

KLASIFIKASI TINGKAT KESEGERAN CUMI – CUMI BERDASARKAN FITUR TEKSTUR DAN WARNA DENGAN MENGGUNAKAN METODE SUPPORT VECTOR MACHINE

(Classification of Squids Freshness Based on Texture and Color Using Support Vector Machine)

Fathin Zulian Tsany, Fitri Bimantoro*, Gibran Satya Nugraha

Program Studi Teknik Informatika, Universitas Mataram

Jl. Majapahit 62, Mataram, Lombok NTB, INDONESIA

Email: fathinzts@gmail.com, bimo@unram.ac.id, gibransn@unram.ac.id

*Penulis Korespondensi

Abstract

Marine animals are very susceptible to decay. The traditional method that is often used to distinguish the freshness of squid by local people is from the body color and smell of the squid. This method is very simple but has many shortcomings in distinguishing freshness from squid. The drawback of this method lies in the understanding and level of accuracy of each person who is different. So it is necessary to create a system that can distinguish the freshness level of squid automatically only from the image of the squid. In this study, a system model was developed that can classify the freshness level of squid using the Support Vector Machine (SVM) method. The GLCM and histogram methods as well as the HSI color space are used for texture and color feature extraction. This study uses three types of classification. The total data used in this study are 360 body images of squid that have been cropped and resized by 128 x 128 pixels for the treatment type class. The total data for the freshness class with three types of classes is 495 and the total data for the freshness class with two types of classes is 330. In this study, the process of cropping, augmentation, resizing and conversion of color space in the dataset was carried out. The distribution of training data and test data is 70:30. The highest accuracy obtained is 67.75%.

Keywords: Squids Freshness, SVM, GLCM, HSI, Multi-Class

1. PENDAHULUAN

Indonesia merupakan negara kepulauan terbesar di dunia. Wilayah pesisir dan pulau-pulau kecil dan lautan kepulauan Indonesia disimpan potensi sumber daya alam dan jasa lingkungan yang sangat besar dan belum dimanfaatkan secara optimal. Potensi lestari sumberdaya perikanan laut Indonesia kurang lebih 6,4 juta ton per tahun [1]. Dengan luasnya perairan di Indonesia maka beragam pula hasil laut yang didapat, salah satunya adalah cumi – cumi. Nilai rata-rata hasil tangkapan cumi – cumi setiap tahun sebesar 88ton dan 189ton untuk wilayah selat Karimata hingga Laut Jawa pada tahun 2011 – 2012 [2]. Banyaknya hasil laut berupa cumi – cumi menyebabkan berkembangnya restoran yang menyediakan *seafood*.

Kebiasaan mengkonsumsi *seafood* di kalangan masyarakat semakin meningkat. *Seafood* merupakan makanan yang berasal dari olahan hewan-hewan laut, seperti udang, cumi-cumi, kepiting, ikan-ikan laut dan

sebagainya. *Seafood* dapat dikatakan salah satu olahan makanan yang paling digemari oleh masyarakat dan sering menjadi makanan untuk dikonsumsi sehari-hari. Hewan-hewan laut yang sering dijadikan menu olahan *seafood* dapat dikatakan relatif mudah didapatkan karena bisa dijumpai di pasar tradisional maupun pasar modern. Cumi – cumi merupakan hewan lunak (*Phylum Mollusca*) yang banyak digemari karena mengandung nilai gizi yang tinggi [3]. Cumi – cumi mengandung gizi yang baik untuk manusia, yaitu *selenium*, *riboflavin*, dan *vitamin B 12*. Tinta pada cumi-cumi juga dapat berfungsi sebagai antioksidan [4].

Seperti hewan laut lainnya cumi – cumi cepat mengalami pembusukkan. Ketika membeli cumi-cumi tentunya konsumen harus bisa membedakan mana cumi-cumi yang segar atau tidak. Tingkat kesegaran cumi-cumi juga akan berpengaruh pada cita rasa dan gizi dari makanan yang akan dibuat nantinya. Oleh karena itu, sangat penting untuk dapat membedakan cumi-cumi segar, atau yang sudah setengah segar

maupun yang sudah tidak layak dikonsumsi. Masih banyak masyarakat yang menjadi konsumen atau pembeli cumi-cumi yang belum bisa membedakan cumi-cumi segar atau yang sudah tidak segar lagi. Kebiasaan masyarakat membedakan cumi - cumi dari warnanya. Jika warnanya putih dan tidak pucat dapat dikatakan segar oleh masyarakat padahal faktanya cumi - cumi dengan warna putih sudah masuk kategori tidak segar. Oleh karena itu, perlu adanya cara untuk memberitahu atau mengajarkan masyarakat bagaimana cara membedakan cumi-cumi segar, tidak segar dan busuk dengan cara yang efektif.

Terdapat banyak metode yang dapat digunakan untuk klasifikasi tingkat kesegaran, salah satunya adalah metode *support vector machine*. *Support vector machine* merupakan mesin pembelajaran yang dapat digunakan untuk klasifikasi citra yang terdiri atas dua kelas. Saat ini telah ada *multi class support vector machine* yang dapat mengklasifikasi data ke dalam beberapa kelas (lebih dari dua kelas) [5]. Sebelumnya telah digunakan metode *support vector machine* untuk klasifikasi tingkat kesegaran hewan laut yaitu ikan dengan akurasi sebesar 98% [6].

Sepengetahuan penulis belum ada yang melakukan penelitian khusus tentang klasifikasi kesegaran cumi-cumi, penelitian sejenis membahas tentang klasifikasi kelas cumi-cumi menggunakan *Artificial Neural Network (ANN)* [7]. Fitur atau ciri yang dapat membedakan tingkat kesegaran cumi-cumi diperoleh berdasarkan fitur tekstur dan warna. Semakin lama umur daging cumi – cumi akan membuat cumi – cumi mengalami perubahan warna menjadi semakin mendekati warna merah dan perubahan tekstur yaitu bertambahnya bintik – bintik merah pada tubuh cumi – cumi. Untuk fitur warna digunakan model ruang warna HSI dan metode histogram. Model ruang warna HSI dapat menggambarkan warna yang dilihat oleh mata manusia [8]. Digunakan metode GLCM untuk ekstraksi fitur tekstur. Metode GLCM sangat berguna pada pengenalan pola [9]. Kombinasi antara ruang warna HSI dengan metode GLCM telah banyak digunakan oleh peneliti sebelumnya dan menghasilkan akurasi yang cukup tinggi. Salah satu penelitian yang menggunakan kombinasi antara ruang warna HSI dan GLCM yaitu penelitian tentang kesegaran daging sapi yang menghasilkan akurasi sebesar 90,5% [10].

Berdasarkan uraian yang telah dipaparkan di atas penulis akan melakukan penelitian yang berjudul “Klasifikasi Tingkat Kesegaran Cumi Berdasarkan Fitur Tekstur dan Warna dengan Menggunakan Metode *Support Vector Machine*”. Di dalam penelitian ini, tingkat kesegaran cumi – cumi lokal akan diklasifikasi

berdasarkan fitur tekstur dan warna yang ada pada badan cumi – cumi dengan menggunakan metode klasifikasi *support vector machine*.

2. TINJAUAN PUSTAKA

Beberapa penelitian terbaru yang berkaitan dengan penelitian tingkat kesegaran telah dilakukan sebelumnya oleh peneliti terdahulu namun untuk objek berupa cumi belum pernah dilakukan. Penelitian tentang cumi – cumi [7] pada bidang *computer vision* telah dilakukan namun penelitian tersebut meneliti tentang jenis cumi – cumi berdasarkan bentuk morfologinya dengan menggunakan metode *multilayer perceptron (MLP)*. Klasifikasi tingkat kesegaran hewan laut [11] lainnya pernah dilakukan oleh peneliti sebelumnya dengan menggunakan metode pendekatan kuadran terkecil dengan akurasi sebesar 83,33%. Dalam kasus hewan laut yang sama yaitu ikan pernah dilakukan penelitian tentang kesegaran ikan menggunakan metode *support vector machine* [6] dengan akurasi sebesar 78,59%.

Ruang warna HSI telah banyak digunakan pada penelitian sebelumnya. Penelitian tentang menentukan kesegaran apel [8] dengan menggunakan citra dari kulit buah apel yang utuh kemudian citra diubah dari RGB ke ruang warna HSI sehingga diperoleh akurasi tertinggi sebesar 50%. Ruang warna yang sama digunakan pada klasifikasi daging sapi segar [10] dengan akurasi tertinggi sebesar 84% untuk pengaruh ruang warna HSI terhadap rotasi.

Metode GLCM telah digunakan pada penelitian sebelumnya tentang klasifikasi daging sapi segar [5] dengan menggunakan citra daging sapi dengan 2 perlakuan yaitu dengan suhu *chilling* atau pendinginan dan tanpa pendinginan. Didapatkan akurasi sebesar 90,5%. Metode yang sama juga digunakan pada kasus klasifikasi retakan bangunan [12] dengan menggunakan citra dari tembok bangunan yang memiliki garis retakan paling parah dan didapatkan akurasi sebesar 96,35%. Dengan menggunakan metode GLCM untuk kasus klasifikasi variasi lahan padi [13] dengan menggunakan citra warna lahan padi yang berbeda – beda sehingga didapatkan akurasi sebesar 85.7% untuk tanaman padi yang baru tumbuh, 83.1% untuk tanaman padi yang subur 100% untuk tanaman padi yang sudah matang. Metode serupa juga digunakan dalam klasifikasi gambar lahan pertanian [14] dengan akurasi sebesar 84,375%.

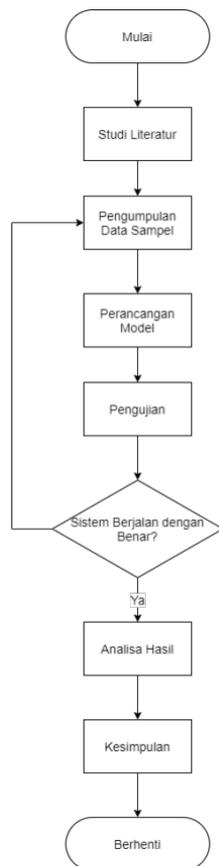
Adapun metode *support vector machine* telah digunakan dalam berbagai kasus klasifikasi. Penelitian tentang klasifikasi tingkat kesegaran daging [5] menggunakan metode *support vector machine* dengan

akurasi sebesar 90,5%. Metode yang sama juga digunakan pada klasifikasi retakan bangunan [12] dan didapatkan tingkat akurasi sebesar 96,35%. Klasifikasi tingkat kesegaran hewan laut[6] juga pernah dilakukan dengan menggunakan metode serupa dengan akurasi sebesar 78,59%.

Berdasarkan penjelasan di atas, maka fitur tekstur pada badan cumi - cumi juga dapat diekstraksi dengan metode ekstraksi fitur GLCM dan fitur warna pada badan cumi – cumi dapat diekstraksi menggunakan model ruang warna HSI dan metode histogram serta klasifikasi dapat dilakukan dengan menggunakan metode klasifikasi *Support Vector Machine*. Sehingga pada penelitian ini akan dibangun sistem klasifikasi tingkat kesegaran cumi – cumi dengan menggunakan metode *Support Vector Machine Classifier Support Vector Machine* dipilih karena merupakan salah satu *classifier* yang dapat mengatasi permasalahan pada data yang *non linear*.

3. METODE PENELITIAN

3.1 Diagram Alir Penelitian



Gambar 1. Diagram Alir Penelitian

Pada penelitian ini akan dilakukan beberapa tahapan seperti pada Gambar 1. Pertama dilakukan

studi literatur dengan tujuan untuk menambah dasar serta wawasan penulis dalam melakukan penelitian ini. Studi literatur bersumber dari jurnal – jurnal serta buku yang berisi materi terkait. Tahap selanjutnya merupakan pengumpulan data sampel. Pada tahap ini dilakukan pengambilan citra cumi – cumi serta pengumpulan *dataset* yang akan digunakan pada penelitian ini. Kemudian dilakukan perancangan model, tahap ini meliputi perancangan sistem seperti apa yang akan dihasilkan pada penelitian ini. Dilakukan pengujian untuk mengetahui apakah sistem berjalan sesuai fungsinya atau tidak. Jika tidak berjalan sesuai fungsinya maka kembali ke tahap pengumpulan data sampel untuk mengecek apakah ada kesalahan pada data yang digunakan. Analisa hasil merupakan tahapan untuk analisa hasil dari sistem yang telah dibuat pada penelitian ini. Dari hasil analisa diperoleh kesimpulan pada penelitian ini.

3.2 Pengumpulan Data Sampel

Data yang digunakan berupa foto cumi – cumi dengan menggunakan tiga kondisi yaitu tanpa pendinginan, direndam air es dan disimpan di dalam kulkas dengan suhu medium. Foto cumi – cumi yang digunakan pada penelitian ini diambil langsung oleh penulis. Cumi – cumi yang digunakan diperoleh dari pedagang di pasar Tanjung Luar. Waktu yang ditempuh untuk mengambil cumi – cumi ke tempat pengambilan foto *dataset* 3-3,5 jam. Cumi – cumi dengan kondisi tanpa pendinginan diambil selama 7 jam setiap jamnya. Cumi – cumi dengan kondisi disimpan di dalam kulkas diambil sekali setiap hari selama 14 hari. Cumi – cumi dengan kondisi direndam air es dilakukan pengambilan gambar sebanyak dua kali setiap harinya selama 7 hari dan air rendaman diganti setiap selesai mengambil gambar. Adapun contoh citra cumi – cumi yang telah dikumpulkan dapat dilihat pada Tabel 1. Sehingga data yang diperoleh dan digunakan nantinya sejumlah 360 data.

TABEL 1. CONTOH CITRA CUMI – CUMI DISIMPAN DI DALAM KULKAS

Citra					
Hari ke-	0	1	2	3	4
Citra					
Hari ke-	5	6	7	8	9
Citra					

Hari ke-	10	11	12	13	14
----------	----	----	----	----	----

Pelabelan dataset dilakukan oleh pakar dari Dinas Perairan dan Perikanan Provinsi NTB. Adapun penjelasan lebih rinci mengenai data yang akan digunakan untuk masing – masing kelas dapat dilihat pada Tabel II, Tabel III, dan Tabel IV

TABEL II. PEMBAGIAN DATASET KELAS JENIS PERLUKUAN

Jenis Data	Kelas			Total
	Tanpa pendinginan	Direndam dengan air es	Disimpan di dalam kulkas	
Data Latih	84	84	84	252
Data Uji	36	36	36	108
Total				360

TABEL III. PEMBAGIAN DATASET KELAS JENIS KESEGERAN 3 KELAS

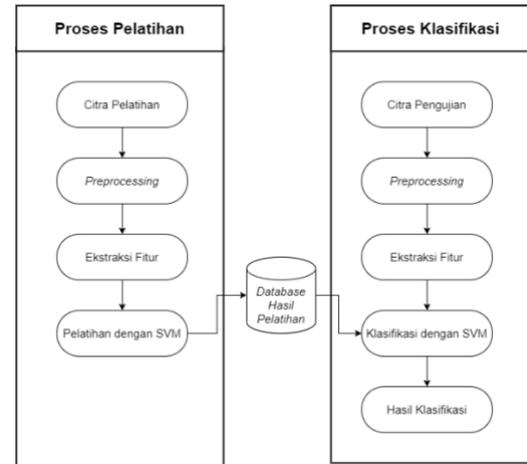
Jenis Data	Kelas			Total
	Segar	Tidak Segar	Busuk	
Data Latih	116	116	116	348
Data Uji	49	49	49	147
Total				495

TABEL IV. PEMBAGIAN DATASET KELAS JENIS KESEGERAN 2 KELAS

Jenis Data	Kelas		Total
	Segar	Tidak Segar	
Data Latih	116	116	232
Data Uji	49	49	98
Total			330

Perbedaan pada Tabel III dan Tabel IV yaitu terletak pada perbedaan *dataset* yang digunakan. Dilakukan augmentasi data untuk kelas tidak segar dan kelas busuk pada Tabel III. Sedangkan pada Tabel IV terdapat penggabungan *dataset* dari data kelas busuk dan tidak segar menjadi kelas tidak segar.

3.3 Perancangan Model



Gambar 2. Perancangan Sistem

Terdapat dua proses utama pada penelitian ini yaitu proses pelatihan dan proses klasifikasi. Penjelasan tentang tahapan proses pelatihan dan klasifikasi akan dijelaskan pada subbab 3.3.1 sampai 3.3.4

3.3.1. PreProcessing

Pada tahap *Preprocessing*, akan dilakukan empat tahapan yaitu *cropping*, *resize*, augmentasi, dan konversi ruang warna. Berikut penjelasan dan uraian mengenai tahap – tahap proses *preprocessing* tersebut:

- Cropping*, merupakan proses pemotongan citra menjadi ukuran tertentu. Proses ini digunakan dengan tujuan agar dapat meningkatkan akurasi dari sistem. Pada penelitian ini dilakukan *cropping* citra dengan rasio 1:1 pada bagian badan cumi – cumi. Proses ini dilakukan secara manual.
- Augmentasi citra, merupakan proses mengubah gambar agar komputer mengenali gambar baru sebagai gambar yang berbeda namun manusia masih mengenali gambar baru adalah gambar yang sama dengan gambar awal. Proses ini dilakukan dengan tujuan untuk memperbanyak dan menyeimbangkan jumlah data setiap kelasnya.
- Resize*, merupakan proses perubahan ukuran citra. Proses ini bertujuan untuk memberikan *dataset* yang seragam sehingga dapat mempermudah pelatihan sistem. Pada penelitian ini digunakan citra yang telah di-*resize* dengan ukuran 128 piksel x 128 piksel.
- Konversi ruang warna merupakan tahap terakhir dari proses *preprocessing*. Warna citra dikonversi dari warna semula yaitu RGB menjadi HSI dan *grayscale*.

Semua citra hasil dari ketiga tahapan *preprocessing* tersebut selanjutnya akan diproses pada tahapan ekstraksi fitur

3.3.2. Ekstraksi Fitur

- a. **Fitur Warna RGB.** Pada ruang warna atau RGB masing-masing piksel memiliki warna tertentu, warna tersebut adalah merah (Red), hijau (Green) dan biru (Blue). Jika masing-masing warna memiliki range 0 - 255, maka totalnya adalah 2553 = 16.581.375 (16 K) variasi warna berbeda pada gambar, dimana variasi warna ini cukup untuk gambar apapun. Karena jumlah bit yang diperlukan untuk setiap piksel, gambar tersebut juga disebut gambar-bit warna. Ruang warna ini terdiri dari tiga matriks yang mewakili nilai-nilai merah, hijau dan biru untuk setiap pikselnya [26].
- b. **Fitur Warna HSI.** Model warna HSI mendefinisikan warna dalam terminologi *Hue*, *Saturation* dan *Intensity*. *Hue* menyatakan warna sebenarnya, seperti merah, hijau dan biru. *Hue* digunakan untuk membedakan warna-warna dan menentukan kemerahan (*redness*), kehijauan (*greeness*) dan sebagainya dari cahaya. *Saturation* menyatakan tingkat kemurnian suatu warna, yaitu mengindikasikan seberapa banyak warna putih diberikan pada warna. *Intensity* adalah atribut yang menyatakan banyaknya cahaya yang diterima oleh mata tanpa memperdulikan warna. Dari warna RGB bisa didapatkan warna HSI melalui persamaan 1 sampai 4 untuk setiap komponen – komponen HSI [8]:

$$H = \begin{cases} \theta & \text{jika } B \leq G \\ 360 - \theta & \text{jika } B > G \end{cases} \quad (1)$$

dengan

$$\theta = \cos^{-1} \left\{ \frac{\frac{1}{2}(R-G)+(R-B)}{[(R-G)^2+(R-B)(G-B)]^{\frac{1}{2}}} \right\} \quad (2)$$

$$S = 1 - \frac{3}{(R+G+B)} [\min(R, G, B)] \quad (3)$$

$$I = \left(\frac{R+G+B}{3} \right) \quad (4)$$

- c. **Fitur Warna *Grayscale*.** Untuk mengubah citra berwarna yang mempunyai nilai matriks masing – masing r, g dan b menjadi citra *grayscale* dengan nilai s, maka konversi dapat dilakukan dengan mengambil rata-rata dari nilai r, g dan b sehingga dapat dituliskan menjadi persamaan (5) [30].

$$S = \left(\frac{R+G+B}{3} \right) \quad (5)$$

d. **Fitur Tekstur GLCM**

- 1. *Contrast*

$$Con = \sum_{n=0}^{Ng-1} n^2 \left\{ \sum_{i=1}^{Ng} \sum_{\substack{j=1 \\ |i-j|=n}}^{Ng} p(i, j) \right\} \quad (6)$$

- 2. *Corellation*

$$Cor = \frac{\sum_i \sum_j (ij)p(i, j) - \mu_x \mu_y}{\sigma_x \sigma_y} \quad (7)$$

- 3. *Homogeneity*

$$IDM = \sum_i \sum_j \frac{1}{1+(i-j)^2} p(i, j) \quad (8)$$

- 4. *Entropy*

$$Ent = -\sum_i \sum_j p(i, j) \log(p(i, j)) \quad (9)$$

- 5. *Variance*

$$var = \sum_i \sum_j (i - \mu)^2 p(i, j) \quad (10)$$

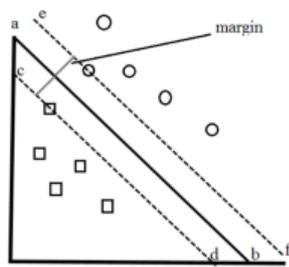
3.3.3. Support Vector Machine (SVM)

Support Vector Machine merupakan salah satu algoritma klasifikasi yang paling handal. SVM didasarkan pada gagasan untuk memaksimalkan margin yaitu memaksimalkan jarak minimum dari *hyperplane* pemisah ke contoh terdekat. SVM dasar hanya mendukung klasifikasi biner, tetapi ekstensi SVM telah diusulkan untuk menangani kasus klasifikasi *multiclass* juga. Dalam ekstensi ini, parameter dan batasan tambahan ditambahkan ke masalah optimisasi untuk menangani pemisahan kelas yang berbeda. Formulasi SVM dapat menghasilkan masalah optimisasi besar, yang mungkin tidak praktis untuk sejumlah kelas besar. Di sisi lain, SVM melaporkan formulasi yang lebih baik dengan implementasi yang lebih efisien [27].

Dalam kasus klasifikasi yang secara linier bisa dipisahkan, dapat digunakan fungsi pemisah seperti pada persamaan (6) [12].

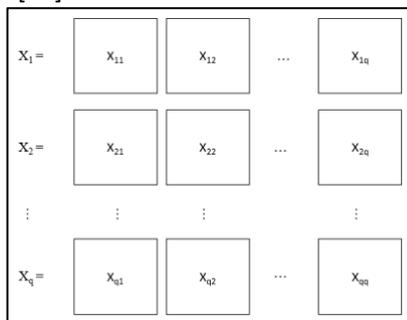
$$f(x) = w^T \cdot x + b \quad (6)$$

Di mana $w = \sum_i a_i \cdot S_i$ dan b adalah bias, sedangkan x merupakan nilai dari citra uji. *Hyperplane* pemisah terbaik antara kedua kelas dapat ditemukan dengan mengukur margin *hyperplane* dan mencari titik maksimal. Margin adalah jarak antara *hyperplane* tersebut dengan *pattern* terdekat dari masing-masing kelas. *Pattern* yang paling dekat ini disebut sebagai *support vector*. Garis ab pada Gambar 3 menunjukkan *hyperplane* terbaik, yaitu terletak tepat pada tengah-tengah kedua kelas sedangkan lingkaran dan kotak yang terletak pada garis putus-putus cd dan ef merupakan *support vector* [12].



Gambar 3. Margin hyperplane

Setiap data latih dinyatakan oleh (x_i, y_i) , di mana $i=1,2, \dots, N$, dan $x_i = \{x_{i1}, x_{i2}, \dots, x_{iq}\}^T$ merupakan atribut (fitur) set untuk data latih ke- i . q merupakan data x_i ke- q . $y_i \in \{-1, +1\}$ menyatakan label kelas seperti pada Gambar 4 [12].



Gambar 4. Ilustrasi SVM

Hyperplane klasifikasi linier SVM, seperti pada Gambar 3, dinotasikan seperti pada persamaan (7) [12].

$$w \cdot x_i + b = 0 \tag{7}$$

Data x_i yang masuk ke dalam kelas -1 adalah data yang memenuhi pertidaksamaan (8).

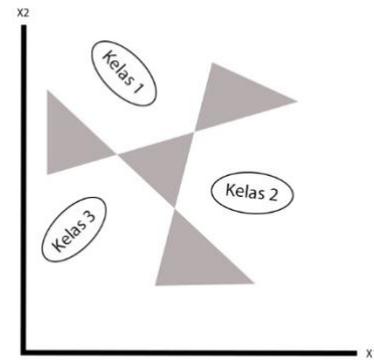
$$w \cdot x_i + b \leq -1 \tag{8}$$

Sementara data x_i yang masuk ke dalam kelas +1 adalah data yang memenuhi pertidaksamaan (9) [12].

$$w \cdot x_i + b \geq +1 \tag{9}$$

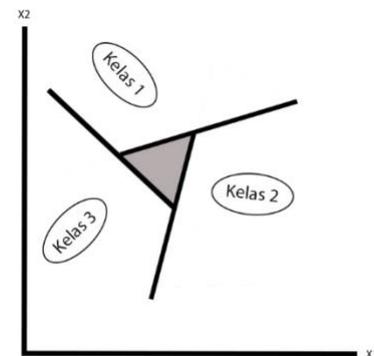
3.3.4. Multi-Class SVM

a. *One-Against-All* merupakan metode yang membandingkan satu kelas dengan semua kelas lainnya, sehingga dikenal sebagai *one-against-theRest*. Kelemahan utama metode *One-Against-All* ini adalah terbentuknya area – area yang tidak dapat diklasifikasikan (yang bukan termasuk kelas manapun). Hal ini dapat diilustrasikan pada Gambar 5, di mana area – are yang tidak dapat diklasifikasikan ditunjukkan dengan warna abu – abu [31].



Gambar 5. Gambar 5 Ilustrasi One-Against-All

b. *One-Against-One* merupakan metode yang mengharuskan membangun sejumlah model SVM biner yang membandingkan satu kelas dengan kelas lainnya. Pada metode ini juga mungkin terbentuknya area – area yang tidak dapat diklasifikasikan dapat diilustrasikan pada Gambar 6, di mana area – area yang tidak dapat diklasifikasikan ditunjukkan dengan warna abu – abu [31].



Gambar 6. Gambar 6 Ilustrasi One-Against-One

4. HASIL DAN PEMBAHASAN

4.1. Hasil

Pengujian dilakukan dengan menggunakan metode yang sama seperti pelatihan yaitu dengan menggunakan metode *Support Vector Machine*. Adapun parameter pengujian yang digunakan yaitu pengaruh kualitas gambar terhadap akurasi dan pengaruh rotasi gambar terhadap akurasi. Proses pengujian untuk setiap kelasnya dapat dilihat pada Gambar 7.



Gambar 7 Pengujian dengan Support Vector Machine

Adapun akurasi pengujian untuk semua kelas dapat dilihat pada Tabel V dan Tabel VI. Untuk pengujian lebih jelasnya akan dijelaskan pada subbab 4.2

TABEL V. AKURASI PENGUJIAN KELAS KESEGERAN DENGAN METODE SVM

Data set	Kernel	Jmlh Kelas	Akurasi (%)					
			C	H	GS	G	GB	GH
HP	RBF	3	39	37	37	39	39	39
	Linear	3	36	33	33	42	39	44
KAM	RBF	3	54	38	50	40	40	40
	Linear	3	40	36	39	36	41	43
Rata - Rata			42,25	36	39,75	39,25	39,75	41,5
HP	RBF	2	63	52	59	60	60	60
	Linear	2	54	47	53	57	55	57
KAM	RBF	2	59	55	58	58	57	57
	Linear	2	52	54	53	59	59	59
Rata - Rata			57	52	55,75	58,5	57,75	58,25

KETERANGAN: C=RGB, H=HSI, GS=GRAYSCALE, G=GLCM, GB=GLCM+RGB, GH=GLCM+HSI

TABEL VI. AKURASI KELAS JENIS PERLAKUAN DENGAN METODE SVM

Data set	Kernel	Jmlh Kelas	Akurasi (%)					
			C	H	GS	G	GB	GH
HP	RBF	3	63	74	61	60	60	60
	Linear	3	61	72	53	68	68	69
KAM	RBF	3	67	69	67	60	60	60
	Linear	3	64	56	61	69	73	75
Rata - Rata			63,75	67,75	60,5	64,25	65,25	66

KETERANGAN: C=RGB, H=HSI, GS=GRAYSCALE, G=GLCM, GB=GLCM+RGB, GH=GLCM+HSI

Dari segi visual gambar yang dihasilkan oleh dataset dengan kamera HP jauh lebih gelap dibandingkan dengan hasil dari dataset kamera DSLR. Selain itu gambar yang dihasilkan oleh kamera DSLR

memiliki noise lebih rendah dibandingkan dengan kamera HP.

4.2. Pembahasan

Pada penelitian ini dilakukan beberapa kali pengujian untuk mengetahui pengaruh dari masing – masing parameter terhadap hasil klasifikasi. Adapun parameter yang digunakan adalah resolusi dari citra dan rotasi gambar. Pengujian untuk masing-masing parameter dilakukan sebanyak 6 kali untuk menguji 6 fitur berbeda yang terdiri atas fitur warna RGB, HSI, grayscale, fitur tekstur GLCM, dan kombinasi fitur tekstur GLCM+RGB, dan GLCM+HSI .

Pada penelitian ini, ekstraksi fitur warna RGB dilakukan dengan menggunakan pendekatan statistik. Nilai statistik yang diekstraksi yaitu rata – rata (mean) dari setiap layer R, G, dan B sehingga dari tahapan ini didapatkan 3 fitur. Sama seperti fitur warna RGB, fitur warna HSI juga didapatkan melalui pendekatan statistik dengan mencari nilai mean dari setiap layer H, S, dan I. Diperoleh jumlah fitur yang sama yaitu 3 fitur. Pada penelitian ini untuk fitur warna grayscale sama seperti fitur warna lainnya dicari nilai rata – rata untuk grayscale sehingga didapatkan 1 fitur.

Penelitian ini menggunakan metode GLCM untuk ekstraksi fitur tekstur. Adapun fitur yang digunakan adalah variance, contrast, homogeneity (IDM), correlation, dan entropy. Pembentukan matriks GLCM pada penelitian ini dilakukan dengan memperhatikan 4 sudut yaitu sudut 0°, 45°, 90°, dan 135° dan dari keempat sudut ini diekstraksi ke-5 fitur tersebut sehingga didapatkan 20 fitur tekstur. Hasil yang didapat dari pengujian akan dijelaskan lebih rinci pada subbab 4.2.1 dan 4.2.2

4.2.1. Pengaruh Kualitas Gambar dengan Akurasi

Pengujian pertama dilakukan untuk mengetahui pengaruh dari kualitas gambar yang diperoleh. Dalam penelitian ini gambar dari kamera HP dan kamera DSLR di-resize menjadi 128x128 piksel kemudian dilakukan pengujian untuk kelas kesegaran dan kelas jenis perlakuan.

TABEL VII. AKURASI MASING – MASING KUALITAS GAMBAR

Kelas	Dataset HP (%)	Dataset Kamera (%)
Jenis Perlakuan	65,17	66,33%
Kesegaran 3 Kelas	38,3	43,67
Kesegaran 2 Kelas	59	56
Rata - Rata	54,17	55,33

Pada Tabel VII dapat dilihat bahwa kualitas gambar mempengaruhi akurasi dari klasifikasi setiap kelasnya. Akurasi terbaik diperoleh untuk dataset yang diambil

menggunakan kamera DSLR yaitu 55,33%. *Recall*, *precision* dan *F1-score* digunakan untuk mempresentasikan akurasi dari setiap kelas yang ada pada penelitian ini. *Precision* merupakan perbandingan prediksi kelas positif yang terklasifikasi dengan benar. *Recall* merupakan perbandingan kelas positif yang terklasifikasi dengan benar. *F1-score* merupakan rata – rata *precision* dan *recall* yang diberi bobot. Adapun akurasi untuk masing – masing kelas dapat dilihat dari nilai *recall*, *precision* dan *F1-score* yang dapat dilihat pada Tabel VIII sampai Tabel XIII.

TABEL VIII. AKURASI KELAS JENIS PERLAKUAN HP

KLS	C (%)			H (%)			GS (%)		
	R	P	F	R	P	F	R	P	F
0	62	72	67	70	83	76	47	81	59
1	73	67	70	89	67	76	60	72	66
2	48	44	46	63	67	65	67	6	10
KLS	G (%)			GB (%)			GH (%)		
	R	P	F	R	P	F	R	P	F
0	69	75	72	75	67	71	74	78	76
1	66	69	68	70	78	74	77	67	72
2	68	58	63	58	58	58	56	61	59

KETERANGAN: C=RGB, H=HSI, GS=GRAYSCALE, G=GLCM, GB=GLCM+RGB, GH=GLCM+HSI, 0 = KELAS SEGAR, 1 = KELAS TIDAK SEGAR, R = *RECALL*, P = *PRECISION*, F = *F-SCORE*

TABEL IX. AKURASI KELAS JENIS PERLAKUAN KAMERA

KLS	C (%)			H (%)			Gs (%)		
	R	P	F	R	P	F	R	P	F
0	84	89	86	74	72	73	82	89	85
1	48	33	39	46	72	56	41	25	31
2	56	69	62	56	25	35	53	69	60
KLS	G (%)			GB (%)			GH (%)		
	R	P	F	R	P	F	R	P	F
0	76	61	68	86	69	77	100	72	84
1	68	72	70	75	75	75	67	83	74
2	63	72	68	63	75	68	68	69	68

KETERANGAN: C=RGB, H=HSI, GS=GRAYSCALE, G=GLCM, GB=GLCM+RGB, GH=GLCM+HSI, 0 = KELAS SEGAR, 1 = KELAS TIDAK SEGAR, R = *RECALL*, P = *PRECISION*, F = *F-SCORE*

Pada Tabel VII dan Tabel IX terlihat jelas persentase dikenalnya setiap kelas jenis perlakuan sangat bervariasi untuk setiap jenis *dataset*. Pada Tabel IX dapat dilihat bahwa kelas direndam air es dari *dataset* kamera dikenali dengan sangat baik dibuktikan dengan nilai tertinggi *recall*, *precision* dan *F1-score* dari kelas direndam air es. Pada Tabel VII didapat nilai tertinggi *recall* oleh fitur GLCM+HSI senilai 100%. Dari

Tabel VIII dan Tabel IX dapat dilihat bahwa untuk kelas jenis perlakuan *dataset* yang dihasilkan oleh kamera DSLR lebih baik dari *dataset* kamera HP dengan fitur terbaik yaitu fitur HSI.

TABEL X. AKURASI KELAS JENIS KESEGERAN 3 KELAS HP

Kls	C (%)			H (%)			GS (%)		
	R	P	F	R	P	F	R	P	F
0	37	59	46	30	51	38	35	55	43
1	39	18	25	50	24	33	41	18	25
2	41	39	40	44	37	40	40	39	39
Kls	G (%)			GB (%)			GH (%)		
	R	P	F	R	P	F	R	P	F
0	40	37	38	40	39	40	40	39	40
1	31	22	26	31	20	25	31	20	25
2	43	59	50	43	59	50	43	59	50

KETERANGAN: C=RGB, H=HSI, GS=GRAYSCALE, G=GLCM, GB=GLCM+RGB, GH=GLCM+HSI, 0 = KELAS SEGAR, 1 = KELAS TIDAK SEGAR, R = *RECALL*, P = *PRECISION*, F = *F-SCORE*

TABEL XI. AKURASI KELAS JENIS KESEGERAN 3 KELAS KAMERA

Kelas	C (%)			H (%)			GS (%)		
	R	P	F	R	P	F	R	P	F
0	53	82	65	21	8	12	45	86	59
1	49	45	47	35	41	38	50	27	35
2	67	37	47	45	65	53	67	37	47
Kls	G (%)			GB (%)			GH (%)		
	R	P	F	R	P	F	R	P	F
0	36	65	46	36	65	46	36	65	46
1	21	8	12	21	8	12	21	8	12
2	61	47	53	61	47	53	61	47	53

KETERANGAN: C=RGB, H=HSI, GS=GRAYSCALE, G=GLCM, GB=GLCM+RGB, GH=GLCM+HSI, 0 = KELAS SEGAR, 1 = KELAS TIDAK SEGAR, R = *RECALL*, P = *PRECISION*, F = *F-SCORE*

Dapat dilihat pada Tabel X dan Tabel XI bahwa semua kelas dapat dikenali oleh sistem. Nilai presisi terbaik dimiliki oleh fitur warna *grayscale* dari kelas jenis kesegaran dengan 3 kelas kesegaran dengan *dataset* kamera.

TABEL XII. AKURASI KELAS JENIS KESEGERAN 2 KELAS HP

Kls	C (%)			H (%)			GS (%)		
	R	P	F	R	P	F	R	P	F
0	63	63	63	52	45	48	58	67	62
1	63	63	63	52	59	55	61	51	56
Kls	R(%)			H (%)			GR (%)		
	R	P	F	R	P	F	R	P	F
0	59	69	64	59	69	64	59	69	64
1	62	51	56	62	51	56	62	51	56

KETERANGAN: C=RGB, H=HSI, GS=GRAYSCALE, G=GLCM, GB=GLCM+RGB, GH=GLCM+HSI, 0 = KELAS SEGAR, 1 = KELAS TIDAK SEGAR, R = *RECALL*, P = *PRECISION*, F = *F-SCORE*

TABEL XIII. AKURASI KELAS JENIS KESEGERAN 2 KELAS KAMERA

Kelas	C (%)			H (%)			GS (%)		
	R	P	F	R	P	F	R	P	F

0	57	78	66	53	80	64	56	80	66
1	65	41	50	60	31	41	64	37	47
Kelas	G (%)			GB (%)			GH (%)		
	R	P	F	R	P	F	R	P	F
0	56	82	66	55	80	65	55	80	65
1	65	35	45	63	35	45	63	35	45

KETERANGAN: R=RGB, H=HSI, GR=GRAYSCALE, G=GLCM, GB=GLCM+RGB, GH=GLCM+HSI, 0 = KELAS SEGAR, 1 = KELAS TIDAK SEGAR, R = *RECALL*, P = *PRECISION*, F = *F-SCORE*

Hasil klasifikasi untuk kelas kesegaran dengan dua jenis kelas kesegaran jauh lebih baik dibandingkan dengan kelas kesegaran dengan tiga jenis kelas kesegaran. Dapat dilihat pada Tabel 4.XII dan Tabel XIII adanya peningkatan nilai akurasi dari kedua *dataset* baik dari *dataset* hp dan *dataset* kamera dari akurasi sebelumnya yang dapat dilihat pada Tabel X dan Tabel XI.

4.2.2. Pengaruh Rotasi Terhadap Akurasi

Pengujian terakhir dilakukan untuk mengetahui pengaruh dari rotasi gambar terhadap akurasi yang diperoleh. Dalam penelitian ini gambar pengujian dari *dataset* kamera HP diputar 90° dan 180° derajat searah jarum jam kemudian dilakukan pengujian untuk kelas kesegaran dan kelas jenis perlakuan.

TABEL XIV. TABEL AKURASI MASING – MASING SUDUT ROTASI

Kelas	Dataset 90° (%)	Dataset 180° (%)
Jenis Perlakuan	44,5	46,17
Kesegaran 3 Kelas	38,33	38,33
Kesegaran 2 Kelas	60,33	59,83
Rata - Rata	47,72	48,11

Pada Tabel XIV dapat dilihat bahwa terdapat perbedaan rotasi sudut mempengaruhi akurasi. Jika dibandingkan dengan Tabel VII terdapat kemunduran nilai rata – rata akurasi dari 54,17 menjadi sekitar 47-48,11. Adapun akurasi untuk masing – masing sudut dapat dilihat dari nilai *recall*, *precision* dan *F1-score* yang dapat dilihat pada Tabel XV sampai Tabel XX.

TABEL XV. AKURASI KELAS JENIS PERLAKUAN DATASET PENGUJIAN ROTASI SUDUT 90°

Kls	C (%)			H (%)			GS (%)		
	R	P	F	R	P	F	R	P	F
0	97	43	59	92	62	74	100	38	55
1	3	33	5	56	50	53	14	50	22
2	28	43	34	19	47	27	3	33	5
Kls	G (%)			GB (%)			GH (%)		
	R	P	F	R	P	F	R	P	F
0	86	42	57	94	39	55	97	45	62
1	39	40	39	22	38	28	47	55	51
2	0	0	0	0	0	0	0	0	0

KETERANGAN: R=RGB, H=HSI, GR=GRAYSCALE, G=GLCM, GB=GLCM+RGB, GH=GLCM+HSI, 0 = KELAS SEGAR, 1 = KELAS TIDAK SEGAR, R = *RECALL*, P = *PRECISION*, F = *F-SCORE*

TABEL XVI. AKURASI KELAS JENIS PERLAKUAN DATASET PENGUJIAN ROTASI SUDUT 180°

Kls	C (%)			H (%)			GS (%)		
	R	P	F	R	P	F	R	P	F
0	97	43	59	92	63	75	100	38	55
1	3	33	5	56	50	53	14	50	22
2	28	43	34	22	50	31	3	33	5
Kls	G (%)			GB (%)			GH (%)		
	R	P	F	R	P	F	R	P	F
0	78	42	54	97	38	55	94	50	65
1	58	51	55	28	62	38	61	55	58
2	0	0	0	0	0	0	0	0	0

KETERANGAN: R=RGB, H=HSI, GR=GRAYSCALE, G=GLCM, GB=GLCM+RGB, GH=GLCM+HSI, 0 = KELAS SEGAR, 1 = KELAS TIDAK SEGAR, R = *RECALL*, P = *PRECISION*, F = *F-SCORE*

Pada Tabel XV dan Tabel XVI untuk fitur warna tidak terdapat perbedaan kecuali pada fitur warna HSI ada sedikit perbedaan antara *dataset* sudut 90° dan 180°. untuk setiap jenis *dataset*. Perubahan nilai akurasi sangat terlihat pada fitur tekstur dan kombinasi fitur tekstur dan warna. Pada fitur GLCM, GLCM+RGB dan GLCM+HSI kelas tanpa pendinginan tidak dapat dikenali sama sekali sehingga menyebabkan penurunan nilai akurasi klasifikasi untuk kelas jenis perlakuan.

TABEL XVII. AKURASI KELAS JENIS KESEGARAN 3 KELAS DATASET PENGUJIAN ROTASI SUDUT 90°

Kls	C (%)			H (%)			GS (%)		
	R	P	F	R	P	F	R	P	F
0	59	37	46	51	30	38	55	35	43
1	18	39	25	24	50	33	18	41	25
2	39	41	40	37	44	40	39	40	39
Kls	G (%)			GB (%)			GH (%)		
	R	P	F	R	P	F	R	P	F
0	39	37	38	39	37	38	39	37	38
1	20	29	24	18	27	22	18	27	22
2	59	47	52	59	47	52	59	47	52

KETERANGAN: C=RGB, H=HSI, GS=GRAYSCALE, G=GLCM, GB=GLCM+RGB, GH=GLCM+HSI, 0 = KELAS SEGAR, 1 = KELAS TIDAK SEGAR, R = *RECALL*, P = *PRECISION*, F = *F-SCORE*

TABEL XVIII. AKURASI KELAS JENIS KESEGARAN 3 KELAS DATASET PENGUJIAN ROTASI SUDUT 180°

Kls	C (%)			H (%)			GS (%)		
	R	P	F	R	P	F	R	P	F
0	59	37	46	51	30	38	55	35	43
1	18	39	25	24	50	33	18	41	25
2	39	41	40	37	44	40	39	40	39
Kls	G (%)			GB (%)			GH (%)		
	R	P	F	R	P	F	R	P	F
0	37	40	38	39	40	40	39	40	40
1	22	31	26	20	31	25	20	31	25

2	59	43	50	59	43	50	59	43	50
---	----	----	----	----	----	----	----	----	----

KETERANGAN: C=RGB, H=HSI, GS=GRAYSCALE, G=GLCM, GB=GLCM+RGB, GH=GLCM+HSI, 0 = KELAS SEGAR, 1 = KELAS TIDAK SEGAR, R = RECALL, P = PRECISSION, F = F-SCORE

Dapat dilihat pada Tabel XVII dan Tabel XVIII fitur warna kelas jenis kesegaran tiga kelas untuk setiap dataset memiliki nilai akurasi yang sama. Fitur tekstur dan kombinasi fitur tekstur dan warna memiliki perbedaan nilai akurasi seperti pada kelas jenis perlakuan. Kelas busuk pada kelas kesegaran untuk jumlah kelas 3 kelas dapat dikenali.

TABEL XIX. AKURASI KELAS JENIS KESEGERAN 2 KELAS DATASET PENGUJIAN ROTASI SUDUT 90°

Kls	C (%)			H (%)			GS (%)		
	R	P	F	R	P	F	R	P	F
0	63	63	63	43	51	47	67	58	62
1	63	63	63	59	51	55	51	61	56
Kls	G (%)			GB (%)			GH (%)		
	R	P	F	R	P	F	R	P	F
0	78	60	68	78	60	68	78	60	68
1	49	69	57	49	69	57	49	69	57

KETERANGAN: C=RGB, H=HSI, GS=GRAYSCALE, G=GLCM, GB=GLCM+RGB, GH=GLCM+HSI, 0 = KELAS SEGAR, 1 = KELAS TIDAK SEGAR, R = RECALL, P = PRECISSION, F = F-SCORE

TABEL XX. AKURASI KELAS JENIS KESEGERAN 2 KELAS DATASET PENGUJIAN ROTASI SUDUT 180°

Kls	C (%)			H (%)			GS (%)		
	R	P	F	R	P	F	R	P	F
0	63	63	63	43	51	47	67	58	62
1	63	63	63	59	51	55	51	61	56
Kls	G (%)			GB (%)			GH (%)		
	R	P	F	R	P	F	R	P	F
0	78	59	67	78	59	67	78	59	67
1	47	68	55	47	68	55	47	68	55

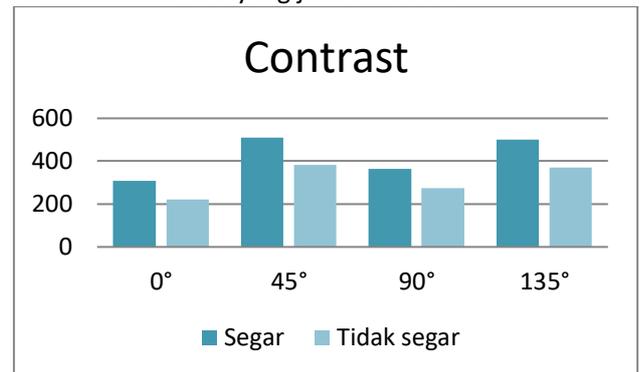
KETERANGAN: C=RGB, H=HSI, GS=GRAYSCALE, G=GLCM, GB=GLCM+RGB, GH=GLCM+HSI, 0 = KELAS SEGAR, 1 = KELAS TIDAK SEGAR, R = RECALL, P = PRECISSION, F = F-SCORE

Dapat dilihat pada Tabel XVII sampai Tabel XX fitur warna untuk kelas jenis kesegaran setiap dataset memiliki nilai akurasi yang sama masing – masing kelasnya sehingga dapat disimpulkan bahwa untuk dataset pengujian kelas kesegaran untuk fitur warna tidak dipengaruhi rotasi.

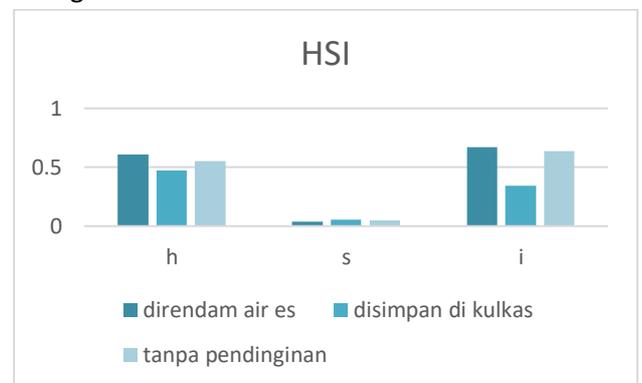
4.2.3. Analisa Sebaran Data

Akurasi terbaik untuk kelas jenis kesegaran diperoleh oleh fitur GLCM sebesar 58,5% dengan fitur GLCM terbaik yaitu fitur *contrast*. Dapat dilihat pada

gambar 7 sebaran nilai dari data antar masing–masing kelas memiliki nilai yang jauh berbeda.



Gambar 7. Grafik Sebaran Data Fitur *Contrast* Kelas Kesegaran



Gambar 8. Grafik Sebaran Data Fitur HSI Kelas Jenis Perlakuan

Nilai akurasi klasifikasi kelas jenis perlakuan tertinggi diperoleh fitur HSI dengan nilai rata-rata sebesar 67,75%. dapat dilihat pada gambar 8 merupakan grafik sebaran data dari fitur HSI untuk kelas jenis perlakuan. Antar masing-masing kelas memiliki perbedaan nilai yang berbeda sehingga dapat dikatakan bahwa fitur HSI dapat membedakan ketiga kelas dengan cukup baik.

5. KESIMPULAN DAN SARAN

5.1. Kesimpulan

Tujuan penelitian yang sudah dipaparkan pada bagian Pendahuluan telah didapatkan, sedangkan beberapa kesimpulan yang didapatkan dari penelitian ini antara lain sebagai berikut:

1. Faktor penentu nilai akurasi dari metode *support vector machine* adalah terletak pada data. Jika data diberi label dengan tepat maka akurasi dari metode *support vector machine* (SVM) dapat meningkat.

Selain data perlu juga memperhatikan fitur – fitur yang digunakan.

2. Banyaknya fitur yang digunakan tidak dapat menjamin peningkatan nilai akurasi. Perlu dilakukan seleksi fitur terlebih dahulu untuk menentukan fitur yang sesuai dengan permasalahan yang ada.
3. Klasifikasi jenis perlakuan fitur terbaik didapatkan yaitu pada fitur warna HSI dengan nilai rata – rata akurasi sebesar 67,75%. Fitur terbaik untuk kelas jenis kesegaran yaitu fitur GLCM dengan nilai akurasi 58,5%.
4. Perbedaan penggunaan media pengambilan gambar *dataset* pada penelitian juga mempengaruhi akurasi dari klasifikasi dengan menggunakan metode SVM. Hasil akurasi dari *dataset* dengan menggunakan kamera DSLR jauh lebih baik dibandingkan *dataset* menggunakan kamera HP. Selain itu rotasi juga dapat mempengaruhi hasil dari akurasi. Baik buruknya sebuah *dataset* dapat dilihat dari grafik penyebaran data dari setiap fitur yang digunakan. Jika terdapat perbedaan nilai fitur dari masing – masing kelas yang signifikan dapat dikatakan *dataset* yang digunakan merupakan *dataset* yang baik.

2. Saran

Adapun saran untuk penelitian lebih lanjut adalah sebagai berikut:

1. Perlu perhatian ekstra dalam pengambilan dan pemberian label *dataset*. Lebih baik jika membentuk tim dengan *time keeper* di dalamnya.
2. Lakukan pengambilan data dengan menggunakan kamera Iphone.
3. Perlu dilakukan segmentasi untuk meningkatkan kualitas data.
4. Lakukan seleksi fitur untuk mengetahui fitur yang tepat untuk jenis data seperti bagian tubuh cumi – cumi beserta grafik korelasi antar variabel kelas.
5. Lakukan percobaan dengan menggunakan metode CNN atau metode klasifikasi lainnya.

6. UCAPAN TERIMA KASIH

Ucapan terima kasih diberikan kepada Bapak Sugianur, S.Pi. sebagai pakar dari pelabelan *dataset* yang digunakan penelitian ini.

7. DAFTAR PUSTAKA

- [1] R. Lasabuda, “Pembangunan Wilayah Pesisir dan Lautan dalam Perspektif Negara Kepulauan Republik Indonesia,” *Ilm. Platax*, vol. 1, p. 93, 2013.
- [2] B. A. Prasetyo, A. Hartoko, and S. Hutabarat, “Sebaran Spasial Cumi-cumi (*Loligo Spp.*) Dengan Variabel Suhu Permukaan Laut Dan Klorofil-a Data Satelit Modis Aqua Di Selat Karimata Hingga Laut Jawa,” *J. Manag. Aquat. Resour.*, vol. 3, no. 1, p. 51, 2014.
- [3] A. Febrianto, D. Simbolon, J. Haluan, and . Mustaruddin, “Pola Musim Penangkapan Cumi-Cumi Di Perairan Luar dan Dalam Daerah Penambangan Timah Kabupaten Bangka Selatan,” *Mar. Fish. J. Mar. Fish. Technol. Manag.*, vol. 8, no. 1, p. 64, 2017.
- [4] T. W. Agustini, Hadiyanto, I. Wijayanti, U. Amalia, and S. Benjakul, “Effect of Melanin Free Ink Extracted from Squid (*Loligo sp.*) on Proximate and Sensory Characteristics of Soft-Bone Milkfish (*Chanos chanos*) during Storage,” *IOP Conf. Ser. Earth Environ. Sci.*, vol. 116, no. 1, p. 4, 2018.
- [5] R. Farinda, I. G. P. Sutawijaya, and F. Bimantoro, Klasifikasi Tingkat Kesegaran Daging Sapi Berdasarkan Fitur Tekstur dan Warna Menggunakan Support Vector Machine. Mataram: Program Studi Teknik Informatika, 2018.
- [6] L. K. S. Tolentino et al., “Fish Freshness Determination Through Support Vector Machine,” *J. Telecommun. Electron. Comput. Eng.*, vol. 9, no. 2–5, pp. 139–143, 2017.
- [7] K. Himabindu, S. Jyothi, and D. M. Mamatha, “Classification of Squids Using Morphometric Measurements,” *Gazi Univ. J. Sci.*, vol. 30, no. 2, pp. 61–71, 2017.
- [8] S. Aini, I. G. P. S. Wijaya, and G. W. Wiriasto, “Klasifikasi Kesegaran Buah Apel Berdasarkan Ekstraksi Fitur Warna Dan Tekstur Menggunakan Gray Level Co-Occurrence Matrix Dan Algoritma K-Nearest Neighbor,” *J. Tek. Elektro*, vol. 16, pp. 1–8, 2018.
- [9] L. P. Mohaniah; Sathyanarayana, Dr. P.; Gurukumar, “Image Texture Feature Extraction Using GLCM Approach,” *Int. J. Sci. Res. Publ.*, vol. 3, no. 5, p. 4, 2016.
- [10] R. Farinda, Z. R. Firmansyah, C. Sulton, I. S. Wijaya, and F. Bimantoro, “Beef Quality Classification based on Texture and Color Features using SVM Classifier,” *Univ. Mataram*, pp. 1–11, 2018.
- [11] D. Bee, W. D. Ch Weku, and A. J. Rindengan, “Aplikasi Penentuan Tingkat Kesegaran Ikan Selar Berbasis Citra Digital Dengan Metode Kuadrat Terkecil,” *JdC*, vol. 5, no. 2, pp. 121–130, 2016.
- [12] C. Sulton, I. B. K. Widiartha, and I. G. P. Sutawijaya, Klasifikasi Retakan (Crack) pada Bangunan dengan Analisis Citra Menggunakan Metode GLCM dan

- Klasifikasi SVM. Mataram: Program Studi Teknik Informatika, 2019.
- [13] M. V. Latte, S. Shidnal, B. S. Anami, and V. B. Kuligod, "A Combined HSV and GLCM Approach For Paddy Variety Identification From Crop Images," *Int. J. Signal Process. Image Process. Pattern Recognit.*, vol. 8, no. 10, pp. 221–232, 2015.
- [14] M. V. Latte, S. Shidnal, B. S. Anami, and V. B. Kuligod, "A Combined Color and Texture Features Based Methodology for Recognition of Crop Field Image," *Int. J. Signal Process. Image Process. Pattern Recognit.*, vol. 8, no. 2, pp. 287–302, 2015.
- [15] S. Hadinoto, "Pembuatan Bekasam Cumi-Cumi (*Loligo sp*) Dengan Variasi Pemberian Garam (NaCl) dan Beras Gongseng (*Oriza Sativa*) Terhadap Penerimaan Konsumen," *Maj. Biam*, vol. 9, no. 2, p. 76, 2013.
- [16] R. R. Apandi, Pembentukan Formaldehid Alami Pada Cumi-cumi (*Loligo sp.*) Selama Penyimpanan Suhu Chilling. Bogor: Institut Pertanian Bogor, 2017.
- [17] D. Alviana, Kemunduran Mutu Daging Cumi-Cumi Selama Penyimpanan Suhu Dingin Berdasarkan Aspek Enzimatis Dan Histologis. Bogor: Institut Pertanian Bogor, 2017.
- [18] D. S. Soenarto M.Pd., "Buku Media FT Fotografi," in *Media Pembelajaran Teknologi dan Kejuruan*, 2013, pp. 34–44.
- [19] M. Sheraton, "Ultimate Field Guide to Photography," *Smithsonian*, vol. 40, no. 12, pp. 42–48, 2010.
- [20] T. Riyadi, "Sinematografi dengan Kamera DSLR," *Humaniora*, vol. 5, no. 2, p. 919, 2014.
- [21] N. Syafitri, "Pengenalan Pola Untuk Deteksi Uang Koin," *SNTIKI*, vol. III, p. 20, 2011.
- [22] I. Santoso, Y. Christyono, and M. Indriani, "Kinerja Pengenalan Citra Tekstur Menggunakan Analisis Tekstur Metode Run Length," *Semin. Nas. Apl. Teknol. Inf. 2007 (SNATI 2007)*, vol. I, p. 19, 2007.
- [23] Noordama, Identifikasi Varietas Durio *Zibethinus* Berdasarkan Sebaran Trikoma Daun Menggunakan GLCM dan KNN. Bogor, 2014.
- [24] S. H. S. Al-Kilidar and L. E. George, "Texture Recognition Using CO-Occurrence Matrix Features and Neural Network," *J. Theor. Appl. Inf. Technol.*, vol. 95, no. 21, pp. 5949–5961, 2017.
- [25] D. Chandrakala and S. Sumathi, "Image Classification Based on Color and Texture features using FRBFN network with Artificial Bee Colony Optimization Algorithm," *Int. J. Comput. Appl.*, vol. 98, no. 14, p. 21, 2014.
- [26] O. N. Shpakov and G. V. Bogomolov, "Pengolahan Citra Digital Untuk Mendeteksi Obyek Menggunakan Pengolahan Warna Model Normalisasi RGB," *Semant.* 2011, vol. 17, p. 330, 2011.
- [27] M. Aly, "Survey on Multiclass Classification Methods Extensible Algorithms," *Neural Networks*, vol. I, p. 4, 2005.
- [28] H. M and S. M.N, "A Review on Evaluation Metrics for Data Classification Evaluations," *Int. J. Data Min. Knowl. Manag. Process*, vol. 5, no. 2, p. 4, 2015.
- [29] G. Hoang, A. Bouzerdoum, and S. Lam, "Learning Pattern Classification Tasks with Imbalanced Data Sets," *J. Fac. Inform.*, vol. 792, p. 200, 2010.
- [30] C. N. Santi, "Mengubah Citra Berwarna Menjadi Gray-Scale dan Citra biner," *Teknol. Inf. Din.*, vol. 16, no. 1, pp. 14–19, 2011.
- [31] Suyanto, "Support Vector Machine", *Machine Learning Tingkat Dasar dan Lanjut*, Edisi 1. Bandung: Penerbit Informatika, 2018, halaman.