

SISTEM DETEKSI KUALITAS SEMANGKA BERDASARKAN PENDARAN WARNA DAN MENGGUNAKAN SUPPORT VECTOR MACHINE (SVM)

*Watermelon Quality Assesment Based On Color Informastion
And Using Support Vector Machine*

Fadilah¹, IGede Pasek Suta Wijaya², Fitri Bimantoro³

¹Program Studi Teknik Informatika, Fakultas Teknik, Unram, Nusa Tenggara Barat, Indonesia
Email : kokopazzo91@gmail.com¹, gpsutawijaya@te.ftunram.ac.id², irfan@te.ftunram.ac.id³

ABSTRAK

Pengenalan kualitas buah menggunakan pengolahan dan deteksi citra merupakan tahap baru dalam perkembangan sistem pendeteksian kualitas produk buah. Ciri-ciri yang lebih rinci dan kompleks dari suatu objek dapat dicari dengan bantuan teknik pengolahan citra. Dalam penelitian ini 140 sample citra buah semangka masuk ke dalam proses bloking serta normalisasi intensitas sebelum masuk ke sistem klasifikasi. Metode linier support vector machine (SVM) dipergunakan untuk mengklasifikasi semangka dengan fitur berupa nilai statistic HSI citra. Metode tersebut sebelumnya telah baik dalam pengenalan kualitas kedelai. Berbeda dengan hasil penelitian pada kedelai, hasil akurasi rata-rata sebesar 60% menunjukkan bahwa sebaran data citra buah semangka begitu kompleks dan diperlukan metode yang lebih baik dalam menangani masalah ini. Kesamaan citra semangka antar kelas menyebabkan sebaran data yang seharusnya untuk tiga kelas hanya terkumpul pada dua kelas. Diperlukan penelitian khusus pada citra semangka untuk mendapatkan fitur yang lebih baik.

Kata Kunci: SVM; Klasifikasi citra; Normalisasi intensitas; Bloking, Kualitas buah

ABSTRACT

Classification of fruit quality using image processing and detection is a new step in development of fruit product quality inspection. Features that represent detail and complex information of an object can be extracted by image processing. In this research, 140 samples of watermelon images are separated in blocks and its intensity is normalized before processed by classification system. Support Vector Machine (SVM) is used as a method for classifying watermelon with statistic values as features. The method was tested in classification of soybeans with good result. Different from previous research with soybeans, accuracy obtained in this research is 60% in average. This result shows that the distribution of data is overly complex to be classified by current method and a better method is required for this problem. The similarity between samples from different classes makes the distribution of data fall into just two classes instead of three. Specific study in watermelon image are required to get better features for classification.

Keywords: SVM ;Image Classification; Intensity Normalization; Image Blocking; Quality Fruit

PENDAHULUAN

Semangka merupakan buah yang sangat digemari di Indonesia. Semangka mengandung zat-zat yang efektif dalam membunuh sel-sel kanker dan bernilai ekonomis tinggi. Walaupun di Indonesia sebagian besar semangka berharga murah, namun tingkat pertumbuhannya tinggi. Sehingga semangka dapat menjadi komoditas ekspor yang menjanjikan. Agar dapat masuk menjadi komoditas ekspor, semangka harus memenuhi syarat kuantitas dan kualitas. Ditinjau dari segi kuantitas, Indonesia pada tahun 2009 menghasilkan lebih dari 474 ton. Hal ini menunjukkan syarat kuantitas sudah

terpenuhi. Akan tetapi yang menjadi masalah adalah dalam segi kualitas, pengecekan dilakukan masih secara manual yang tentunya sulit untuk diterapkan pada sistem besar.

Oleh karena itu, perlu adanya sistem lain yang dapat digunakan untuk mengecek kualitas semangka. Salah satu cara yang mungkin yaitu dengan menganalisa warna dari semangka. Analisa warna semangka dapat dilakukan dengan sistem mata virtual dengan menerapkan kecerdasan buatan. Untuk membangun sistem ini dibutuhkan metode yang handal. Salah satu metode tersebut yaitu *Support Vector Machine* (SVM).

Penelitian terdahulu yang terkait dengan penelitian ini antara lain Deteksi Kualitas Biji Kedelai Sebagai Bahan Baku Tempe Melalui Pengolahan Citra Digital menggunakan SVM untuk pengklasifikasiannya dan menggunakan ekstraksi ciri LBP (*Local Binary Pattern*) untuk memperoleh informasi pada setiap citra input (Annisadkk, 2014). Dari hasil pengujiannya, *varian kernel* SVM terbaik adalah kernel polynomial, menghasilkan akurasi 93% dan hasil akurasi terbaik pada *multiclass* SVM adalah sebesar 74,88%.

Penelitian mengenai pengenalan wajah dengan metode klasifikasi SVM menggunakan ekstraksi ciri analisis diskriminan majemuk atau transformasi *fukunagakoontz*. Basis data wajah yang digunakan adalah basis data Yale dan ORL (Andriati, 2011). Dari hasil penelitiannya didapat bahwa keberhasilan metode klasifikasi SVM untuk basis data Yale mencapai 100% dan untuk basis data ORL mencapai 95%. Hasil ini menunjukkan bahwa aplikasi pengenalan wajah dengan menggunakan metode klasifikasi SVM merupakan sebuah aplikasi yang cukup handal.

Penelitian tentang Pengklasifikasian Warna Kulit Berdasarkan RAS Menggunakan Algoritma SVM. Hasil dari penelitian dengan menggunakan metode ini memberikan akurasi sebesar 92,5% (Ilyarismadkk, 2016).

Penelitian yang berkaitan dengan Pengklasifikasian Warna Kulit Berbasis Piksel Menggunakan Jaringan Syaraf Tiruan ini menentukan klasifikasi warna kulit dan bukan warna kulit yang menggunakan 2 layer tersembunyi dengan 4 dan 3 neuron. Penelitian ini menggunakan 3 jenis *training function* yang berbeda yaitu *trainbfg*, *traingdm* dan *trainlm*, dan dari ke-3 jenis *training function* tersebut, hasil citra *output* terbaik didapatkan dengan menggunakan *training function* jenis *trainlm* (Susanti, 2014).

Dari uraian diatas bahwa deteksi kualitas semangka berdasarkan fitur pendaran warna dan SVM sangat mungkin dilakukan.

SISTEM DETEKSI. Sistem deteksi kualitas buah semangka secara sederhana dapat digambarkan seperti pada Gambar 1. Pada

sistem ini terdapat dua proses utama, yaitu pelatihan dan pengklasifikasian.

Proses pelatihan terdiri atas:

1. Menyiapkan citra buah semangka untuk proses pelatihan
2. Konversi nilai warna RGB ke warna HSI
3. Melakukan ekstraksi fitur dengan parameter mean, median, modus dan varian untuk mendapatkan hasil bobot *training sample* pada proses pelatihan,
4. Pelatihan SVM untuk mendapatkan bobot *training sample* yang dapat digunakan untuk mengklasifikasikan citra semangka berdasarkan pendaran warna.
5. Simpan bobot *training sample* yang didapatkan dari proses pelatihan SVM.

Sedangkan proses pengklasifikasian meliputi:

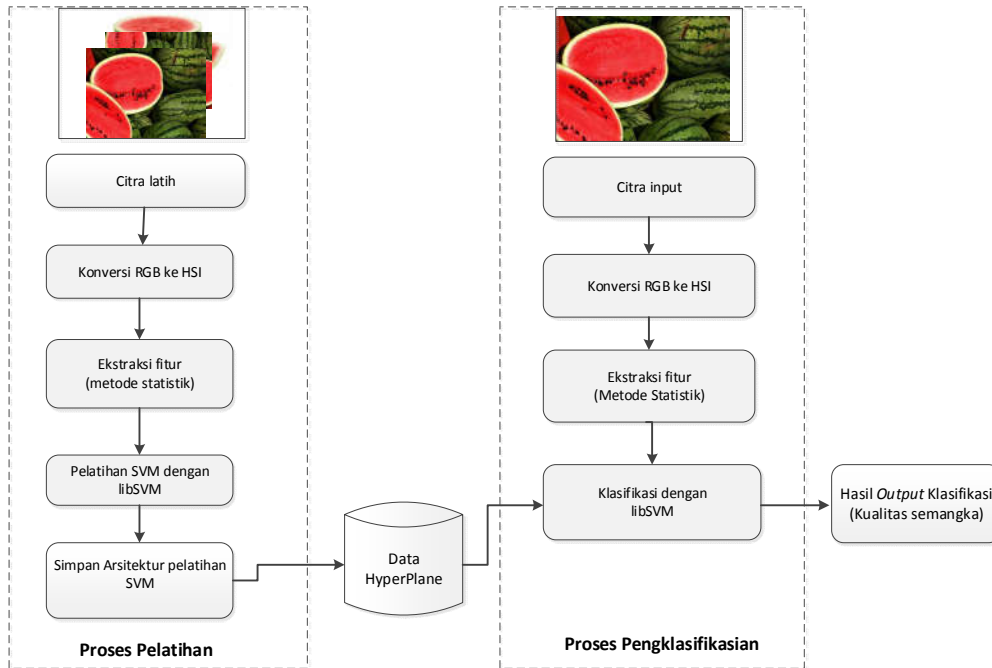
1. Memasukkan data citra yang akan diklasifikasi.
2. Konversi nilai warna RGB ke warna HIS dan lakukan ekstraksi fitur seperti pada proses training.
3. Load arsitektur SVM hasil pelatihan (Garis pemisah masing-masing class)
4. Melakukan klasifikasi untuk menentukan kualitas buah semangka berdasarkan fitur warna dengan lib SVM
5. Representasi hasil keluaran klasifikasi berupa kualitas semangka dari citra masukkan.

Ruang Warna HSI. Pengolahan citra merupakan pemrosesan citra, khususnya dengan menggunakan komputer, menjadi citra yang kualitasnya lebih baik. Pengolahan Citra bertujuan memperbaiki kualitas citra agar mudah diinterpretasi oleh manusia atau computer (Putra, 2010).

Model ruang warna HSI merepresentasikan warna dalam terminologi *hue*, *intensity*, dan *saturation*. Konversi citra RGB ke dalam ruang warna HSI dapat dilakukan dengan menggunakan Persamaan 1, 2, dan 3 dengan asumsi bahwa nilai R, G, dan B telah ternormalisasi kedalam rentang 0~1 (Munir, 2004).

$$I = \frac{R+G+B}{3} \dots\dots\dots(1)$$

$$H = \cos^{-1} \frac{2R-G-B}{2\sqrt{(R-G)^2+(R-B)(G-B)}} \dots\dots\dots(2)$$



Gambar 1 Block diagram sistem deteksi kualitas semangka

$$S = 1 \frac{3}{R+G+B} \min (R, G, B) \dots\dots\dots(3)$$

Transformasi citra dari ruang warna RGB ke ruang warna HSI dilakukan sebelum ekstraksi pendaran warna dari citra

Ekstraksi Fitur, pengenalan pola merupakan teknik yang bertujuan untuk mengklasifikasikan citra yang telah diolah sebelumnya berdasarkan kesamaan atau kemiripan ciri yang dimilikinya. Bagian terpenting dari teknik pengenalan pola adalah bagaimana memperoleh informasi atau ciri penting yang terdapat dalam sinyal (Theodoridis dkk, 2003)

Teknik ekstraksi fitur yang dikembangkan pada model ini adalah fitur warna yang diekstraksi menggunakan metode statistik. Metode statistik merupakan kumpulan dari teknik mengumpulkan, analisis, dan interpretasi data dalam bentuk angka dan bilangan yang menunjukkan sifat-sifat (karakteristik) data yang dikumpulkan tersebut (Sugiyono, 2004). Teknik statistik yang digunakan untuk mengekstraksi pendaran warna adalah mean,

- **Mean.** Mean atau rata-rata hitungan adalah bilangan yang didapat dari hasil pembagian jumlah nilai data oleh banyak data dalam kumpulan tersebut, seperti yang dirumuskan pada Persamaan (4).

$$\bar{x} = \frac{\sum_{i=1}^n x_i}{n} \dots\dots\dots(4)$$

Atau dapat juga ditulis mejadi Persamaan (5).

$$\bar{x} = \frac{\sum_{i=1}^n f_i x_i}{\sum_{i=1}^n f_i} \dots\dots\dots(5)$$

Dimana f_i merupakan frekuensi data ke x_i dan n adalah jumlah sampel.

- **Median.** Median adalah sebuah bilangan yang bersifat setengah dari data. Adapun perhitungan median dapat dilakukan dengan Persamaan (6) atau (7).

$$x_t = \frac{x_{n+1}}{2} \dots\dots\dots(6)$$

$$x_t = \frac{x_{\frac{n}{2}} + x_{\frac{n}{2}+1}}{2} \dots\dots\dots(7)$$

- **Modus.** Merupakan data yang dengan frekuensi terbanyak. Untuk data kontinyu modus dihitung dengan menggunakan Persamaan (8).

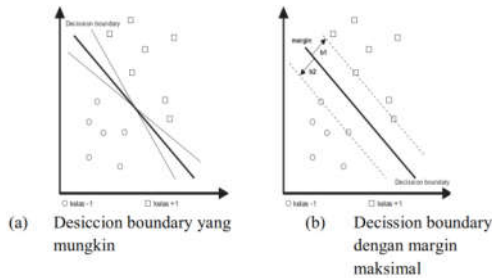
$$x_m = LCB_{mod} + \left(\frac{f_{mod} - f_{mod-1}}{2} \right) \dots\dots\dots(8)$$

- **Varian.** Jika mempunyai sample berukuran dengan data x_1, x_2, \dots, x_n dan rata-rata μ , maka varian atas sampel data diatas dapat dihitung menggunakan persamaan (9) atau (10).

$$S^2 = \frac{\sum (x_i - \mu)^2}{n-1} \dots\dots\dots(9)$$

$$S^2 = \frac{n \sum x_i^2 - (\sum x_i)^2}{n(n-1)} \dots\dots\dots(10)$$

Algoritma SVM, Ide dasar SVM adalah memaksimalkan batashyperplane (*maximal margin hyperplane*), seperti yang diilustrasikan pada Gambar 2. Pada Gambar 2(a) ada sejumlah pilihan Hyperplane yang memungkinkan untuk set data. Pada Gambar 2(b) merupakan hyperplane dengan margin yang paling maksimal. Meskipun Gambar 2(a) sebenarnya juga bisa menggunakan hyperplane sembarang Hyperplane dengan margin yang maksimal akan memberikan generalisasi yang lebih baik pada metode klasifikasi (Santoso, 2005).



Gambar 2. Decision boundary yang mungkin untuk set data

Gambar2 memperlihatkan beberapa pola yang merupakan anggota dari dua buah kelas data: +1 dan -1. Data yang tergabung pada kelas-1 disimbolkan dengan bentuk lingkaran, sedangkan data pada kelas +1 disimbolkan dengan bentuk bujur sangkar.

Margin adalah jarak antara hyperplane tersebut dengan dataterdekat darimasing-masing kelas. Data yang paling dekat ini disebut *supportvector*. Garissolid pada Gambar 2 (b) menunjukkan hyperplane yang terbaik, yaitu yang terletak tepat pada tengah-tengah kedua kelas, *margin* (garis putus-putus) adalah *support vector*. Usaha untuk mencari lokasi hyperplane ini merupakan inti dari proses pelatihan pada SVM.

Setiap data latih dinyatakan oleh (x, y) , dimana $i=1,2,\dots, N$, dan $x=\{x_1, x_2, \dots, x_q\}$ merupakan atribut (fitur) set untuk data latih ke- i . $y \in \{-1, +1\}$ menyatakan label kelas. Hyperplane klasifikasi linier SVM, dinotasikan dengan persamaan (11)

$$w \cdot x_i + b = 0 \dots\dots\dots(11)$$

w dan b adalah parameter model. $w \cdot x_i$ merupakan *inner product* antara w dan x_i . Data x_i yang masuk ke dalam kelas -1 adalah data yang memenuhi pertidaksamaan (12).

$$w \cdot x_i + b \leq -1 \dots\dots\dots(12)$$

Sedangkan data x_i yang masuk ke dalam kelas +1 adalah data yang memenuhi pertidaksamaan (13).

$$w \cdot x_i + b \geq +1 \dots\dots\dots(13)$$

Teknik Pengujian, pada penelitian ini, system harus diuji dengan parameter-parameter statistic yang meliputi tingkat akurasi, *False Positive Rate (FPR)* dan *False Negative Rate (FNR)*. Berikut merupakan persamaan untuk menghitung masing-masing parameter tersebut diatas (Sujatmikodkk, 2016, Wikipedia, 2015).

$$Akurasi = \frac{Tp+Tn}{Np+Nn} \times 100\% \dots\dots\dots(14)$$

$$FNR = \frac{Fn}{Np} \times 100\% \dots\dots\dots(15)$$

$$FPR = \frac{Fp}{Nn} \times 100\% \dots\dots\dots(16)$$

Dimana,

- Tp (*True Positive*) adalah banyaknya hasil klasifikasi benar untuk suatu kelas yang bernilai positive.
- Tn (*True Negative*) adalah banyaknya hasilklasifikasi benar untuk suatu kelas yang bernilai negative.
- Fp (*False Positive*) adalah banyaknya hasilklasifikasi benar untuk suatu kelas dan bernilai negative.
- Fn (*False Negative*) adalah banyaknya hasil klasifikasi salah untuk suatu kelas dan bernilai positive.
- Np adalah Jumlah sampel data bernilai positive. dan Nn = Jumlah data bernilai negative.


HASIL DAN PEMBAHASAN

Citra uji yangd igunakan sesuai dengan penelitian berukuran 128x128 piksel. Data kemudian dibagi menjadi 4 bagians ehingga citra masukkan menjadi berukuran 64x64. Setelah data citra iinputkan, nilaiH Slakan diambil dari gambar. Kemudian dilakukan normalisasi pada intensitas (I).

Selanjutnya akan dilakukan ekstraksi fitur dari gambar berupa mean, median, modus dan varian. Setelah didapatkan nilai fitur SVM akan membaca kembali arsitektur SVM (*xml*) yang telah disimpan.


Beberapa variasi pengujian akan dilakukan untuk mengetahui performa dari teknik klasifikasi. Variasi pengujian tersebut antara lain pengaruh jumlah fitur,

Pengaruh jumlah fitur terhadap performa, Tujuan pengujian ini yaitu untuk mengetahui pengaruh penggunaan fitur yang ada dengan performa sistem klasifikasi. Hasil pengujian disajikan pada Gambar 2.

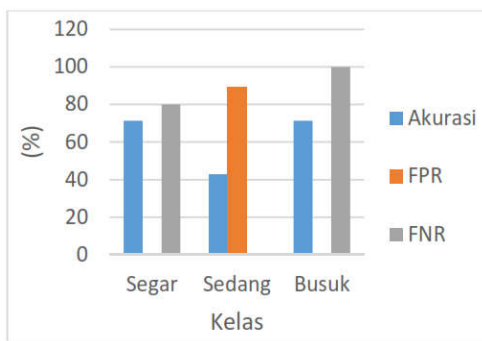


Gambar 3. Grafik performa menggunakan berbagai jumlah fitur

Gambar 3 tampak bahwa akurasi rata-rata cenderung meningkat seiring dengan bertambahnya jumlah fitur yang digunakan walaupun kecil. Tingkat akurasi maksimum untuk kelas segar terdapat pada jumlah fitur 9-12 dengan hasil klasifikasi yang sama sedangkan untuk kelas sedang terdapat pada penggunaan 6 fitur.




Gambar 4. Grafik performa sistem menggunakan 6 fitur




Gambar 5 Grafik performa sistem menggunakan 9 fitur

Gambar 4 dan 5 dapat dilihat bahwa sistem masih memiliki tingkat FNR 100% pada kelas busuk. Hal ini menunjukkan bahwa sistem tidak memungkinkan untuk menghasilkan klasifikasi busuk.

Pengaruh bloking dan normalisasi terhadap performa, hasil klasifikasi dari sistem menggunakan bloking yang ditunjukkan pada Gambar 6 dan 7.



Gambar 6. Grafik pengaruh bloking terhadap performa menggunakan 6 fitur



Gambar 7. Grafik pengaruh bloking terhadap performa menggunakan 9 fitur


Gambar 6 dan 7 di atas dapat dilihat bahwa nilai akurasi dari sistem tanpa menggunakan proses bloking berada disekitaran 60 persen. Pada hasil klasifikasi terlihat bahwa hasil hanya mencakup untuk kelas segar dan sedang.

Pada sistem dengan menggunakan bloking, tingkat akurasi menurun untuk kedua jumlah fitur namun terjadi peningkatan pada hasil TP pada klasifikasi segar. Hal ini menunjukkan bahwa dengan menggunakan bloking dapat meningkatkan jumlah hasil pengklasifikasian sega pada kedua jumlah fitur namun mengakibatkan terjadi peningkatan klasifikasi segar yang terlalu besar pada 9 fitur.


Sedangkan untuk hasil klasifikasi dari sistem menggunakan normalisasi yang ditunjukkan pada Gambar 8

dan

9.




Gambar 8. Pengaruh normalisasi terhadap performa untuk 6 fitur




Gambar 9. Pengaruh normalisasi terhadap performa untuk 96 fitur

Dari Gambar 8 dan 9 ternyata normalisasi meningkatkan hasil klasifikasi segar dibandingkan dengan tanpa normalisasi pada penggunaan 6 fitur. Pada penggunaan 9 fitur, hasil klasifikasi tidak berubah dari sebelum dilakukan proses normalisasi. Perbandingan hasil segar dan sedang untuk 6 dan 9 fitur secara berurutan yaitu 21:49 dan 5:65. Untuk tingkat akurasi pada penggunaan 6 fitur terlihat terjadi pengurangan sedikit dan memiliki tingkat akurasi rata-rata yang sama dengan penggunaan 9 fitur.

Ketika kedua proses blocking dan normalisasi bekerja secara simultan maka performa sistem klasifikasi disajikan pada Gambar 10 dan 11.




Gambar 10. Pengaruh blocking dan normalisasi terhadap performa untuk 6 fitur



Gambar 11. Pengaruh blocking dan normalisasi terhadap performa untuk 9 fitur

Dari Gambar 10 dan 11 dapat dilihat bahwa untuk pertama kalinya terdeteksi kelas busuk pada penggunaan 9 fitur. Perbandingan hasil klasifikasi dari ketiga kelas untuk penggunaan 9 dan 6 fitur secara berurutan dari segar:sedang:busuk yaitu 12:56:2 dan 7:63:0. Tingkat akurasi untuk penggunaan 9 fitur maupun 6 fitur berkurang. Dikarenakan ditemukan hasil klasifikasi busuk pada penggunaan 9 fitur dengan blocking dan normalisasi maka dilakukan eliminasi fitur lanjutan dengan sistem tersebut.

Setelah dilakukan penghilangan fitur didapatkan kesimpulan penggunaan 7 fitur minimum dengan menghilangkan means dan median. Sehingga diperoleh tingkat akurasi, FPR dan FNR yang sama seperti penggunaan 9 fitur. Sistem dengan menggunakan 7 fitur inilah yang disimpulkan sebagai sistem terbaik dengan tingkat akurasi, FPR, dan FNR secara berurutan yaitu 60%, 31% dan 62%. Hasil ini cukup baik jika dilihat dari persebaran data fitur rata-rata pada *sample* yang digunakan. Sebaran data tersebut dapat dilihat pada grafik berikut.



Gambar 11. Sebaran fitur statistik

Dari Gambar 11 diatas dapat dilihat sebaran data yang dihasilkan. Data diambil dari nilai rata-rata semua fitur pada 10 data latih. Dari sebaran data tersebut dapat disimpulkan bahwa antara kelas segar dan sedang hanya memiliki sebaran data yang baik pada 6 sample yaitu pada 2, 3, 4, 6, 8,

dan 10. Hal inilah yang menyebabkan tingkat akurasi dari kedua kelas tersebut berada disekitaran 60 persen. Sedangkan untuk kelas busuk, hampir semua sample busuk menyatu dengan sample sedang. Hanya satu sample saja yang memiliki sebaran yang cukup baik yaitu pada sample terakhir. Hal inilah yang menyebabkan sample busuk sebagian besar dideteksi sebagai sample sedang. Oleh karena hal tersebut dapat disimpulkan bahwa untuk kasus klasifikasi tingkat kesegaran semangka kurang cocok menggunakan fitur yang diambil dari pendaran warna.

KESIMPULAN

Berdasarkan hasil pengujian dan pembahasan, dapat disimpulkan bahwa:

1. Penambahan proses bloking dan normalisasi sangat mempengaruhi sistem yang mengakibatkan sistem dapat mendeteksi kelas busuk.
2. Bloking mempengaruhi sebaran hasil klasifikasi kelas sedang menjadi berkurang sehingga didapatkan sistem yang lebih layak.
3. Dari 12 fitur diperoleh fitur terbaik yaitu sejumlah 7 fitur dengan menghilangkan kanvarianH, varianS, varianI, mean S dan median H.
4. Akurasi, FPR dan FNR rata-rata dari sistem optimal secara berurutan yaitu 60%, 31% dan 62%.
5. Penggunaan fitur (mean, median, modus, varian) pada pendaran warna kurang cocok untuk kasus deteksi kualitas semangka.

SARAN

Jika dilakukan penelitian lebih lanjut pada kasus ini dapat mempertimbangkan saran-saran dan perubahan sebagai berikut:

1. Fitur dapat ditambahkan atau diganti dengan fitur-fitur lain yang lebih kompleks.
2. Diperlukan pembagian kelas yang lebih jelas misalnya dengan membagi kelas berdasarkan waktu ataupun dilakukan penelitian lebih lanjut untuk pembagian kelas kesegaran semangka.
3. Diperlukan jumlah sample yang lebih banyak dan jenis semangka yang lebih bervariasi agar didapatkan data sample yang lebih layak.
4. Modifikasi parameter dapat dilakukan dengan menambah jenis lampu atau penanganan lainnya.
5. Modifikasi proses dapat dilakukan dengan menambahkan proses pengolahan citra

lainnya seperti filtering ataupun penajaman gambar.

DAFTAR PUSTAKA

- Andriati, S., 2011, *Aplikasi Pengenalan Wajah Menggunakan Metode Support Vector Machine*, Jurusan Teknik Elektro Politeknik Negeri Bali.
- Annisa, D. R., Hidayat, B.A., Novianty., 2014, *Deteksi Kualitas Biji Kedelai Sebagai Bahan Baku Tempe Melalui Pengolahan Citra Digital Dengan Ekstraksi Ciri LBP dan Metode Klasifikasi SVM*, Universitas Telkom.
- Ilyarisma, R., Wijaya, IGPS., Akbar, LSAI., 2016, *Pengklasifikasian Warna Kulit Berdasarkan Ras Menggunakan Algoritma Support Vector Machine (SVM)*, *Dielektrika*, Vol. 3, No. 1, pp. 53 - 59..
- Munir, R., 2004, *Pengolahan Citra Digital*, Bandung, Informatika.
- Nugroho, A. S., Witarto, A. B., Handoko, D., 2003, *Support Vector Machine Teori dan aplikasinya dalam Bioinformatika*, Kuliah umum Ilmu Komputer.com.
- Putra, D., 2010, *Pengolahan Citra Digital*, Andi, Yogyakarta.
- Santoso, B., 2005, *Tutorial Support Vector Machine*, Fakultas Teknik Industri, Institut Teknik Surabaya, Surabaya.
- Sugiyono, 2004, *Statistika Untuk Penelitian*, Bandung, Alfabeta.
- Sujatmiko, N., Wijaya, IGPS., Akbar, LSAI., 2017, *Pengenalan Citra Pornografi Berdasarkan Deteksi Genital Menggunakan Template Matching*, *Dielektrika*, Vol. 4, No. 1, pp. 17-23.
- Susanti, S., 2014, *Pengklasifikasian Kulit Berbasis Piksel Menggunakan Jaringan Syaraf Tiruan*, Jurusan Teknik Elektro, Universitas Mataram.
- Theodoridis, S., Koutroumbas, K., 2003, *Pattern Recognition*, 2nd Edition, Academic Press, New York, USA.
- Wikipedia, 2015, *Confusion Matrix*, tersedia https://en.wikipedia.org/wiki/Confusion_matrix diakses 2015