

CESS
(Journal of Computer Engineering, System and Science)

Available online: <https://jurnal.unimed.ac.id/2012/index.php/cess>

ISSN: 2502-714x (Print) | ISSN: 2502-7131 (Online)



**Penerapan Algoritma *Support Vector Machine* Dalam Pengenalan Wajah
Berdasarkan Fitur Isomap**

***Application of the Support Vector Machine Algorithm in Face Recognition
Based on Isomap Features***

Rifki Kosasih^{1*}, Iffatul Mardhiyah², Dina Indarti³

^{1,3} *Teknologi Industri, Informatika, Universitas Gunadarma, Indonesia*

² *Magister Manajemen Sistem Informasi, Universitas Gunadarma, Indonesia*

Jl. Margonda Raya No. 100, Depok

Email: ¹rifki_kosasih@staff.gunadarma.ac.id, ²iffatul@staff.gunadarma.ac.id,

³dina_indarti@staff.gunadarma.ac.id

**Corresponding Author*

ABSTRAK

Pengenalan wajah merupakan salah satu bidang yang digunakan untuk mengenali seseorang melalui citra ataupun video. Pengenalan wajah ini dapat digunakan untuk absensi kehadiran yang lebih efektif dan efisien dibandingkan dengan absensi menggunakan cara manual. Pada penelitian ini data yang digunakan merupakan data citra wajah yang terdiri dari 6 orang dengan tiap orang memiliki 4 variasi ekspresi wajah. Tahapan selanjutnya adalah melakukan ekstraksi fitur wajah dengan menggunakan metode isomap. Metode isomap adalah salah satu metode yang dapat mereduksi dimensi dari dimensi yang tinggi ke dimensi yang lebih rendah. Dalam studi ini dimensi yang dihasilkan sebanyak 4 sehingga terdapat 4 fitur yang akan digunakan dalam pengklasifikasian wajah. Fitur-fitur tersebut dibagi menjadi fitur latih dan fitur uji. Untuk pengklasifikasian wajah, digunakan metode *Support Vector Machine (SVM)*. Metode *Support Vector Machine* merupakan metode *supervised learning* yang dapat digunakan dalam pengenalan pola dan klasifikasi. Metode *Support Vector Machine* memperhatikan perhitungan jarak kedekatan fitur satu dengan fitur lainnya dalam pengenalan pola dan klasifikasi. Berdasarkan hasil klasifikasi diperoleh tingkat akurasi sebesar 87,5%, rata-rata terbobot presisi sebesar 79,1675% dan rata-rata terbobot *recall* sebesar 87,5%.

Kata Kunci: Pengenalan wajah; Isomap; SVM; Ekstraksi Fitur; Klasifikasi.

ABSTRACT

Face recognition is one of the fields used to recognize a person through images or videos. Face recognition can be used for attendance which is more effective and efficient compared to



This open access article is distributed under a Creative Commons Attribution (CC-BY) 4.0 license

attendance using the manual method. In this study, we use facial image data consisting of 6 people with each person having 4 variations of facial expressions. The next stage, we perform facial feature extraction using the isomap method. The isomap method is a method that can reduce dimensions from high dimensions to lower dimensions. In this study, the resulting dimensions are 4 so that there are 4 features that will be used in classifying faces. These features are divided into training features and test features. For face classification, the support vector machine (SVM) method is used. The support vector machine method is a supervised learning method that can be used in pattern recognition and classification. The support vector machine method pays attention to calculating the proximity of one feature to another feature in pattern recognition and classification. Based on the classification results obtained an accuracy rate of 87.5%, a weighted average precision of 79.1675% and a weighted average *recall* of 87.5%.

Keywords: *Face Recognition; Isomap; SVM; Feature Extraction; Classification.a*

1. PENDAHULUAN

Wajah merupakan salah satu ukuran fisiologis yang mudah digunakan untuk membedakan indentitas individu yang satu dengan lainnya. Manusia dapat membedakan wajah antara orang yang satu dengan yang lain dengan cara melihat wajah seseorang. Oleh karena itu, wajah dapat dijadikan ciri khusus atau fitur yang dapat digunakan dalam pengenalan seseorang yang biasa dikenal dengan pengenalan wajah [1], [2].

Pengenalan wajah merupakan salah satu teknologi biometrics yang banyak dipelajari dan dikembangkan dalam mengenali seseorang. Pengenalan wajah dapat diaplikasikan ke berbagai bidang salah satunya di bidang perekaman data seperti absensi. Pengenalan citra wajah pada sistem absensi untuk meminimalisir keterlambatan, bolos dan tidak dapat melakukan kecurangan untuk digantikan saat absen dengan menggunakan metode *Eigenface*, dan nilai akurasi bervariasi rata-rata 93% dipengaruhi oleh jarak, pencahayaan dan objek wajah yang tertutupi, [3]. Pada penelitian lain, identifikasi pengenalan wajah untuk sistem presensi memperoleh rata-rata nilai akurasi pada pengenalan wajah menggunakan LBPH (*Local Binary Pattern Histogram*) sebesar 93,9%, untuk klasifikasi KNN menggunakan *Euclidean Distance* [4].

Pada awalnya, absensi kehadiran dilakukan dengan menggunakan metode manual yaitu dengan cara mengisi daftar hadir yang sudah dibuat sebelumnya. Akan tetapi metode ini banyak memiliki kekurangan, salah satunya saat melakukan absen dapat menyebabkan antrian yang cukup panjang sehingga waktu yang dibutuhkan untuk melakukan absensi menjadi lama, selain itu adanya kemungkinan terjadinya pemalsuan tanda tangan. Oleh karena itu, dibutuhkan suatu metode alternatif yang dapat melakukan perekaman data absensi secara otomatis dan efisien. Pada penelitian ini diusulkan menggunakan metode *Support Vector Machine (SVM)* berdasarkan ekstraksi fitur isomap.

Isomap merupakan salah satu teknik reduksi dimensi yang digunakan untuk mengekstrak fitur yang berasal dari citra wajah [5]. Fitur-fitur yang sudah diperoleh sebelumnya digunakan sebagai input untuk pengklasifikasian wajah dengan menggunakan metode SVM. Metode SVM memiliki keunggulan dalam menentukan jarak menggunakan support vector sehingga cenderung membuat perhitungan menjadi lebih cepat dan tingkat

akurasi yang tinggi. Dalam menganalisa sistem pengenalan wajah, sangat diperlukan model yang memperhatikan tingkat akurasi dalam perhitungan jarak kedekatan antara fitur satu dengan fitur lainnya. Oleh karena itu, metode SVM dipilih sebagai salah satu model yang digunakan untuk menentukan klasifikasi fitur setelah melalui proses ekstraksi fitur [6].

Beberapa penelitian terdahulu yang berkaitan dengan pengenalan wajah telah dilakukan seperti Salamun yang menggunakan metode *Principle Component Analysis* (PCA) untuk mengekstrak fitur wajah. Data yang digunakan sebanyak 130 citra dan dalam penelitiannya diperoleh bahwa tingkat akurasi pengenalan wajah sebesar 82,27% [7]. Akan tetapi proses komputasi sangat besar. Wajah memiliki perbedaan (ciri khas), selain itu wajah juga merupakan pusat dari ekspresi pada manusia. Djamsi membuat dua skenario pengujian untuk mendeteksi ekspresi wajah berdasarkan citra wajah, dengan menggunakan dataset TFEIDHigh, yaitu dengan metode *K-Nearest Neighbour (K-NN)* dan metode *Convolutional Neural Network (CNN)* [8]. Penelitian lain mengenai pengenalan wajah pada gambar wajah berkualitas rendah dengan ekstraksi fitur gabungan Hu-Moment, HOG dan Haralick dengan algoritma *Linear Discriminant Analysis* (LDA) menghasilkan nilai akurasi yang cukup tinggi sekitar 79,71%. Pengenalan wajah dengan menggunakan metode *machine learning* dapat juga dilakukan dengan metode *Logistic Regression (LR)*, *Linear Discriminant Analysis (LDA)*, *Decision Tree Classifier*, *Random Forest Classifier (RF)*, *Gaussian NB*, *K Neighbors Classifier (KNN)* dan *Support Vector Machine (SVM)* dan beberapa metode ekstraksi fitur Hu-Moment, HOG dan Haralick pada dataset Yale Face [9].

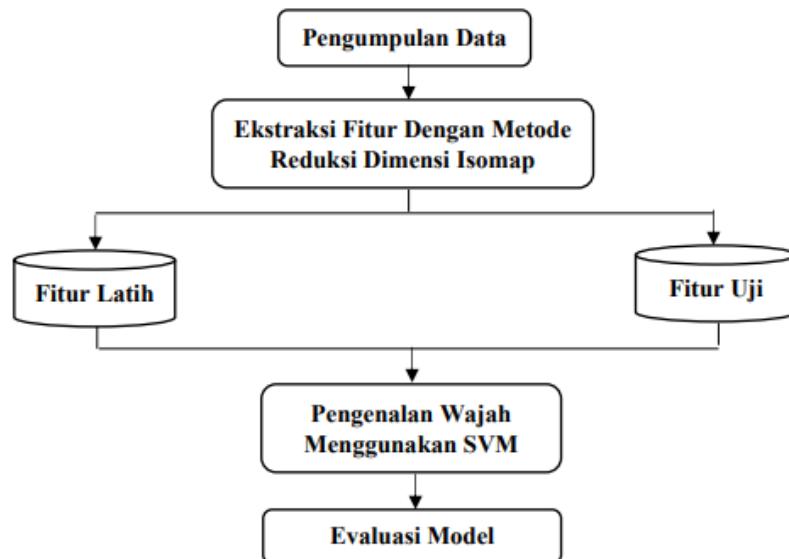
Lebih lanjut, Rosyani juga menerapkan *Canberra Distance* untuk pencocokan citra uji dengan citra latih berdasarkan fitur wajah yang diperoleh dengan metode PCA. Data yang digunakan adalah 40 citra wajah dan berdasarkan hasil uji coba diperoleh tingkat akurasi sebesar 84,5% [10]. Akan tetapi proses komputasi sangat besar. Selanjutnya, Fahrurrozi menerapkan operator *Local Binary Pattern (LBP)* dan metode PCA untuk mengenali wajah. Dalam penelitiannya operator LBP digunakan untuk mempertegas fitur wajah. Pada penelitiannya digunakan 40 citra wajah yang terdiri dari 8 orang dengan tiap orang memiliki 5 citra wajah dengan variasi ekspresi. Berdasarkan hasil penelitian penerapan LBP dalam mengenali wajah, didapatkan tingkat akurasi sebesar 75% [11].

Kosasih melakukan pengelompokan wajah manusia menggunakan metode reduksi dimensi seperti isomap. Citra yang digunakan terdiri dari 5 orang dengan tiap orang memiliki 4 variasi citra wajah. Dalam penelitian dengan metode isomap, fitur hasil reduksi dapat divisualisasikan untuk dapat dilakukan ekstraksi fitur. Dalam penelitiannya, citra-citra wajah yang berasal dari orang yang sama mengelompok ke dalam satu area akan tetapi pada penelitian pengelompokan wajah manusia dengan metode isomap belum melakukan pengenalan wajah [12].

Oleh karena itu, pada penelitian ini diusulkan untuk melakukan klasifikasi wajah berdasarkan ekstraksi fitur isomap. Dalam penelitian ini digunakan metode pengklasifikasi metode *support vector machine (SVM)* untuk mengenali wajah seseorang. Selain itu, evaluasi model juga dilakukan dengan menghitung tingkat akurasi, *recall* dan presisi.

2. METODE PENELITIAN

Dalam penelitian ini, untuk melakukan pengenalan wajah dibutuhkan tahapan-tahapan. Tahapan pertama adalah pengumpulan data citra wajah yang dengan beberapa variasi wajah. Tahapan kedua dalam penelitian ini melakukan ekstraksi fitur dengan menggunakan metode reduksi dimensi Isomap. Pada tahapan ekstraksi fitur memperhatikan fitur latih dan fitur uji yang dilanjutkan dengan tahapan pengenalan wajah menggunakan metode SVM seperti pada Gambar 1.



Gambar 1. Tahapan Penelitian

Berdasarkan Gambar 1, alur tahapan penelitian, data citra wajah yang dikumpulkan terdiri dari 6 orang dengan tiap orang memiliki 4 variasi wajah (total 24 citra). Citra tersebut diperoleh dari ORL database. Tahapan selanjutnya adalah mengekstrak fitur pada citra wajah yang akan digunakan untuk pengklasifikasian wajah. Metode yang digunakan untuk mengekstrak fitur wajah adalah metode isomap. Selanjutnya, pengenalan wajah akan dilakukan dengan menggunakan SVM dan dilakukan evaluasi model.

2.1. Metode Isomap

Metode Isomap merupakan salah satu metode reduksi dimensi yang dapat digunakan untuk mengekstrak fitur pada citra wajah manusia. Metode Isomap pertama kali diperkenalkan oleh Tenenbaum yang mengusulkan untuk membangun graf $G(V, E)$ dengan V merupakan *vertex* yang mewakili kumpulan dari citra-citra wajah dan E merupakan *edge* yang mewakili jarak antara dua *vertex* [13]. Kemudian menentukan k tetangga terdekat dan mencari jarak terdekat dari graf $G(V, E)$ berdasarkan jarak geodesi H_g . Dalam penelitian ini digunakan metode Floyd warshall untuk mencari jarak terdekat dari graf $G(V, E)$. Tahapan selanjutnya adalah melakukan transformasi dari dimensi yang tinggi ke dimensi yang lebih rendah dengan membangun matriks M_g seperti pada persamaan (1) [14].

$$M_g = -\frac{BH_g^2B}{2} \quad (1)$$

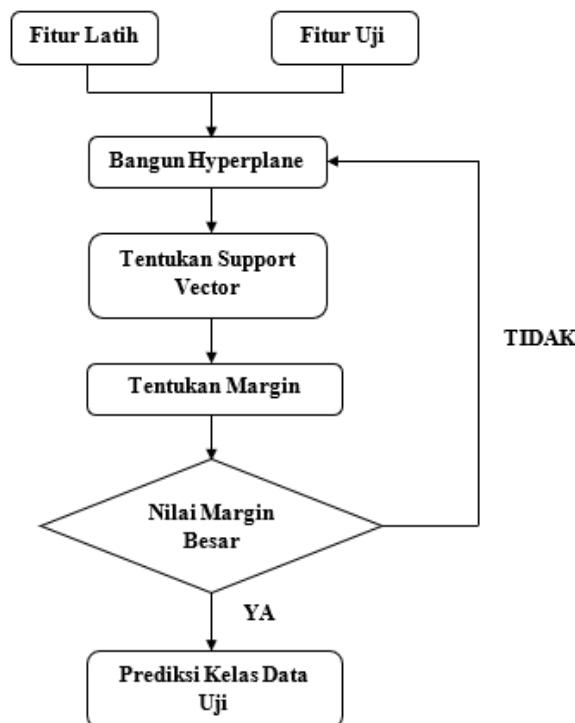
dengan $B = I - \frac{1}{n} \mathbf{1} \mathbf{1}^T$, I merupakan matriks identitas, $\mathbf{1}$ merupakan vektor yang semua anggotanya adalah 1, dan C_g^2 merupakan matriks yang setiap anggotanya adalah kuadrat dari setiap anggota C_g . Sesuai persamaan (1) matriks M_g diperoleh dengan melakukan perhitungan matriks B dikalikan dengan hasil kuadrat matriks jarak geodesi dan perkalian dari kanan dengan matriks B , selanjutnya dibagi 2. Tahapan terakhir dalam menentukan matriks hasil transformasi adalah mencari nilai eigen (λ) dan vektor eigen (ν) yang diperoleh dari matriks F_g . Setelah itu bangun matriks Y seperti pada persamaan (2).

$$Y = [\sqrt{\lambda_1} \nu_1, \sqrt{\lambda_2} \nu_2, \dots, \sqrt{\lambda_n} \nu_n]^T \quad (2)$$

Matriks Y merupakan matriks hasil transformasi yang digunakan sebagai fitur baru sebagai hasil ekstraksi fitur. Hasil ekstraksi fitur selanjutnya digunakan untuk input klasifikasi. Fitur-fitur hasil ekstraksi fitur dibagi menjadi fitur latih dan fitur uji. Tahapan berikutnya, dilakukan klasifikasi fitur uji dengan menggunakan metode *support vector machine* (SVM).

2.2. Support Vector Machine (SVM)

Support vector machine (SVM) merupakan metode *supervised learning* yang digunakan untuk pengenalan pola dan analisis data. Selain itu, metode ini juga dapat digunakan dalam klasifikasi dan analisis regresi [15], [16]. Dalam proses klasifikasi, SVM memetakan vektor dengan memasukkan ke ruang yang berdimensi tinggi. Dalam ruang tersebut, dibangun *hyperplane* yang digunakan untuk memisahkan kelas-kelas pada data. Langkah-langkah dari metode SVM dapat dilihat pada Gambar 2.



Gambar 2. Langkah-Langkah dari metode SVM

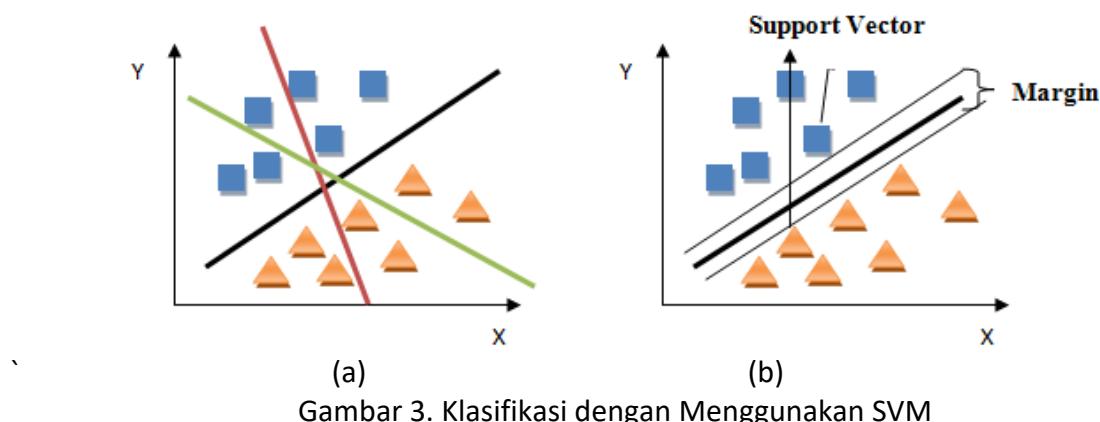
Berdasarkan Gambar 2, Setelah fitur latih dan fitur uji diperoleh selanjutnya fitur-fitur dari data dipetakan ke dalam ruang dimensi lebih tinggi menggunakan fungsi *kernel*. Pemetaan fitur latih dan fitur uji pada ruang dimensi lebih tinggi dengan membangun *hyperplane*. Dalam penelitian pengenalan wajah dengan isomap ini, fungsi *kernel linear* digunakan dalam memetakan fitur uji dan fitur latih seperti pada persamaan (3) [17].

$$K(x_i, x_j) = x_i^T x_j \quad (3)$$

Setelah itu dibangun *hyperplane* dengan menggunakan rumus pada persamaan (4).

$$W^T x + b = 0 \quad (4)$$

Persamaan (4) merepresentasikan *hyperplane*, dengan W merupakan vektor normal yang dapat menentukan arah dari *hyperplane* dan b merupakan konstanta yang menentukan jarak antara *hyperplane* dengan titik pusat. Setelah itu langkah selanjutnya adalah menentukan *support vector* yang merupakan fitur latih yang terdekat dengan *hyperplane*. *Support vector* ini akan menentukan bidang pemisah (*hyperplane*) yang memisahkan antara set objek yang memiliki keanggotaan kelas yang berbeda dengan cara menghitung *margin*. *Margin* merupakan jarak antara *hyperplane* dengan titik kelas terdekat (*support vector*) [18]. Jika *margin* lebih besar di antara kelas-kelas, maka itu dianggap sebagai *margin* yang baik dan selanjutnya dapat digunakan untuk memprediksi data uji [19]. Jika besar *margin* lebih kecil maka proses diulangi dengan membangun kembali *hyperplane*. Proses ini dilakukan berulang sampai diperoleh *hyperplane* yang terbaik. *Hyperplane* yang terbaik adalah yang hasil perhitungan nilai *margin* lebih besar. Ilustrasi dari metode SVM dapat dilihat pada Gambar 3.



Gambar 3 (a) menunjukkan klasifikasi belum menggunakan SVM, belum ada *hyperplane* dan selanjutnya pada Gambar 3 (b) terlihat sudah terdapat *hyperplane* yang terlihat dan terdapat *margin*. *Margin* dihitung untuk mengetahui jarak antara *hyperplane* dengan *support vector*. *Margin* yang nilainya lebih besar yang akan digunakan dalam menentukan prediksi kelas data uji.

3. HASIL DAN PEMBAHASAN

Pada bagian ini dibahas hasil penelitian yang sudah dilakukan seperti hasil pengumpulan dataset citra wajah, hasil ekstraksi fitur dengan menggunakan metode isomap dan hasil klasifikasi wajah dengan menggunakan metode SVM. Berdasarkan Gambar 2, tahap pertama menghasilkan hasil pengumpulan data citra wajah. Ekstraksi fitur pada penelitian ini menggunakan metode isomap untuk mendapatkan fitur unik pada wajah. Fitur-fitur hasil ekstraksi dibagi secara acak menjadi fitur latih dan fitur uji. Metode isomap mereduksi dimensi dari dimensi yang tinggi ke dimensi yang lebih rendah untuk mempermudah proses ekstraksi. Selanjutnya, pada penelitian pengenalan wajah akan digunakan metode SVM. Metode SVM menentukan jarak menggunakan support vector, dengan tujuan membuat perhitungan menjadi lebih cepat dan tingkat akurasi yang tinggi. Model yang dihasilkan diharapkan dapat memperhatikan tingkat akurasi dalam perhitungan jarak kedekatan antara fitur satu dengan fitur lainnya.

3.1. Hasil Pengumpulan Citra Wajah

Dataset citra wajah yang sudah dikumpulkan berasal dari ORL *database* seperti pada Gambar 4. Citra-citra tersebut berukuran 280×315 , terdiri dari citra wajah 6 orang yang berbeda. Tiap orang memiliki 4 variasi wajah, sehingga total terdapat 24 citra.



Gambar 4. Dataset Citra Wajah

3.2. Hasil Ekstraksi Fitur Citra

Tahapan selanjutnya adalah melakukan ekstraksi fitur menggunakan metode isomap untuk mendapatkan fitur unik pada wajah. Citra-citra wajah yang sudah dikumpulkan selanjutnya diubah menjadi kumpulan vektor-vektor berdimensi tinggi. Vektor-vektor tersebut selanjutnya disebut dengan verteks. Setelah itu dilakukan reduksi dimensi dari

dimensi tinggi menjadi dimensi yang lebih rendah dengan menggunakan metode isomap seperti pada persamaan (2). Hasil reduksi dimensi tersebut selanjutnya disebut dengan hasil ekstraksi fitur. Hasil ekstraksi fitur dapat dilihat pada Tabel 1.

Tabel 1. Fitur Hasil Isomap

fitur1	fitur2	fitur3	fitur4	Kelas
3353,991	895,3262	-1905,87	-547,668	1
1865,715	539,9132	-732,798	130,2959	1
2591,17	-913,433	-676,285	1808,866	1
254,3354	-2302,86	-4,20926	2810,173	1
-1669,34	5691,88	4499,27	3580,42	2
-1386,63	7475,373	4079,722	387,3025	2
-537,349	8090,167	4172,715	906,2219	2
258,4072	4698,528	4139,107	3229,985	2
-1509,9	3310,644	-2107,86	-3009,61	3
-5018,16	3229,181	-3885,48	-3687,17	3
-3752,17	1644,93	-2640,35	-4241,87	3
-3337,56	4378,413	-3404,94	-1299,32	3
-9293,96	-3889,42	392,4702	2361,835	4
-7616,62	-2642,77	-296,885	-1989,9	4
-8536,55	-2661,72	882,6216	-3641,11	4
-8374,26	-2811,57	730,7217	1752,626	4
2871,136	-2708,39	-1427,35	-999,04	5
4279,461	-13795,8	-2087,92	1299,07	5
10899,96	-5659,91	11283,26	-5583,11	5
-1417,9	-2787,44	-1472,83	-214,15	5
7471,734	1367,492	-3430,37	8072,981	6
692,9532	-5742,52	573,569	2388,598	6
15720,48	5147,206	-5708,31	-3471,2	6
2191,061	-553,263	-972,016	-44,2337	6

Pada Tabel 1, terdapat empat fitur yang dihasilkan oleh metode isomap. Fitur-fitur tersebut dibagi secara acak menjadi 16 fitur latih dan 8 fitur uji. Fitur latih digunakan sebagai data historis sedangkan fitur uji digunakan untuk menguji model klasifikasi berdasarkan fitur latih. Untuk pengujian, digunakan model klasifikasi seperti SVM. Di dalam proses pengklasifikasian dengan menggunakan model klasifikasi SVM, fitur latih dan fitur uji yang telah diperoleh selanjutnya dipetakan ke dalam ruang dimensi lebih tinggi menggunakan fungsi *kernel*. Pemetaan fitur latih dan fitur uji pada ruang dimensi lebih tinggi dengan membangun *hyperplane*. Dalam penelitian pengenalan wajah dengan isomap ini, fungsi *kernel linear* digunakan dalam memetakan fitur uji dan fitur latih seperti pada persamaan (3).

Tabel 2. Matriks Confusion dari SVM

		Data Sebenarnya					
		1	2	3	4	5	6
Hasil Prediksi	1	2	0	0	0	0	1
	2	0	1	0	0	0	0
	3	0	0	2	0	0	0
	4	0	0	0	1	0	0
	5	0	0	0	0	1	0
	6	0	0	0	0	0	0

Pada Tabel 2, terdapat 6 kelas dengan satu kelas diwakili dengan satu orang. Berdasarkan hasil matriks confusion, wajah orang ke-1 pada keadaan nyata diprediksi wajah orang ke-1 sebanyak 2, wajah orang ke-2 pada keadaan nyata diprediksi wajah orang ke-2 sebanyak 1, wajah orang ke-3 pada keadaan nyata diprediksi wajah orang ke-3 sebanyak 2, wajah orang ke-4 pada keadaan nyata diprediksi wajah orang ke-4 sebanyak 1, wajah orang ke-5 pada keadaan nyata diprediksi wajah orang ke-5 sebanyak 1, sedangkan wajah orang ke-6 pada keadaan nyata diprediksi wajah orang ke-1 sebanyak 1.

Jumlah wajah orang terdeteksi di keadaan sebenarnya dan dinyatakan sebagai wajah orang yang bersesuaian di sistem, sesuai jumlah nilai diagonal pada matriks confusion adalah 7. Berdasarkan Tabel 2, tidak ditemukan hasil prediksi data citra dengan kasus tidak ada wajah yang terdeteksi dalam keadaan sebenarnya dan tidak terdeteksi di sistem, sehingga nilai TN adalah 0. Banyak data yang aktual kelasnya negatif, namun model memprediksi positif adalah 1, sehingga dikatakan nilai FP adalah 1. Tidak terdapat kasus tidak ada wajah yang terdeteksi dalam keadaan sebenarnya tetapi dinyatakan wajah di sistem pada hasil prediksi, sehingga nilai FN bernilai 0.

Evaluasi hasil pengujian dilakukan dengan menghitung nilai presisi, *recall*, akurasi, rata-rata terbobot presisi (RTP) dan rata-rata terbobot *recall* (RTR) pada masing-masing kelas dengan menggunakan (4), (5), (6), (7) dan (8), [20]–[22].

$$akurasi = \frac{TP+TN}{TP+FP+TN+FN} \times 100\% \quad (4)$$

$$p_i = \frac{TP_i}{TP_i+FP_i} \times 100\% \quad (5)$$

$$RTP = \frac{\sum_{i=1}^n p_i d_i}{\sum_{i=1}^n d_i} \quad (6)$$

$$r_i = \frac{TP_i}{TP_i+FN_i} \times 100\% \quad (7)$$

$$RTR = \frac{\sum_{i=1}^n r_i d_i}{\sum_{i=1}^n d_i} \quad (8)$$

Dengan TP (*True Positive*) adalah wajah orang ke A terdeteksi di keadaan sebenarnya dan dinyatakan sebagai wajah orang ke A di sistem, FP (*False Positive*) adalah tidak ada wajah yang terdeteksi dalam keadaan sebenarnya tetapi dinyatakan wajah di sistem, FN (*False Negative*) adalah wajah ke A terdeteksi di keadaan sebenarnya tetapi tidak terdeteksi di sistem dan TN (*True Negative*) adalah tidak ada wajah yang terdeteksi dalam keadaan sebenarnya dan tidak terdeteksi di sistem, p_i merupakan nilai presisi untuk kelas ke- i , d_i merupakan jumlah data aktual pada kelas ke- i dan r_i merupakan nilai *recall* untuk kelas ke- i . Selanjutnya, p_i digunakan untuk perhitungan mencari RTP atau rata-rata terbobot presisi. Nilai recall r_i digunakan untuk menentukan rata-rata terbobot recall (RTR).

Akurasi adalah perhitungan yang digunakan untuk mengevaluasi akurasi klasifikasi. Berdasarkan Tabel 2, nilai akurasi diperoleh dengan menggunakan persamaan (4) adalah 87,5 % sebagaimana penjabaran pada persamaan berikut ini

$$\text{akurasi} = \frac{TP+TN}{TP+FP+TN+FN} \times 100\% = \frac{7+0}{7+1+0+0} \times 100\% = \frac{7}{8} \times 100\% = 87,5\%$$

Nilai presisi yang disimbolkan dengan p_i adalah nilai proporsi kasus positif yang diprediksi benar dan dihitung dalam bentuk persentase untuk kelas ke- i sesuai hasil klasifikasi, seperti yang ditunjukkan pada persamaan (5). Perhitungan nilai presisi pada tiap kelas menggunakan persamaan (5) dengan memperhatikan nilai TP setiap kelas. Nilai presisi untuk kelas ke-1 adalah sebesar 66,67% ditunjukkan pada persamaan berikut ini

$$p_1 = \frac{TP_1}{TP_1+FP_1} \times 100\% = \frac{2}{2+1} \times 100\% = 66,67\%$$

$$p_2 = \frac{TP_2}{TP_2+FP_2} \times 100\% = \frac{1}{1+0} \times 100\% = 100\%$$

$$p_3 = \frac{TP_3}{TP_3+FP_3} \times 100\% = \frac{2}{2+0} \times 100\% = 100\%$$

$$p_4 = \frac{TP_4}{TP_4+FP_4} \times 100\% = \frac{1}{1+0} \times 100\% = 100\%$$

$$p_5 = \frac{TP_5}{TP_5+FP_5} \times 100\% = \frac{1}{1+0} \times 100\% = 100\%$$

$$p_6 = \frac{TP_6}{TP_6+FP_6} \times 100\% = \frac{0}{0+1} \times 100\% = 0\%$$

$$RTP = \frac{(2 \times 66,67\%) + (1 \times 100\%) + (2 \times 100\%) + (1 \times 100\%) + (1 \times 100\%) + (0 \times 100\%)}{2+1+2+1+1+1} = 79,1675\%$$

Berdasarkan hasil matriks confusion, nilai presisi untuk kelas ke-2 dengan nilai TP nya bernilai 1, dan FP bernilai 0, sehingga nilai presisi untuk kelas ke-2 adalah 100%, sesuai perhitungan pada persamaan (11). Nilai TP untuk kelas ke-3 berdasarkan Tabel 2 bernilai 2, sedangkan nilai FP nya bernilai 0, sehingga nilai presisi untuk kelas ke-3 adalah sebesar 100%, sesuai persamaan (12). Hasil prediksi pada Tabel 2 menghasilkan nilai TP untuk kelas ke-4 dan ke-5

bernilai 1 dengan FP bernilai 0, sehingga nilai presisi untuk kelas ke-4 dan ke-5 bernilai sama yaitu 100% sesuai perhitungan pada persamaan (13) dan (14). Oleh karena TP untuk kelas ke-6 bernilai 0 sedangkan nilai FP bernilai 1, sesuai perhitungan pada persamaan (15), nilai presisi untuk kelas ke-6 adalah 0%.

Rata-rata terbobot presisi dihitung berdasarkan hasil nilai presisi seluruh kelas dan jumlah data aktual keseluruhan, disimbolkan dengan *RTP* dan ditunjukkan oleh persamaan (6). Berdasarkan hasil perhitungan nilai presisi kelas ke-1 sampai kelas ke-6 sesuai persamaan (10)-(15), maka hasil perhitungan *RTP* atau rata-rata terbobot presisi adalah sebesar 79,1675%. Untuk hasil evaluasi keseluruhan dapat dilihat seperti pada Tabel 3.

Tabel 3. Hasil Performa Metode SVM

Kelas	Presisi	Recall	Jumlah Data Uji
1	66,67 %	100 %	1
2	100 %	100 %	1
3	100 %	100 %	1
4	100 %	100 %	2
5	100 %	100 %	2
6	0 %	0 %	1
Rata-rata Terbobot	79,1675 %	87,5%	

Perhitungan nilai recall untuk kelas ke-*i* dalam persentase ditunjukkan oleh persamaan (7). Berdasarkan Tabel 3, diperoleh bahwa nilai rata-rata terbobot presisi hasil pengenalan wajah sebesar 79,1675 %, nilai rata-rata terbobot *recall* sebesar 87,5 %.

4. KESIMPULAN

Wajah merupakan salah satu fitur yang digunakan untuk mengenali seseorang. Pengenalan wajah dapat digunakan di berbagai bidang seperti absensi, keamanan keanggotaan, dan deteksi wajah lainnya. Dalam penelitian ini, digunakan 24 citra dari 6 orang dengan tiap orang mempunyai 4 citra yang berbeda dalam variasi ekspresi wajah. Ekstraksi fitur pada penelitian ini dilakukan dengan menggunakan metode isomap. Hasil ekstraksi fitur tersebut menghasilkan 4 fitur yang selanjutnya digunakan untuk tahap pengklasifikasian wajah. Fitur-fitur hasil ekstraksi dibagi menjadi 16 fitur latih dan 8 fitur uji. Tahapan selanjutnya setelah ekstraksi fitur adalah melakukan klasifikasi wajah dengan metode *support vector machine* (SVM). Metode support vector machine merupakan metode supervised learning yang dapat digunakan dalam pengenalan pola dan klasifikasi. Keunggulan dari metode support vector machine adalah memperhatikan perhitungan jarak kedekatan fitur satu dengan fitur lainnya. Tahapan terakhir adalah melakukan evaluasi model dengan menghitung nilai akurasi, rata-rata terbobot presisi dan rata-rata terbobot *recall*. Nilai presisi pada 4 kelas sesuai hasil prediksi pada matriks confusion bernilai 100% dari 6 kelas yang terbentuk. Berdasarkan hasil penelitian dengan metode SVM diperoleh bahwa tingkat akurasi sebesar 87,5%, nilai rata-rata terbobot presisi sebesar 79,1675 %, nilai rata-rata terbobot *recall* sebesar 87,5 %. Untuk penelitian selanjutnya adalah memperbanyak data citra wajah

dan menggunakan pendekatan metode lain seperti deep learning dalam melakukan pengenalan wajah.

DAFTAR PUSTAKA

- [1] R. Kosasih, "Penggunaan Metode Linear Discriminant Analysis Untuk Pengenalan Wajah Dengan Membandingkan Banyaknya Data Latih," *J. Ilm. Teknol. dan Rekayasa*, vol. 26, no. 1, pp. 25–34, 2021.
- [2] R. Kosasih, "Pengenalan Wajah Menggunakan PCA dengan Memperhatikan Jumlah Data Latih dan Vektor Eigen," *J. Inform. Univ. Pamulang*, vol. 6, no. 1, pp. 1–6, 2021.
- [3] Rifky Kurniawan, "Penerapan Metode *Eigenface* untuk Pengenalan Citra Wajah pada Sistem Absensi," *J. Ilm. Indones.*, vol. 7, no. 10, pp. 17871–17885, 2022, doi: 10.36418/syntax-literate.v7i10.13208.
- [4] D. Yulianti, I. Triastomoro, and S. Sa'idah, "Identifikasi Pengenalan Wajah Untuk Sistem Presensi Menggunakan Metode Knn (K-Nearest Neighbor)," *J. Tek. Inf. dan Komput.*, vol. 5, no. 1, pp. 1–10, 2022, doi: 10.37600/tekinkom.v5i1.477.
- [5] R. Kosasih, "Kombinasi Metode Isomap dan KNN Pada Image Processing Untuk Pengenalan Wajah," *CESS (Journal Comput. Eng. Syst. Sci.)*, vol. 5, no. 2, pp. 166–170, 2020.
- [6] Salamun and F. Wazir, "Rancang Bangun Sistem Pengenalan Wajah Dengan Metode Principal Component Analysis," *J. Teknol. dan Sist. Inf. UNIVRAB*, vol. 1, no. 2, pp. 59–75, 2016, doi: 10.36341/rabit.v1i2.25.
- [7] E. A. M. Iqbal, "Hybrid model transfer Learning ResNet50 dengan *Support Vector Machine* untuk Deteksi Masker pada Image wajah," 2023.
- [8] N. Djamsi, D. Rizki Chandranegara, and Z. Sari, "Mendeteksi Ekspresi Wajah dengan Meninjau Iris Mata Menggunakan Metode Transformasi Hough dan K-Nearest Neighbor (KNN)," *Repositor*, vol. 5, no. 1, pp. 575–580, 2023.
- [9] Siti Khotimatul Wildah, S. Agustiani, Ali Mustopa, Nanik Wuryani, Hendri Mahmud Nawawi, and Rizky Ade Safitri, "Pengenalan Wajah Menggunakan Pembelajaran Mesin Berdasarkan Ekstraksi Fitur Pada Gambar Wajah Berkualitas Rendah," *INFOTECH J. Inform. Teknol.*, vol. 2, no. 2, pp. 95–103, 2021, doi: 10.37373/infotech.v2i2.189.
- [10] P. Rosyani, "Pengenalan Wajah Menggunakan Metode Principal Component Analysis (PCA) dan Canberra Distance," *J. Inform. Univ. Pamulang*, vol. 2, no. 2, p. 118, 2017, doi: 10.32493/informatika.v2i2.1515.
- [11] A. Fahrerozi and R. Kosasih, "Face Recognition Using Local Binary Pattern Combined With PCA For Images Under Various Expression and Illumination," in *Proceeding on International Workshop on Academic Collaboration 2017*, 2017, no. May, pp. 1–7.
- [12] R. Kosasih and A. Fahrerozi, "Clustering of Face Images by Using Isomap method," in *Proceeding on International Workshop on Academic Collaboration 2017*, 2017, no. May, pp. 52–56.
- [13] J. B. Tenenbaum, V. De Silva, and J. C. Langford, "A Global Geometric Framework for Nonlinear Dimensionality Reduction," *Science (80-)*, vol. 290, no. December, pp. 2319–2323, 2000.
- [14] R. Kosasih, A. Fahrerozi, and D. Riminarsih, "Implementation of Random Forest on Face

Recognition Using Isomap Features," *CESS (Journal Comput. Eng. Syst. Sci.)*, vol. 7, no. 2, p. 459, 2022, doi: 10.24114/cess.v7i2.34498.

- [15] A. Ambarwari, Q. J. Adrian, Y. Herdiyeni, and I. Hermadi, "Plant species identification based on leaf venation features using SVM," *TELKOMNIKA*, vol. 18, no. 2, pp. 726–732, 2020, doi: 10.12928/TELKOMNIKA.v18i2.14062.
- [16] M. Jawad, A. Dujaili, A. Ebrahimi-moghadam, and A. Fatlawi, "Speech emotion recognition based on SVM and KNN classifications fusion," *Int. J. Electr. Comput. Eng.*, vol. 11, no. 2, pp. 1259–1264, 2021, doi: 10.11591/ijece.v11i2.pp1259-1264.
- [17] K. M. Mustapha and E. A. Abdellatif, "Adapted branch-and-bound algorithm using SVM with model selection," *Int. J. Electr. Comput. Eng.*, vol. 9, no. 4, pp. 2481–2490, 2019, doi: 10.11591/ijece.v9i4.pp2481-2490.
- [18] Y. K. Zamil, S. A. Ali, and M. A. Naser, "Spam image email filtering using K-NN and SVM," *Int. J. Electr. Comput. Eng.*, vol. 9, no. 1, p. 245, 2019, doi: 10.11591/ijece.v9i1.pp245-254.
- [19] Q. Tian, L. Zhang, Y. Wei, W. Zhao, and W. Fei, "Vehicle Detection and Tracking at Night in Video Surveillance," *Int. J. Online Eng.*, vol. 9, no. 6, pp. 60–64, 2013, doi: 10.3991/ijoe.v9i6.2828.
- [20] A. Fahrerozi and R. Kosasih, "Texture Features and Statistical Features for Wood Types Classification System," in *5th International Conference of Computer and Informatics Engineering (IC2IE)*, 2022, pp. 186–191.
- [21] D. P. Lestari and R. Kosasih, "Comparison of two deep learning methods for detecting fire hotspots," *Int. J. Electr. Comput. Eng.*, vol. 12, no. 3, pp. 3118–3128, 2022, doi: 10.11591/ijece.v12i3.pp3118-3128.
- [22] D. P. Lestari, R. Kosasih, T. Handhika, Murni, I. Sari, and A. Fahrerozi, "Fire Hotspots Detection System on CCTV Videos Using You only Look Once (YOLO) Method and Tiny YOLO Model for High Buildings Evacuation," in *2nd International Conference of Computer and Informatics Engineering IC2IE*, 2019, pp. 87–92.