

PERBANDINGAN KINERJA SUPPORT VECTOR MACHINE (SVM) DALAM MENGENALI WAJAH MENGGUNAKAN SURF DAN GLCM

Syamsul Bahri^{1*}, Khairun Saddami², Fitri Arnia³, dan Kahlil Muchtar³

¹Magister Teknik Elektro, Fakultas Teknik, Universitas Syiah Kuala

²Doktor Ilmu Teknik, Program Pascasarjana, Universitas Syiah Kuala

³Jurusan Teknik Elektro dan Komputer, Fakultas Teknik, Universitas Syiah Kuala

*Corresponding author, e-mail: paksamsol@gmail.com

Abstrak— Pengenalan wajah merupakan salah satu bagian dari penelitian biometrika. Pengenalan wajah banyak digunakan dalam proses identifikasi manusia. Metode ekstraksi fitur *Speed-Up Robust Feature* (SURF) merupakan salah satu metode yang digunakan untuk mengenali wajah. Penelitian ini bertujuan untuk membandingkan kinerja sistem pengenalan wajah dengan menggunakan metode ekstraksi fitur SURF dan *Gray Level Co-occurrence Matrix* (GLCM). Pada penelitian ini, data *input* wajah akan diekstraksi fiturnya menggunakan SURF dan GLCM. Setiap fitur digunakan pada tahapan klasifikasi menggunakan *Support Vector Machine* (SVM). Data yang digunakan merupakan data yang didapatkan dari National Cheng Kung University (NCKU). Data wajah NCKU mempunyai sudut rotasi yang lebih banyak. *Dataset* yang digunakan pada penelitian ini terdiri dari 10 kelas yang menunjukkan 10 subjek penelitian. Pengenalan wajah menggunakan metode SURF dan SVM mempunyai akurasi 85%, sedangkan menggunakan metode GLCM mempunyai akurasi 50%. Hasil menunjukkan bahwa metode SURF mempunyai kinerja yang lebih baik dari metode GLCM.

Kata Kunci : SURF, GLCM, pengenalan wajah, SVM

Abstract— Face recognition is one part of the biometrics research. Face recognition is widely used in identification and recognition process. Speed-up Robust Feature (SURF) is one of feature extraction method used in face recognition system. This research aims to compare face recognition performance between SURF and Gray Level Co-occurrence Matrix (GLCM) methods for perspective rotation. In this study, the image features were extracted using SURF and GLCM. Each feature was used on classification stage using Support Vector Machine (SVM). The dataset was obtained from National Cheng Kung University (NCKU). The NCKU dataset has more variation of rotation angle. The dataset used in this study consists of 10 classes that showed 10 of the subject. The results show that SURF method obtained 85% of accuracy and GLCM method reached 50% of accuracy. Therefore, we concluded that SURF method has better performance on implementing on face recognition system.

Keywords : SURF, GLCM, Face Recognition, SVM

1. Pendahuluan

Pengenalan wajah salah satu bidang penelitian yang sangat populer dalam pengenalan pola dan visi komputer, salah satunya adalah penelitian biometrika. Dalam konteks pengenalan pola, wajah memiliki pola yang unik dibandingkan biometrik lainnya. Wajah menampilkan berbagai informasi yang rumit tentang identitas, usia, jenis kelamin, ras dan keadaan emosional dan perhatian.

Banyak penelitian telah dilakukan untuk mengenali wajah seseorang, salah satu metode yang digunakan adalah metode *Speed-up Robust Features* (SURF). SURF merupakan metode pengembangan dari *scale invariant feature*

transform (SIFT). SIFT mempunyai kelebihan berupa tahan terhadap sifat invariant dari skala dan rotasi dari suatu citra serta mempunyai sifat distinctive (mempunyai ciri-ciri khusus yang unik) [1]. Namun, salah satu kekurangan SIFT adalah waktu proses yang sangat lama. SURF yang merupakan pengembangan dari SIFT mempunyai waktu proses yang lebih cepat dari SIFT [2] dengan tetap mempertahankan keunggulan dari SIFT. Metode SURF dapat digunakan pada proses pengenalan wajah. Namun, terdapat pada metode SURF berupa ketidakmampuan SURF dalam menangani citra dengan perubahan iluminasi [3]. Selain itu,

SURF sangat sensitif terhadap perubahan perspektif (sudut pandang) citra, misalnya terjadi perubahan seperti rotasi kiri atau ke kanan atau sering disebut dengan perubahan planar [4].

Beberapa penelitian terakhir menerapkan metode *deep learning* untuk membangun sistem pengenalan wajah. Ramaiah menggunakan CNN untuk mengenali wajah yang mengalami perubahan iluminasi [5], namun metode menggunakan *deep learning* mempunyai kekurangan pada waktu komputasi. Sebelumnya Syafeeza menggunakan metode CNN dengan pendekatan yang berbeda untuk mengenali wajah yang mengalami perubahan iluminasi pada wajah [6].

Metode *Gray Level Co-occurrence Matrix* (GLCM) adalah salah satu metode yang membangkitkan fitur berdasarkan tekstur dari suatu citra. Salah satu kelebihan GLCM adalah tidak terpengaruh oleh iluminasi citra yang tidak merata [7]. GLCM bekerja dengan mendeteksi posisi dari piksel yang mempunyai kesamaan level keabuan. GLCM menyimpan informasi struktural dari sebuah pola tekstur yang terdapat pada sebuah citra. Selain itu, GLCM juga dapat diterapkan untuk mengenali citra 3D seperti pada penelitian [8], [9]. Oleh karena itu, pada penelitian ini dilakukan perbandingan metode SURF dengan metode GLCM dalam mendeteksi tekstur dari sebuah citra tanpa dipengaruhi oleh rotasi secara planar dan iluminasi dari sebuah citra. Selanjutnya, pada penelitian ini digunakan metode *Support Vector Machine* (SVM) untuk mengklasifikasi dan mengenali wajah dari citra masukan. SVM dipilih karena merupakan salah satu metode berbasis pembelajaran yang mempunyai kemampuan yang sangat baik untuk klasifikasi dengan komputasi yang sederhana.

Penelitian ini membandingkan kinerja metode SURF dengan metode GLCM untuk mendeteksi perubahan perspektif wajah dari sebuah citra tanpa dipengaruhi oleh iluminasi dari sebuah citra. Selanjutnya, pada penelitian ini digunakan metode *Support Vector Machine* (SVM) untuk mengklasifikasi dan mengenali wajah dari citra masukan. SVM dipilih karena merupakan salah satu metode berbasis pembelajaran yang mempunyai kemampuan yang sangat baik untuk klasifikasi dengan komputasi yang sederhana.

2. Tinjauan Pustaka

2.1 *Speed-up Robust Feature* (SURF)

SURF adalah pengembangan algoritma ekstraksi fitur *Scale Invariant Feature Transform* (SIFT). Ekstraksi fitur adalah metode untuk membangkitkan ciri dari suatu citra [10]. SURF mampu mendeteksi fitur lokal dari suatu citra dengan tepat, cepat dan invarian terhadap perubahan skala, rotasi, dan transformasi. SURF menggunakan gabungan citra integral dan *blob detection* berdasarkan determinan dari matriks Hessian pada algoritma ekstraksi fiturnya. Tahapan ekstraksi diawali dengan menentukan titik perhatian (*interest point*) yang mengandung banyak informasi dan stabil terhadap gangguan pada citra, yang mana nilai *interest point* didapatkan menggunakan *blob detection*. Pada tahapan *interest point* terdapat dua tahapan yaitu *scale space representation* dan *feature description*. Pada tahapan *scale space representation* dilakukan untuk mengatasi citra yang memiliki ukuran beragam agar tidak menyulitkan proses perbandingan fitur, sedangkan tahapan *feature description* adalah tahapan ekstraksi fitur pada algoritma SURF. Ekstraksi fitur didapatkan dengan melihat orientasi yang dominan pada titik penting citra, kemudian membangun suatu area yang akan diambil nilainya dan akan dicari fitur korespondensi terhadap citra pembandingan.

2.2 *Gray Level Co-occurrence Matrix* (GLCM)

GLCM adalah metode ekstraksi fitur berdasarkan tekstur dari suatu objek pada citra dan juga berbasis statistik dengan menghitung frekuensi pola piksel yang muncul sehingga membentuk suatu ciri unik. Sudut-sudut yang digunakan pada perhitungan pola distribusi adalah 0° , 45° , 90° dan 135° .

Fitur yang dapat dibangkitkan menggunakan matriks *co-occurrence* diantaranya adalah fitur kontras, korelasi, keseragaman, dan energy [11].

2.3 *Support Vector Machine* (SVM)

SVM merupakan salah satu metode *machine learning* untuk klasifikasi data yang bersifat terlatih [11]. SVM memisahkan data ke dalam kelas dengan garis pemisah (*hyperline*) pada ruang input. SVM menggunakan hipotesis yang berupa fungsi linier dalam ruang fitur yang berdimensi tinggi. *Hyperplane* terbaik dapat diperoleh dengan memaksimalkan margin pada *support vector*.

SVM mampu menentukan *hyperplane* yang optimal pada data yang dapat dipisahkan secara

linier. Persamaan 1 merupakan persamaan untuk menentukan *hyperplane* terbaik pada data yang bersifat linier .

$$f(x) = w \cdot x_i + b \quad (1)$$

dimana w adalah bobot dari fitur, x_i adalah fitur masukan untuk setiap titik, dan b adalah bias. *Hyperplane* yang optimal adalah *hyperplane* yang mempunyai jarak margin yang sama dengan pola pada kedua kelas.

Data masukkan yang berupa data *non-liner* tidak dapat secara langsung ditentukan *hyperplane* untuk memisahkan datanya. Sehingga, SVM dikembangkan agar persoalan seperti itu dapat diatasi, yaitu dengan menggunakan kernel pada SVM. Kernel ini dikenal dengan kernel trick, dimana memetakan data awal ke dalam ruang yang berdimensi tinggi (*feature space*) yang kemudian akan terbentuk sebuah bidang pemisah untuk memisahkan data sesuai dengan kelasnya. Pada *feature space* akan dilakukan pemisahan secara linier. Beberapa kernel yang dapat digunakan untuk data yang non-linier yaitu [12] ditunjukkan pada persamaan 2 ,3 dan 4:

1. Kernel linier: $K(x, x') = x^T x'$ (2)

2. Kernel *polynomial*:

$$K(x, x') = (\gamma(x^T x' + 1))^d \quad (3)$$

3. Kernel *Radial Basis Function* (RBF):

$$K(x, x') = \exp(-\gamma(\|x^T x'\|)^2) \quad (4)$$

i. Multiclass SVM

Terdapat beberapa tipe SVM untuk dapat mengklasifikasi data ke dalam multi kelas, diantaranya adalah *one-against-all* dan *one-against-one*. *one-against-all* adalah metode membandingkan setiap model klasifikasi dengan seluruh data, dengan memisahkan kelas suatu fitur dengan lainnya yang bukan kelas fitur. Sedangkan *one-against-one* adalah metode membandingkan setiap data klasifikasi dengan data dari kategori yang lain, dengan memisahkan kelas suatu fitur dengan fitur kelas lainnya akan membentuk *hyperplane* yang optimal untuk setiap kelasnya. Dengan adanya konsep multiclass SVM, penerapan SVM semakin luas seperti pada

pengenalan karakter [13], pengendalian kualitas daya listrik [14], dan penginderaan jauh [15].

2.3.2 Validasi

Cross-validation (CV) merupakan salah satu metode validasi yang digunakan untuk mengevaluasi kinerja suatu model. CV akan membagi data menjadi data latih dan data uji, yang mana model/algorithm akan dilatih data latih dan diuji oleh data uji.

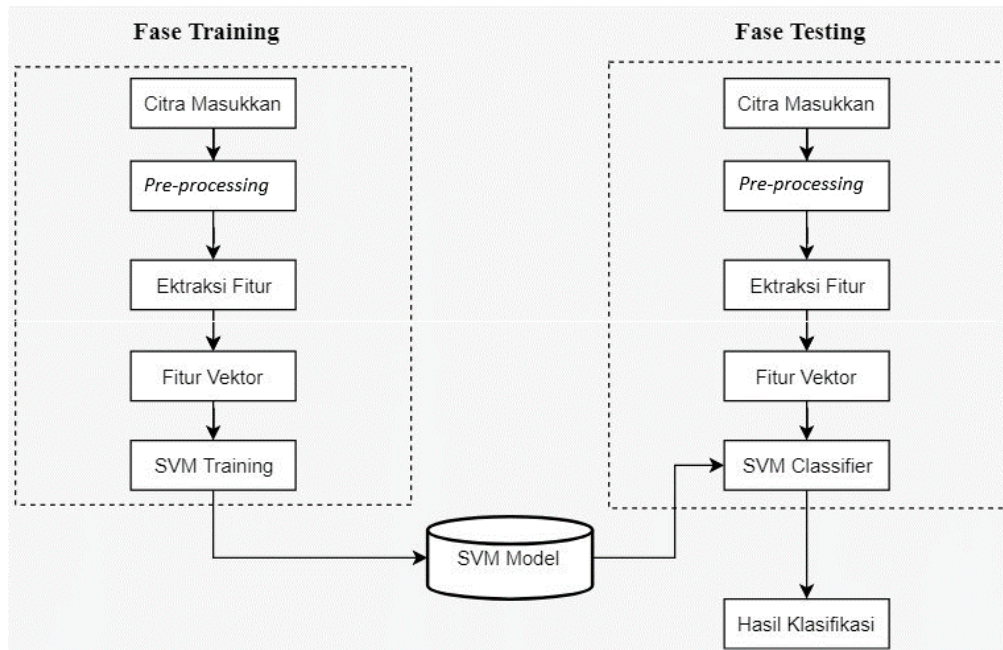
N-fold cross validation adalah salah satu metode CV yang digunakan untuk mengetahui keberhasilan suatu metode/algorithm. Proses *n-fold cross validation* membagi data ke dalam n partisi dengan ukuran yang sama yang selanjutnya proses uji dan latih dilakukan sebanyak n kali. Dalam iterasi ke- i partisi i akan menjadi data uji dan yang lainnya akan menjadi data latih.

3. Metode Penelitian

Pada penelitian ini digunakan dua kelompok *dataset* citra yaitu citra data latih (*latih*) dan citra data uji (*uji*) yang diperoleh dari [http://robotics.csie.ncku.edu.tw/Databases/Our Database/](http://robotics.csie.ncku.edu.tw/Databases/OurDatabase/) yang dikenal dengan *dataset* National Cheng Kung University (NCKU). *Dataset* yang digunakan pada tahapan latih adalah 740 citra wajah yang terdiri dari 10 subjek. Dari 740 citra tersebut, 720 dijadikan sebagai citra latih dan 20 citra dijadikan citra uji dengan proses pengambilan secara acak. Diagram alur kerja pada penelitian ini di ilustrasikan pada gambar 1.

3.1 Tahapan *preprocessing*

Tahapan ini adalah tahapan mengubah citra menjadi citra abu-abu dengan fungsi *rgb2gray* yang sudah terintegrasi ke dalam aplikasi MATLAB. Hal ini dapat dilakukan karena metode SURF dan GLCM tidak membutuhkan informasi warna dari sebuah citra. Oleh karena itu, proses ekstraksi fitur dapat dilakukan terhadap citra keabuan dari objek yang sama.



Gambar 1. Alur penelitian

3.2 Tahapan ekstraksi fitur


Pembangkitan fitur dari citra dilakukan dengan menggunakan GLCM dan SURF.

3.2.1 SURF

Metode SURF mengekstraksi fitur *descriptor* dan fitur *orientation*. *Descriptor* yang dihasilkan oleh metode SURF berukuran 64 *descriptor* untuk setiap titik poin. Fitur ini digunakan sebagai masukan untuk klasifikasi sistem pengenalan wajah. Dari hasil pengujian untuk 10 subjek citra maka panjang ukuran dari fitur SURF adalah 1x8600 fitur.

3.2.2 GLCM

Tahapan pertama yang dilakukan pada metode GLCM adalah menghitung matriks *co-occurrence* dari citra masukan. Matriks *co-occurrence* didapatkan menggunakan fungsi yang sudah terdapat pada aplikasi MATLAB yaitu fungsi *graycomatrix*. Gambar 2 menunjukkan contoh hasil perhitungan matriks *co-occurrence*. Matriks *co-occurrence* seperti pada gambar 2b diekstraksi fitur GLCM dengan menggunakan persamaan 2, 3, 4, dan 5. Matriks pada gambar 3 menggambarkan contoh dari fitur GLCM yang dibangkitkan.



Gambar 2. Hasil perhitungan matriks co-occurrence

18.65248	18.64755	18.66475	18.64610
0.19337	0.12059	0.19064	0.12839
0.94097	0.95749	0.93966	0.95238
0.93968	0.96264	0.94065	0.96020

Gambar 3. Matriks fitur GLCM

Fitur yang diperoleh dari masing-masing metode digabungkan untuk selanjutnya dilakukan klasifikasi. Untuk memudahkan tahapan klasifikasi, sebelum dimasukkan ke tahapan klasifikasi, panjang fitur dari setiap citra diatur sama dengan cara menghapus fitur yang mempunyai panjang lebih dari fitur yang terkecil.

3.3 Tahapan klasifikasi

Dilakukan klasifikasi terhadap fitur citra masukan dengan menggunakan *library libsvm* [16]. Sebelum dilakukan proses uji, terlebih dahulu ditentukan penentuan parameter yang tepat

untuk pembentukan model latih. Penentuan ini dilakukan dengan metode *cross validation*. Parameter yang diuji berupa kernel yang digunakan, nilai *degree* atau pangkat, serta nilai *gamma*.


Proses validasi dilakukan dengan menggunakan metode *k-fold cross validation*. Nilai *k* yang digunakan pada penelitian ini adalah $k=2$ dan $k=4$. Ilustrasi dari proses *k-fold cross validation* dapat dilihat pada gambar 4.

Berdasarkan hasil pengujian, parameter yang terbaik untuk sistem pengenalan wajah pada penelitian ini adalah kernel *Radial Basis Function* (RBF) dengan nilai *gamma* sebesar 10^{-5} dan kernel polinomial dengan pangkat bernilai 1 dan *gamma* bernilai 10^{-4} .

3.4 Evaluasi

Pengujian terhadap model hasil *latih* dilakukan untuk menguji ketahanan model terhadap citra yang diuji. Citra yang akan diuji


adalah citra yang sudah mengalami sudut putar yang sudah tersedia pada *dataset* NKCU.



Gambar 4. Pembagian *dataset* untuk validasi dengan nilai $k=4$

Hasil dari masing-masing pengujian diukur kinerja dengan menggunakan metode *accuracy*. *Accuracy* adalah metode evaluasi hasil klasifikasi yang sudah tersedia pada *library* *libsvm*. Persamaan 5 menunjukkan rumus perhitungan nilai *Accuracy* [16]:

$$Accuracy = \frac{\text{data yang diprediksi dengan tepat}}{\text{total data yang diuji}} \quad (5)$$



Gambar 5. Perbandingan akurasi kernel Polinomial dan RBF pada tahapan *training*, dimana: (a) pengujian iterasi pertama, (b) pengujian iterasi kedua, (c) pengujian iterasi ketiga, (d) pengujian iterasi keempat.

4. Hasil dan Pembahasan

Pada bagian ini dipaparkan hasil dan pembahasan dari penelitian. Ada dua bagian yang dipapar, yaitu hasil pengujian parameter pada tahapan *training* dan pengujian *dataset* terhadap keseluruhan data. Pada tahapan *training*, parameter terbaik yang akan digunakan pada proses pengujian ditentukan dengan menggunakan metode *4-fold validation*. Gambar 5 menunjukkan hasil validasi parameter pada tahapan *training*.

4.1. Penentuan parameter dengan tahapan *training*

Tahapan validasi dilakukan untuk menentukan parameter terbaik dalam membangun model sistem pengenalan wajah. Tahapan validasi yang dilakukan ini merupakan bagian dari tahapan *training*. Pada penelitian ini, metode validasi yang digunakan adalah *4-fold cross validation*. Gambar 5 menunjukkan grafik perbandingan kernel *polynomial* dan *Radial Basis Function* (RBF) dengan 4 iterasi.

Berdasarkan Gambar 5, dapat dilihat bahwa kernel RBF menghasilkan akurasi yang lebih baik dari kernel polinomial. Pada percobaan pertama, kedua, dan ketiga seperti pada gambar 5a, 5b, dan 5c kernel RBF menghasilkan akurasi lebih tinggi dari polinomial, namun pada percobaan keempat, kernel polinomial mempunyai akurasi lebih baik. Berdasarkan pengujian tersebut, terlihat bahwa kernel polinomial dan RBF mempunyai performansi yang tidak sama pada saat *training*. Oleh karena itu, dilakukan pengujian terhadap kedua kernel tersebut untuk melihat kernel terbaik bagi citra uji.

4.2. Pengujian terhadap citra uji dengan metode GLCM

4.2.1. Pengujian menggunakan kernel polinomial

Pada pengujian pertama dilakukan pengujian terhadap dua puluh citra uji dengan parameter seperti pada Tabel 1.

Tabel 1. Parameter uji menggunakan kernel pertama

No	Kernel	Degree	Gamma
1	Polynomial	10	10-4

Hasil pengujian model dari metode GLCM menggunakan kernel polinomial dapat dilihat pada Tabel 2. Metode GLCM hanya berhasil mengenali citra uji dengan tingkat akurasi 0,35 atau 35%. Hanya ada tujuh citra yang dapat diprediksi dengan benar yaitu Citra_1b, Citra_4a, Citra_5a, Citra_5b, Citra_7a, Citra_7b, dan Citra_8a, sedangkan citra uji lain tidak diprediksi dengan tepat.

Tabel 2. Hasil uji menggunakan menggunakan metode GLCM

No	Citra	Label	Prediksi	Akurasi
1	Citra_1a	1	8	0
2	Citra_1b	1	1	1
3	Citra_2a	2	7	0
4	Citra_2b	2	8	0
5	Citra_3a	3	6	0
6	Citra_3b	3	1	0
7	Citra_4a	4	4	1
8	Citra_4b	4	7	0
9	Citra_5a	5	5	1
10	Citra_5b	5	5	1
11	Citra_6a	6	1	0
12	Citra_6b	6	1	0
13	Citra_7a	7	7	1
14	Citra_7b	7	7	1
15	Citra_8a	8	8	1
16	Citra_8b	8	1	0
17	Citra_9a	9	6	0
18	Citra_9b	9	6	0
19	Citra_10a	10	7	0
20	Citra_10b	10	9	0
	Rata-rata			0,35

4.2.2. Pengujian menggunakan kernel RBF

Pada pengujian kedua dilakukan pengujian terhadap dua puluh citra uji menggunakan kernel RBF. Penelitian ini menggunakan parameter pada Tabel 3.

Tabel 3. Parameter uji pada pengujian kedua

No	Kernel	Gamma
1	RBF	10-5

Hasil pengujian model dari metode GLCM menggunakan kernel RBF dapat dilihat pada Tabel 4. Metode gabungan berhasil mengenali citra uji dengan tingkat akurasi 0,40 atau 40%. Hanya ada delapan citra yang dapat diprediksi dengan benar yaitu Citra_1b, Citra_4a, Citra_5a, Citra_5b, Citra_7a, Citra_7b, Citra_8a, dan Citra_8b, sedangkan citra uji lain tidak diprediksi dengan benar.

Tabel 4. Hasil uji menggunakan metode GLCM

No	Citra	Label	Prediksi	Akurasi
1	Citra_1a	1	8	0
2	Citra_1b	1	1	1
3	Citra_2a	2	7	0
4	Citra_2b	2	8	0
5	Citra_3a	3	7	0
6	Citra_3b	3	2	0
7	Citra_4a	4	4	1
8	Citra_4b	4	7	0
9	Citra_5a	5	5	1
10	Citra_5b	5	5	1
11	Citra_6a	6	1	0
12	Citra_6b	6	1	0
13	Citra_7a	7	7	1
14	Citra_7b	7	7	1
15	Citra_8a	8	8	1
16	Citra_8b	8	8	1
17	Citra_9a	9	7	0
18	Citra_9b	9	7	0
19	Citra_10a	10	7	0
20	Citra_10b	10	9	0
Rata-rata				0,40

4.3. Pengujian terhadap citra uji dengan metode SURF

i. Pengujian menggunakan kernel polinomial

Pada pengujian pertama dilakukan pengujian terhadap dua puluh citra uji dengan parameter seperti pada Tabel 5.

Tabel 5. Parameter uji menggunakan kernel pertama

No	Kernel	Degree	Gamma
1	Polynomial	10	10-4

Hasil pengujian model dari metode SURF menggunakan kernel polinomial dapat dilihat pada Tabel 6. Metode SURF berhasil mengenali citra uji dengan tingkat akurasi 0,75 atau 75%. Ada lima citra yang tidak dapat diprediksi dengan benar yaitu Citra_2a yang diprediksi sebagai citra 3, Citra_4a yang diprediksi sebagai citra 9, Citra_6b yang diprediksi sebagai citra 1, Citra_10a yang diprediksi sebagai citra 7, dan Citra_10b yang diprediksi sebagai citra 3, sedangkan citra uji lain diprediksi dengan benar.

Tabel 6. Hasil uji menggunakan menggunakan metode SURF

No	Citra	Label	Prediksi	Akurasi
1	Citra_1a	1	1	1
2	Citra_1b	1	1	1
3	Citra_2a	2	3	0
4	Citra_2b	2	2	1
5	Citra_3a	3	3	1
6	Citra_3b	3	3	1
7	Citra_4a	4	9	0
8	Citra_4b	4	4	1
9	Citra_5a	5	5	1
10	Citra_5b	5	5	1
11	Citra_6a	6	6	1
12	Citra_6b	6	1	0
13	Citra_7a	7	7	1
14	Citra_7b	7	7	1
15	Citra_8a	8	8	1
16	Citra_8b	8	8	1
17	Citra_9a	9	9	1
18	Citra_9b	9	9	1
19	Citra_10a	10	7	0
20	Citra_10b	10	3	0
Rata-rata				0,75

ii. Pengujian menggunakan kernel RBF

Pada pengujian kedua dilakukan pengujian terhadap dua puluh citra uji. Penelitian ini menggunakan parameter pada Tabel 7.

Tabel 7. Parameter uji pada pengujian kedua

No	Kernel	Gamma
1	RBF	10-5

Hasil pengujian model dari metode SURF dengan menggunakan kernel RBF dapat dilihat pada Tabel 8. Metode gabungan berhasil mengenali citra uji dengan tingkat akurasi 0,80 atau 80%. Hanya ada empat citra yang tidak dapat diprediksi dengan benar yaitu Citra_6b, Citra_9b, Citra_10a dan Citra_10b. Citra_6b diprediksi sebagai citra 1, Citra_9b diprediksi sebagai citra 5, Citra_10a diprediksi sebagai citra 9 dan Citra_10b diprediksi sebagai citra 9, sedangkan citra uji lain diprediksi dengan benar.

Tabel 8. Hasil uji menggunakan metode SURF

No	Citra	Label	Prediksi	Akurasi
1	Citra_1a	1	1	1
2	Citra_1b	1	1	1
3	Citra_2a	2	2	1
4	Citra_2b	2	2	1
5	Citra_3a	3	3	1
6	Citra_3b	3	3	1
7	Citra_4a	4	4	1
8	Citra_4b	4	4	1
9	Citra_5a	5	5	1
10	Citra_5b	5	5	1
11	Citra_6a	6	6	1
12	Citra_6b	6	1	0
13	Citra_7a	7	7	1
14	Citra_7b	7	7	1
15	Citra_8a	8	8	1
16	Citra_8b	8	8	1
17	Citra_9a	9	9	1
18	Citra_9b	9	5	0
19	Citra_10a	10	9	0
20	Citra_10b	10	9	0
Rata-rata				0,80

Gambar 6 menunjukkan perbandingan kinerja metode SURF dengan GLCM. Gambar 6a menggambarkan bar dari pengujian dengan parameter adalah kernel polinomial, degree sebesar 10 dan gamma sebesar 0,01. Metode SURF mempunyai kinerja yang lebih baik dari metode GLCM, dimana metode SURF mempunyai akurasi sebesar 0,75 atau 75% sedangkan metode GLCM mempunyai akurasi sebesar 0,35 atau 35%. Berdasarkan gambar 6a metode SURF mempunyai performansi lebih baik dibandingkan metode GLCM untuk citra uji.

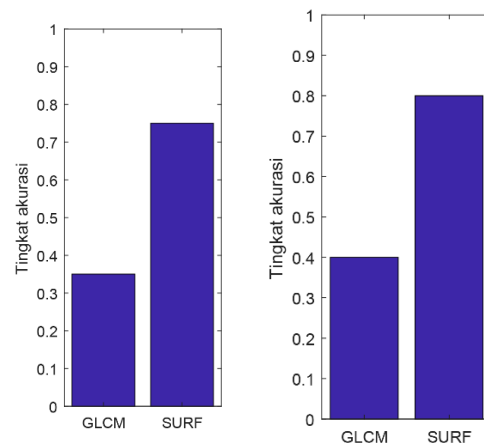
Gambar 6b menggambarkan bar dari pengujian dengan parameter adalah kernel RBF, dengan gamma sebesar 0,00001. Metode SURF mempunyai kinerja yang sangat baik dengan akurasi mencapai 0,80 atau 80% sedangkan metode GLCM mempunyai akurasi sebesar 0,775 atau 77,5%. Secara rata-rata, metode SURF mempunyai akurasi 0,65 atau 65% dan metode GLCM mempunyai akurasi sebesar 0,375 atau 37,5%.

Metode SURF menunjukkan keunggulan kinerja pada kedua kernel yang digunakan baik kernel polinomial atau kernel RBF. Fitur yang dibangkitkan oleh metode SURF lebih banyak dan detail dibandingkan dengan fitur GLCM. Fitur SURF mengandung informasi fitur, letak atau titik koordinat dimana fitur tersebut. Sedangkan fitur GLCM hanya mengandung informasi dasar dari suatu citra seperti kontras, keseragaman dan korelasi piksel. Dengan jumlah fitur yang lebih

banyak maka detail informasi yang dihasilkan juga lebih baik. Sehingga SVM baik dengan kernel polinomial atau RBF dapat menentukan hyperplane yang baik untuk fitur SURF dibandingkan GLCM.

5. Kesimpulan

Penelitian ini memaparkan perbandingan metode ekstraksi fitur SURF dan GLCM untuk sistem pengenalan wajah dengan menggunakan teknik klasifikasi SVM. Dari hasil penelitian dapat disimpulkan bahwa metode SURF mempunyai kinerja yang lebih baik dari metode GLCM untuk sistem pengenalan wajah pada dataset NCKU. Dengan menggunakan kernel Polinomial dan RBF, metode SURF mempunyai akurasi yang hampir mencapai dua kali lebih baik dari metode GLCM. Penelitian ke depan akan dilakukan dengan menggabungkan kedua metode tersebut untuk sistem pengenalan wajah.



(a) Kernel polinomial (b) kernel RBF
 Gambar 6. Perbandingan penggunaan teknik kernel pada metode SURF dan GLCM

Daftar Pustaka

- [1] F. P. Hilman, "Perbandingan Metode SURF dan SIFT dalam Identifikasi Tanda Tangan," *e-Proceeding Eng.*, vol. 2, no. 2, pp. 2467–2481, 2015.
- [2] H. Bay, A. Ess, T. Tuytelaars, and L. Van Gool, "Speeded-up robust features (SURF)," *Comput. Vis. image Underst.*, vol. 110, no. 3, pp. 346–359, 2008.
- [3] M. M. El-Gayar, H. Soliman, and N. Meky, "A Comparative Study of Image Low Level Feature Extraction Algorithms," *Egypt.*

- Informatics J.*, vol. 14, pp. 175–181, 2013.
- [4] D. Thachasongtham, T. Yoshida, F. De Sorbier, and H. Saito, “3D object pose estimation using viewpoint generative learning,” in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 2013, pp. 512–521.
- [5] N. P. Ramaiah, E. P. Ijjina, and C. K. Mohan, “Illumination invariant face recognition using convolutional neural networks,” in *Signal Processing, Informatics, Communication and Energy Systems (SPICES), 2015 IEEE International Conference on*, 2015, pp. 1–4.
- [6] D. Chen, X. Cao, F. Wen, and J. Sun, “Blessing of dimensionality: High-dimensional feature and its efficient compression for face verification,” in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2013, pp. 3025–3032.
- [7] G. A. S. Saroja and C. H. Sulochana, “Texture analysis of non-uniform images using GLCM,” in *2013 IEEE Conference on Information and Communication Technologies, ICT 2013*, 2013.
- [8] D. Gao, “Volume texture extraction for 3D seismic visualization and interpretation,” *Geophysics*, vol. 68, no. 4, pp. 1294–1302, 2003.
- [9] F. Tsai, C.-K. Chang, J.-Y. Rau, T.-H. Lin, and G.-R. Liu, “3D Computation of Gray Level Co-occurrence in Hyperspectral Image Cubes,” *Energy Minimization Methods Comput. Vis. Pattern Recognit.*, pp. 429–440, 2007.
- [10] K. Saddami, K. Munadi, and F. Arnia, “Online Feature Extraction Technique for Optical Character Recognition System,” in *Proceedings of International Conference on Engineering and Science of Research and Development*, 2016, pp. 263–267.
- [11] F. Arnia and K. Munadi, *Pengantar Teknik Pengolahan Citra dan Visi Komputer*. Yogyakarta: Ombak, 2018.
- [12] R. Fan, P. Chen, and C. Lin, “Working Set Selection Using Second Order Information for Training Support Vector Machines,” *J. Mach. Learn. Res.*, vol. 6, pp. 1889–1918, 2005.
- [13] F. Arnia, K. Saddami, and K. Munadi, “Moment invariant-based features for Jawi character recognition,” *Int. J. Electr. Comput. Eng.*, vol. 9, no. 3, p. 1711, 2019.
- [14] K. Thirumala, M. S. Prasad, T. Jain, and A. C. Umarikar, “Tunable-Q wavelet transform and dual multiclass SVM for online automatic detection of power quality disturbances,” *IEEE Trans. Smart Grid*, vol. 9, no. 4, pp. 3018–3028, 2016.
- [15] C. Bo, H. Lu, and D. Wang, “Hyperspectral image classification via JCR and SVM models with decision fusion,” *IEEE Geosci. Remote Sens. Lett.*, vol. 13, no. 2, pp. 177–181, 2015.
- [16] C.-C. Chang and C.-J. Lin, “LIBSVM: a library for support vector machines,” *ACM Trans. Intell. Syst. Technol.*, vol. 2, no. 3, p. 27, 2011.

Biodata Penulis

Syamsul Bahri, memperoleh gelar Sarjana Teknik dari Universitas Jabal Ghafur pada tahun 2005 dan menyelesaikan pendidikan magister pada Magister Teknik Elektro, Universitas Syiah Kuala. Bidang penelitian meliputi pengelolaan citra digital.

Khairun Saddami, memperoleh gelar Sarjana Teknik dari Universitas Syiah Kuala (UNSYIAH), Banda Aceh pada tahun 2015. Sekarang sedang menyelesaikan pendidikan doktoral di Universitas Syiah Kuala. Beliau merupakan anggota IEEE dan IAPR. Bidang penelitiannya meliputi pengolahan citra dan pengenalan pola.

Fitri Arnia, memperoleh gelar Sarjana Teknik dari Universitas Sumatera Utara (USU), Medan pada tahun 1997. Pendidikan tingkat master dan doktoral diselesaikannya pada University of New South Wales (UNSW), Sydney, Australia dan Tokyo Metropolitan University, Jepang berturut-turut pada tahun 2004 dan 2008. Beliau bekerja sebagai staf pengajar pada Jurusan Teknik Elektro dan Komputer, Fakultas Teknik, Universitas Syiah Kuala sejak tahun 1999. Beliau juga anggota IEEE, IAPR dan IAENG. Bidang penelitiannya meliputi pengolahan sinyal, citra dan multimedia digital.

Kahlil Muchtar, memperoleh gelar Sarjana Teknik dari Sekolah Tinggi Teknik (STT) PLN, Jakarta pada tahun 2007. Pendidikan tingkat master dan doctoral diselesaikannya pada Asia University, Taiwan dan National Sun Yat-sen University (NSYSU), Taiwan berturut-turut pada tahun 2012 dan 2017. Beliau bekerja sebagai staf pengajar pada Jurusan Teknik Elektro dan Komputer, Fakultas Teknik, Universitas Syiah Kuala sejak tahun 2017. Beliau juga anggota IEEE dan IAENG. Bidang penelitiannya meliputi visi komputer dan multimedia.