat disimpulkan bahwa akurasi model klasifikasi dengan algoritma SVM tidak bergantung dari banyaknya jumlah fitur yang digunakan, tetapi bergantung pada jenis kernel dan fitur.
5. Penggunaan metode cohen kappa dalam pelabelan gambar sangat berpengaruh terhadap jumlah data gambar yang digunakan dalam pembentukan model klasifikasi. Jumlah data yang digunakan dapat berpengaruh terhadap akurasi model klasifikasi yang dihasilkan, dimana semakin banyak jumlah data gambar maka akurasi dari model

semakin baik. Oleh karena itu, kualifikasi rater yang melakukan pelabelan (penilaian) adalah hal yang perlu diperhatikan agar jumlah data dengan penilaian yang sama diharapkan memiliki jumlah yang tinggi.

#### DAFTAR PUSTAKA

- [1] BARUS, A. C. et al., 2015. Piranti Cerdas Penghasil Motif Tenun Nusantara, s.l.: Lembaga Pengelola Dana Pendidikan Kementerian Keuangan.
- [2] B, B. & M, R., 2014. A Study On The Importance Of Image Processing And Its Applications. IJRET: International Journal of Research in Engineering and Technology, pp. 155-160.
- [3] BENOIT, K., 2011. Linear Regression Models with Logarithmic Transformations, London: Methodology Institute London School of Economics.
- [4] COHEN, J., 1960. A Coefficient of Agreement for Nominal Scales. Education and Psychological Measurement, pp. 37-46.
- [5] ERLYANA, Y., 2016. Kajian Visual Keragaman Corak Pada Kain Ulos. Dimensi DKV, pp. 35-46.
- [6] FARSAH, L., ABIDIN, T. F. & MUNADI, K., 2013. Klasifikasi Gambar Berwarna Menggunakan K-Nearest Neighbour dan Support Vector Machine. SNASTIKOM, pp. 105-109.
- [7] FELDMAN, R. & SANGER, J., 2007. The Text Mining Handbook. New York: Cambridge University Press.
- [8] GARCÍA, S., LUENGO, J. & HERRERA, F., 2014. Data Preprocessing in Data Mining. Granada: Spring International Publishing Switzerland.
- [9] GOODFELLOW, I., BENGIO, Y. & COURVILLE, A., 2016. DEEP LEARNING. Cambridge, MA, USA: The MIT Press.
- [10] GORUNESCU, F., 2011. Data Mining: Concepts, Models and Techniques. s.l.:s.n.
- [11] HAN, J., PEI, J. & KAMBER, M., 2012. Data Mining: Concepts and Techniques. Waltham, USA: Morgan Kaufman.
- [12] HASHEMI, M. & HALL, M., 2018. Visualization, Feature Selection, Machine Learning: Identifying the Responsible Group for Extreme Acts of Violence.
- [13] HUSSAIN, M., WAJID, S. K., ELZAART, A. & BERBAR, M., 2011. A Comparison of SVM Kernel Functions for Breast Cancer Detection. Eighth International Conference Computer Graphics, Imaging and Visualization.
- [14] KUMAR, A., PATIDAR, V., KHAZANCHI, D. & SAINI, P., 2015. Effect of Image Quality Improvement on the Leaf. (IJCSIT) International Journal of Computer Science and Information Technologies, pp. 4882-4887.
- [15] KUNZ, A., t.thn. Misclassification and kappa-statistic: theoretical relationship and consequences in application. s.l.:Ludwig-Maximilians-Universita't Mu'nchen Institut fu'r Statistik.
- [16] LING, J., KENCANA, I. P. E. N. & OKA, B. T., 2014. Analisis Sentimen Menggunakan Metode Naïve Bayes Classifier Dengan Seleksi Fitur Chi Square. E-Jurnal Matematika, pp. 92-99.
- [17] LISTYANTO, S. R., t.thn. Implementasi K-Nearest Neighbor Untuk Mengenali Pola Citra Dalam Mendeteksi Penyakit Kulit. pp. 1-7.

- [18] LUBIS, A. N., SARAGIH, H. & DAMANIK, G. N., 2018. Pembangunan Modul untuk Penentuan Kriteria Kualitas Gambar pada Aplikasi JTenun, Sitoluama: Institut Teknologi Del.
- [19] MANNING, C. D., RAGHAVAN, P. & SCHÜTZE, H., 2008. Introduction to Information Retrieval. London: Cambridge University Press.
- [20] NUGROHO, A. S., WITARTO, A. B. & HANDOKO, D., 2003. Application of Support Vector Machine in Bioinformatics.
- [21] OKAFOR, E., SCHOMAKER, L. & WIERING, M. A., 2018. An analysis of rotation matrix and colour constancy data augmentation in classifying images of animal. INFORMATION AND TELECOMMUNICATION, pp. 1-2.
- [22] PARDOSI, J., 2008. Makna Simbolik Umpasa, Sinamot, Dan Ulos Pada Adat Perkawinan Batak Toba. pp. 101-107.
- [23] SANTI, C. N., 2011. Mengubah Citra Berwarna Menjadi Gray-Scale dan Citra biner. Teknologi Informasi DINAMIK, pp. 14-19.
- [24] SARIFUDIN, M. & DRAJAT, M. A., 2015. Pengolahan Citra & Video Digital. Jakarta: Erlangga.
- [25] SUGIARTHA, I. G. R. A., SUDARMA, M. & WIDYANTARA, I. M. O., 2017. Ekstraksi Fitur Warna, Tekstur dan Bentuk untuk Clustered-Based Retrieval of Images (CLUE). Teknologi Elektro, pp. 85-90.
- [26] TAKARI, M., 2009. Ulos Dan Sejenisnya Dalam Budaya Batak Di Sumatera Utara: Makna, Fungsi, Dan Teknologi. pp. 17-29.
- [27] THAKARE, V. S. & PATIL, N. N., 2014. Classification of Texture Using Gray Level Co-Occurrence Matrix and Self-Organizing Map. International Conference on Electronic Systems, Signal Processing and Computing Technologies, pp. 350-355.
- [28] ZULPE, N. & PAWAR, V., 2012. GLCM Textural Features for Brain Tumor Classification. IJCSI International Journal of Computer Science Issues, pp. 354-359.