

Klasifikasi Anjing dan Kucing menggunakan Algoritma Linear Discriminant Analysis dan Support Vector Machine

Suryadi Darmawan Salim¹, Alethea Suryadibrata^{2*}

Informatics, Universitas Multimedia Nusantara, Tangerang, Indonesia

suryadi.darmawan@student.umn.ac.id

alethea@umn.ac.id

Diterima 29 Maret 2019

Disetujui 24 Juni 2019

Abstract— One of the factors driving technological development is the increase in computers ability to complete various jobs. One of them is doing image processing, which is widely used in our daily life, such as the use of fingerprints, face/iris recognition barcodes, medical needs, and various other uses. Classification is one of the applications of image processing that is used the most. One algorithm that can be used for the development of image classification systems is Linear Discriminant Analysis (LDA) and Support Vector Machine (SVM). LDA is a feature extraction algorithm to find a subspace that separates classes well. SVM is a classification algorithm, based on the idea of finding a hyperplane that best divides a dataset into classes. In this study, LDA and SVM algorithms were tested on the dog and cat classification system, with the highest F-score calculation results being 0.69 with 200 training data and 50 testing data for cats and 0.64 with 200 training data and 30 testing data for dogs.

Index Terms— image processing, classification, Linear Discriminant Analysis, Support Vector Machine

I. PENDAHULUAN

Kemampuan seorang manusia dalam melakukan pengenalan terhadap sesama manusia, hewan, dan objek lainnya, merupakan sebuah kemampuan yang luar biasa. Kemampuan *visual* manusia tersebut kemudian diubah ke dalam sebuah sistem yang disebut dengan *Computer Vision*. Tujuan dari *Computer Vision* adalah membangun sebuah model dari sistem visual manusia dan juga melakukan otomatisasi tugas yang dapat dikerjakan oleh sistem visual manusia [7].


Salah satu penerapan *Computer Vision* adalah pada *image processing*, yang digunakan dalam berbagai kegiatan. Klasifikasi merupakan sebuah teknik pada *image processing*. Tujuan dari klasifikasi adalah menyusun objek yang akan diamati ke dalam kategori yang telah didefinisikan [17].



Gambar 1 Gambar Anjing dan Kucing

Seorang manusia dapat dengan mudah membedakan anjing dan kucing pada Gambar 1, hal ini disebabkan oleh pengetahuan dan pelatihan (*data* dan *training*) terhadap fitur yang dimiliki oleh anjing dan kucing [18]. Hal yang sama juga dapat diaplikasikan pada komputer, dengan menggunakan teknik ekstraksi fitur, yang bertujuan untuk memilih dan menyimpan fitur yang unik [3] dan dilanjutkan dengan teknik klasifikasi untuk mengklasifikasikan data yang telah didapatkan. Sebuah komunitas *online* bernama Kaggle yang didirikan oleh Google, pernah mengadakan sebuah kompetisi untuk melakukan klasifikasi anjing dan kucing. Para peserta dapat melakukan klasifikasi terhadap data yang telah disediakan dengan menggunakan berbagai kombinasi teknik untuk mendapatkan tingkat akurasi yang paling tinggi.

Salah satu teknik ekstraksi fitur yang digunakan pada klasifikasi adalah Linear Discriminant Analysis (LDA). Pada sebuah penelitian [3] tentang perbandingan antara algoritma Principal Component Analysis (PCA), Independent Component Analysis (ICA), dan LDA pada sistem pengenalan wajah, LDA menunjukkan tingkat akurasi yang lebih tinggi dibandingkan dengan 2 algoritma lainnya.



Gambar 2 Perbandingan Kombinasi PCA+SVM, LDA+SVM, ICA+SVM untuk mengukur akurasi


Support Vector Machine (SVM) merupakan sebuah algoritma klasifikasi yang awalnya dikembangkan oleh Vapnik dkk (1963). Beberapa penelitian menunjukkan bahwa SVM mampu memberikan performa lebih tinggi dalam tingkat akurasi pada proses klasifikasi data dibandingkan dengan algoritma klasifikasi lainnya [16].

II. LANDASAN TEORI

A. Digital Image Processing

Digital Image Processing (DIP) merupakan sebuah cara untuk memproses gambar digital menggunakan berbagai algoritma [11]. Perkembangan DIP mulai terlihat pada tahun 1960, saat komputer yang cukup kuat untuk melakukan tugas *image processing* muncul. Salah satu penerapan komputer tersebut untuk melakukan *image processing* adalah pada sebuah laboratorium di Pasadena, California tahun 1964 untuk memproses gambar bulan yang ditransmisikan oleh *Ranger 7* [6].

Sebuah gambar, dapat direpresentasikan dengan fungsi $f(s, t)$, dimana s dan t merupakan variabel kontinu (*continuous variable*), yang kemudian akan dibentuk menjadi sebuah *array* 2 dimensi, yang berukuran M baris dan N kolom [6] seperti yang ditunjukkan pada Gambar 3. *Array* tersebut kemudian akan diubah kebentuk matriks sebelum digunakan dalam *image processing* seperti yang ditunjukkan pada Gambar 4 (0, .5, dan 1 merepresentasikan warna hitam, abu-abu, dan putih).



Gambar 3 Gambar yang direpresentasikan ke dalam Array 2 Dimensi

$$A = \begin{bmatrix} a_{1,0} & a_{1,1} & \dots & a_{1,N-1} \\ a_{2,0} & a_{2,1} & \dots & a_{2,N-1} \\ \vdots & \vdots & \ddots & \vdots \\ a_{M-1,0} & a_{M-1,1} & \dots & a_{M-1,N-1} \end{bmatrix}$$

Gambar 4 Matriks yang Merepresentasikan Sebuah Gambar Digital

B. Ekstraksi Fitur

Ekstraksi fitur, merupakan sebuah teknik untuk mendapatkan suatu informasi dari sebuah pola sehingga mempermudah prosedur klasifikasi [9]. Ekstraksi fitur memberikan informasi yang paling relevan dari sumber data dan merepresentasikannya ke ruang dimensi yang lebih rendah. Dalam klasifikasi anjing dan kucing, contoh fitur yang dapat diambil adalah, alat bergerak, bentuk wajah, panjang ekor, dan lainnya.

Ekstraksi fitur terbagi atas beberapa proses, yaitu *dimensionality reduction*, *feature extraction*, dan *feature selection* [10].

a. Dimensionality Reduction

Merupakan sebuah proses mengurangi jumlah variabel yang dipertimbangkan dengan mendapatkan sejumlah kumpulan variabel utama.

b. Feature Extraction

Merupakan sebuah proses mengambil fitur dari sebuah data. Lalu mengubah atau menggabungkan data agar dapat memilih dimensi yang lebih kecil dari fitur *original*.

c. Feature Selection

Merupakan sebuah proses mendapatkan fitur terbaik dari kumpulan data yang diberikan, lalu menghapus berbagai fitur yang tidak berhubungan.

C. Linear Discriminant Analysis

LDA menyediakan data set dari fitur-fitur yang menyimpan informasi paling bersangkutan yang akan digunakan pada proses klasifikasi. Metode ini merupakan skema berbasis proyeksi dari kompleksitas kecil yang menghindari adanya iterasi pada pencarian atau komputasi, yang memungkinkan ekstraksi fitur dapat dilakukan pada kecepatan tinggi [4]. LDA bekerja dengan menentukan sebuah *subspace* dengan memaksimalkan perpindahan antar kelas (*between-class scatter / S_B*) dan meminimalkan perpindahan dalam kelas (*within-class scatter / S_W*) [3] yang dapat direpresentasikan dengan persamaan berikut [2].

$$J(W) = \frac{W^T S_B W}{W^T S_W W}$$

Persamaan tersebut dapat diselesaikan dengan beberapa tahap sebagai berikut [3][5].

- Diketahui sampel $\{x^1, x^2, \dots, x^N\}$.
- N_1 dimiliki oleh kelas w_1 , N_2 oleh kelas w_2 , N_c oleh kelas w_c .
- Menghitung rata-rata dalam kelas (*class mean/mean vector*) dan rata-rata total kelas (*overall mean*) dari seluruh data.
- Tentukan matriks sebaran dalam kelas (S_W).

$$S_W = \sum_{i=1}^c S_i$$

$$S_i = \sum_{x \in W_i} (x - \mu_i)(x - \mu_i)^T$$

Dimana:

$$\mu_i = \frac{1}{N_i} \sum_{x \in W_i} x_i$$

S_i = scatter within tiap kelas

μ_i = mean vector

- e. Tentukan matriks sebaran antar kelas (S_B).

$$S_B = \sum_{i=1}^c N_i (\mu_i - \mu) (\mu_i - \mu)^T$$

Dimana:

$$\mu = \frac{1}{N} \sum_{\forall x} x = \frac{1}{N} \sum_{i=1}^c N_i \mu_i$$

μ = overall mean

- f. Cari *eigenvalue* (λ) dan *eigenvector* (v).

$$S_W^{-1} S_B v = \lambda v$$

- g. Mengurutkan *eigenvalue* sesuai dengan urutan yang paling besar.
- h. Mengambil dua *eigenvalue* terbesar yang memiliki paling banyak informasi.

D. Klasifikasi

Klasifikasi, merupakan teknik untuk mengelompokkan 1 atau lebih objek yang diamati, ke dalam sebuah label atau kategori yang sudah didefinisikan [17], seperti mengelompokkan hewan berdasarkan kelasnya, mengelompokkan tipe-tipe sel pada manusia, mengelompokkan tata surya berdasarkan bentuknya, dan lainnya.

Berdasarkan data training yang digunakan, klasifikasi terbagi atas 2 jenis:

- a. Supervised Classification

Merupakan proses menggunakan data yang telah diketahui untuk mengklasifikasikan data asing [8]. Contoh algoritma [15]: Logistic Regression, Naïve Bayes, SVM (Support Vector Machine), ANN (Artificial Neural Networks), dan Random Forests.

- b. Unsupervised Classification

Merupakan proses *clustering*, yaitu pembagian data asing dalam jumlah tertentu menjadi beberapa kelompok berdasarkan fitur yang serupa [8]. Contoh algoritma [15]: K-Means Clustering, PCA (Principal Component Analysis), dan Autoencoder.

E. Support Vector Machine

Pada penelitian Srivastava dan Bhambhu (2005), menyatakan bahwa SVM merupakan bagian dari metode *supervised learning* yang digunakan pada klasifikasi dan regresi. SVM mencari sebuah *hyperplane* yang dapat dengan baik memisahkan data menjadi beberapa kelas. Dua *hyperplane* paralel dikonstruksi pada tiap sisi *hyperplane* yang memisahkan data.

Pada SVM terdapat beberapa fungsi *kernel* yang paling banyak digunakan. Fungsi tersebut digunakan saat data tidak dapat dipisahkan secara linear, jadi data akan diubah ke tingkat dimensi yang lebih tinggi, setelah itu data dapat diklasifikasikan. Berikut merupakan beberapa fungsi kernel yang paling umum digunakan. [16].

- a. Linear Kernel

$$K(x_i, x_j) = x_i^T x_j$$

- b. Polynomial Kernel

$$K(x_i, x_j) = (\gamma x_i^T x_j + r)^d, \gamma > 0$$

- c. RBF (Radial Basis Function) Kernel

$$K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2), \gamma > 0$$

- d. Sigmoid Kernel

$$K(x_i, x_j) = \tanh(\gamma x_i^T x_j + r)$$

Dimana γ , r , dan d adalah parameter *kernel*.

Menurut penelitian Srivastava dan Bhambhu (2005), RBF merupakan fungsi utama *kernel* karena beberapa hal.

- a. RBF melakukan map sampel secara *non-linear* ke dimensi ruang lebih tinggi tidak seperti *linear kernel*.
- b. RBF memiliki *hyperparameter* lebih sedikit dari *polynomial kernel*.
- c. RBF memiliki sedikit tingkat kesulitan numerikal.

Kernel RBF memiliki beberapa *hyperparameter* yang digunakan yaitu *gamma* dan C [1]. *Gamma* merupakan parameter yang menentukan penyebaran wilayah keputusan (*decision region*). Nilai dari *gamma* mempengaruhi bentuk dari *hyperplane* yang memisahkan data. *Parameter C* menentukan tingkat toleransi terhadap kesalahan saat mengklasifikasikan data.

F. Confusion Matrix

Confusion matrix merupakan sebuah *table* yang mengandung informasi hasil klasifikasi yang terdiri dari nilai benar (*actual*) dan hasil prediksi (*predicted*) [12].

		Predicted	
		Negative	Positive
Actual	Negative	a	b
	Positive	c	d

Gambar 5 Confusion Matrix

Nilai *confusion matrix* pada Gambar 5 adalah sebagai berikut.

- a. Nilai a merupakan jumlah prediksi benar yang menyatakan kelas tersebut bernilai negatif.
- b. Nilai b merupakan jumlah prediksi salah yang menyatakan kelas tersebut bernilai positif.
- c. Nilai c merupakan jumlah prediksi salah yang menyatakan kelas tersebut bernilai negatif.
- d. Nilai d merupakan jumlah prediksi benar yang menyatakan kelas tersebut bernilai positif.

Berdasarkan pada Gambar 5, dapat dilakukan perhitungan beberapa nilai sebagai berikut [12].

- a. *True Positive* (TP), merupakan porsi nilai positif yang diklasifikasikan dengan benar.

$$TP = \frac{d}{c + d}$$

- b. *False Positive* (FP), merupakan porsi nilai negatif yang diklasifikasikan sebagai nilai positif.

$$FP = \frac{b}{a + b}$$

- c. *True Negative* (TN), merupakan porsi nilai negatif yang diklasifikasikan dengan benar.

$$TN = \frac{a}{a + b}$$

- d. *False Negative* (FN), merupakan porsi nilai positif yang diklasifikasikan sebagai nilai negatif.

$$FN = \frac{c}{c + d}$$

Kemudian 4 nilai tersebut dapat digunakan untuk mencari nilai *precision* dan *recall*. Pengertian serta persamaan untuk mendapatkan *precision* dan *recall* adalah sebagai berikut [14].

- a. Precision

Precision mencari nilai positif dari hasil prediksi yang memberikan nilai positif.

$$Precision = \frac{True\ Positive}{True\ Positive + False\ Positive}$$

- b. Recall

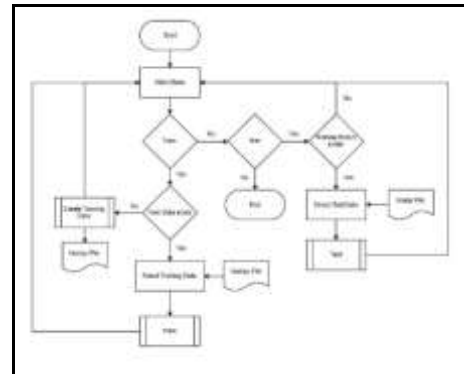
Recall mencari nilai positif yang berhasil diprediksi dari total nilai positif aktual. Recall juga dapat disebut sebagai *true positive rate*.

$$Recall = \frac{True\ Positive}{True\ Positive + False\ Negative}$$

Salah satu standar pengukuran tingkat akurasi yang menggunakan nilai *precision* dan *recall* adalah perhitungan *F-score* (*F-measure*). Perhitungan *F-score* dilakukan dengan mencari rata-rata harmonik (*harmonic mean*) dari *precision* dan *recall* [13].

$$F1 = 2 \frac{Precision * Recall}{Precision + Recall}$$

III. PERANCANGAN SISTEM



Gambar 6 Flowchart Utama Sistem

Pada Gambar 6 menunjukkan *flowchart* utama dari sistem klasifikasi anjing dan kucing. Fungsi *training* dari sistem terdiri dari membuat dan memilih *training data*, setelah itu dilakukan *train*. Fungsi *testing* dari sistem terdiri atas 2 yaitu memilih *testing data* dan melakukan *testing*.

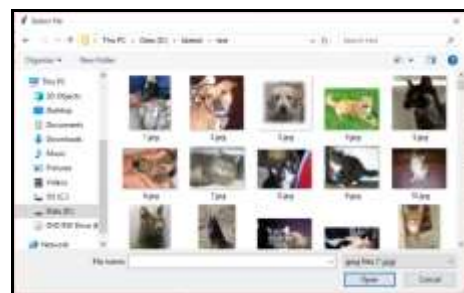
IV. IMPLEMENTASI DAN UJI COBA

A. Implementasi



Gambar 7 Menu Utama Sistem

Pada Gambar 7 menunjukkan menu utama dari sistem klasifikasi anjing dan kucing. Terdapat beberapa tombol yang dapat digunakan untuk membuat dan memilih *training data*, kemudian dapat dilakukan proses *train*. Setelah mendapatkan hasil *training*, dapat dilanjutkan dengan melakukan *testing data* dengan memilih data seperti pada Gambar 8.



Gambar 8 Memilih Testing Data



Gambar 9 Hasil Testing Data

Setelah memilih gambar, dapat menekan tombol *test*, dan sistem akan menampilkan hasil prediksi seperti pada Gambar 9.

B. Evaluasi

Dalam evaluasi hasil penelitian, dilakukan perbandingan nilai *F-score* berdasarkan jumlah *training data* dan *testing data* yang digunakan. Jumlah *training data* yang akan digunakan adalah 100, 150, dan 200. Sedangkan jumlah *testing data* yang akan digunakan adalah 30, 40, dan 50. *Training* dan *testing data* yang digunakan merupakan data dari Kaggle.

Tabel 1 Hasil Evaluasi Data Kucing

Cat				
100 Training Data				
No.	Testing Data	Precision	Recall	F-score
1.	30	0.50	0.27	0.35
2.	40	0.55	0.30	0.39
3.	50	0.56	0.36	0.44
150 Training Data				
No.	Testing Data	Precision	Recall	F-score
1.	30	0.45	0.33	0.38
2.	40	0.57	0.40	0.47
3.	50	0.57	0.52	0.54
200 Training Data				
No.	Testing Data	Precision	Recall	F-score
1.	30	0.65	0.73	0.69
2.	40	0.62	0.75	0.68
3.	50	0.63	0.76	0.69

Tabel 2 Hasil Evaluasi Data Anjing

Dog				
100 Training Data				
No.	Testing Data	Precision	Recall	F-score
1.	30	0.50	0.73	0.59
2.	40	0.52	0.75	0.61

3.	50	0.53	0.72	0.61
150 Training Data				
No.	Testing Data	Precision	Recall	F-score
1.	30	0.47	0.60	0.53
2.	40	0.54	0.70	0.61
3.	50	0.56	0.60	0.58
200 Training Data				
No.	Testing Data	Precision	Recall	F-score
1.	30	0.69	0.60	0.64
2.	40	0.69	0.55	0.61
3.	50	0.70	0.56	0.62

Pada Tabel 1 dan 2 menunjukkan hasil perhitungan *F-score* untuk data kucing dan anjing. Nilai *F-score* tertinggi yang didapatkan adalah 0.69 untuk kucing dengan menggunakan 200 *training data* dan 50 *testing data*. Untuk data anjing didapatkan nilai *F-score* tertinggi yaitu 0.64 dengan menggunakan 200 *training data* dan 30 *testing data*.

V. KESIMPULAN DAN SARAN

A. Kesimpulan

Berdasarkan penelitian yang telah dilakukan, implementasi algoritma Linear Discriminant Analysis dan Support Vector Machine pada sistem klasifikasi anjing dan kucing telah berhasil dilakukan. Hasil yang didapatkan dari uji coba berupa tingkat akurasi yang diukur menggunakan *F-score*, yang menghasilkan tingkat akurasi tertinggi 0.69 untuk kucing dengan menggunakan 200 *training data* dan 50 *testing data*, sedangkan *F-score* untuk anjing adalah 0.64 dengan menggunakan 200 *training data* dan 30 *testing data*. Tingkat akurasi tersebut dipengaruhi oleh beberapa faktor seperti jumlah *training data*, ukuran gambar, kemiripan fitur antara anjing dan kucing, seperti telinga, bentuk tubuh, warna kulit.

B. Saran

Berdasarkan kesimpulan yang didapatkan dari penelitian, berikut adalah saran pengembangan sistem untuk meningkatkan tingkat akurasi klasifikasi.

1. Menambahkan jumlah *training data*. Pada hasil penelitian dapat dilihat bahwa terjadi peningkatan *F-score* saat menambahkan jumlah *training data*.
2. Meningkatkan resolusi gambar yang digunakan pada *training* dan *testing*. Semakin besar ukuran gambar, maka gambar dapat menyimpan informasi lebih banyak. Namun perlu diperhatikan bahwa ukuran gambar yang terlalu besar juga

- dapat meningkatkan daya kerja komputer, sehingga dapat memperlambat proses *training*.
3. Mencoba menggunakan algoritma lain seperti Convolutional Neural Networks (CNN), k-Nearest Neighbor (k-NN), Logistic Regression untuk melakukan proses klasifikasi.

DAFTAR PUSTAKA

- [1] Albon, C. (2017). SVC Parameters When Using RBF Kernel. [online] Chris Albon. Tersedia di: https://chrisalbon.com/machine_learning/support_vector_machines/svc_parameters_using_rbf_kernel/ [Diakses 15 Januari 2019].
- [2] Bishop, C.M. (2006). *Pattern Recognition and Machine Learning*. New York: Springer Science+Business Media, LLC, hh. 188-192.
- [3] Bouzalmat, A., Kharroubi, J., & Zarghili, A. (2014). *Comparative Study of PCA, ICA, LDA, using SVM Classifier*. Sidi Mohamed Ben Abdellah University, Route d'Imouzzer B.P.2202, Morocco.
- [4] Etemad, K., & Chellappa, R. (1997). *Discriminant Analysis for Recognition of Human Face Images*. University of Maryland, College Park, Maryland.
- [5] Fandiansyah, Sari, J.Y., Ningrum, I.P. (2017). *Pengenalan Wajah Menggunakan Metode Linear Discriminant Analysis dan k Nearest Neighbor*. Universitas Halu Oleo, Kendiri, Indonesia.
- [6] Gonzales, R.C., & Woods, R.E. (2008). *Digital Image Processing*. 3rd ed. New Jersey: Pearson Education, Inc. hh.4-55.
- [7] Huang, T.S. (1996). *Computer Vision: Evolution and Promise*. University of Illinois, Urbana and Champaign, Illinois, U.S.
- [8] Kamavisdar, P., Saluja, S., & Agrawal, S. (2013). A Survey on Image Classification Approaches and Techniques. *International Journal of Advanced Research in Computer and Communication Engineering*, 2(1), hh.1005-1009.
- [9] Kumar, G., & Bhatia, P.K. (2014). *A Detailed Review of Feature Extraction in Image Processing Systems*. Panipat Institute of Engg. & Technology, Panipat, Haryana, India.
- [10] Marques, I. (2010). *Face Recognition Algorithms*. University of the Basque Country, Vizcaya, Spanyol.
- [11] Muthuselvi, S. & Prabhu, P. (2016). Digital Image Processing Techniques – A Survey. *Golden Research Thoughts*, 5 (11), hh.1-2.
- [12] Santra, A.K., & Christy, C.J. (2012). Genetic Algorithm and Confusion Matrix for Document Clustering. *International Journal of Computer Science Issues*, 9(1), hh. 322-328.
- [13] Sasaki, Y. (2007). *The Truth of F-measure*. University of Manchester, Manchester, United Kingdom.
- [14] Shung, K. P. (2018). *Accuracy, Precision, or F1?*. [online] Towards Data Science. Tersedia di: <https://towardsdatascience.com/accuracy-precision-recall-or-f1-331fb37c5cb9> [Diakses 15 Desember 2018].
- [15] Soni, D. (2018). *Supervised vs. Unsupervised Learning*. [online] Towards Data Science. Tersedia di: <https://towardsdatascience.com/supervised-vs-unsupervised-learning-14f68e32ea8d> [Diakses 15 Desember 2018].
- [16] Srivastava. D. K., & Bhambhu, L. (2005). *Data Classification Using Support Vector Machine*. BRCM College of Engineering and Technology, Bahal, Bhiwani, Haryana, India.
- [17] Tan, P.N., Steinbach, M., dan Kumar, V. (2005). *Introduction to Data Mining*. 1st ed. Boston: Addison-Wesley Longman Publishing Co., Inc., h.146.
- [18] Vera, Ryan., Valdez, H., Gerhat, T., dan Guzman, M. (2012). *Matrix Methods for Geometric Data Analysis and Pattern Recognition, Cats and Dogs Classification Project*