

Pengenalan Jenis Buah Berdasarkan Citra Menggunakan HOG dan Histogram HSV

Indriana Fadhila Ashari¹, Ema Rachmawati², Febryanti Sthevanie³

^{1,2,3}Fakultas Informatika, Universitas Telkom, Bandung

¹indrianafadhila@student.telkomuniversity.ac.id, ²emarachmawati@telkomuniversity.ac.id,

³sthevanie@telkomuniversity.ac.id

Abstrak

Mengenali berbagai jenis buah merupakan salah satu kegiatan yang sering terjadi di supermarket, ketika pegawai harus mampu mengenali tidak hanya jenis buah tertentu, tetapi juga variasinya sehingga mereka mampu menentukan harga dari buah tersebut. Namun, telah ditemukan adanya masalah seperti pegawai yang tidak dapat mengingat atau menghafalkan setiap kode buah dapat menyebabkan terjadinya kesalahan pada penentuan harga. Sehingga dibutuhkan sistem yang dapat mengenali atau mengklasifikasikan jenis buah secara otomatis melalui citra. Sistem ini dapat mengklasifikasikan 131 jenis buah dari dataset Fruits-360 yang terdapat keterkaitan antar kelas, seperti: tomat dan stroberi memiliki warna yang sama meskipun berbeda bentuk, serta apel braeburn dan apel golden dimana mereka memiliki bentuk yang hampir sama namun memiliki perbedaan pada hal warna. Citra dari buah akan diekstraksi fitur menggunakan *Histogram of Oriented Gradient (HOG)* dan Histogram HSV yang dipadukan dengan *Random Forest (RF)* sebagai metode klasifikasinya. Proses pelatihan yang telah dilakukan dengan 67.692 citra latih, memperoleh sebuah model yang dapat melakukan klasifikasi 131 jenis buah. Hasil prediksi yang dilakukan terhadap 22.688 citra uji dengan 131 jenis kelas berbeda ini dapat memprediksi kelas buah dengan akurasi hingga 98.11795%.

Kata Kunci: pengenalan buah, pembelajaran mesin, *HOG, HSV, random forest*

Abstract

Recognizing various types of fruit is one of activities that often occur in supermarkets, where staff must be able to recognize not only certain types of fruit, but also their variations, so they will be able to determine the price of the fruit. However, still there is problem have been found, such as staff not being able to memorize each fruit code, leading to errors in pricing. Therefore, it is necessary to build a system that can recognize or classify types of fruit automatically through images. This system can classify 131 types of fruit from Fruits-360 dataset which are related between classes, such as tomatoes and strawberries have the same color even though they are different in shape, as well as Braeburn apples and golden apples where they have almost same shape but have differences in color. The image of the fruit will be extracted using Histogram of Oriented Gradient (HOG) and the HSV Histogram and combined with Random Forest (RF) as the classification method. The training process with 67,692 training images has produced a model that can classify 131 types of fruit. The result of the prediction made on 22,688 test images with 131 different class types can predict fruit classes with the up to accuracy 98.11795%

Keywords: fruit recognition, machine learning, *HOG, HSV, random forest*

1. Pendahuluan

Latar Belakang

Gambar atau citra adalah elemen media yang berfungsi dalam penyampaian informasi secara visual. Dengan kemajuan teknologi saat ini, citra digital dapat diolah menjadi informasi yang berguna. Kemajuan teknologi ini memungkinkan manusia untuk mengklasifikasi buah otomatis dengan akurat dan efisien.

Klasifikasi buah secara otomatis ini dapat diterapkan dalam supermarket, dimana karyawan supermarket perlu mengklasifikasikan jenis buah untuk menentukan harga buah tersebut [1]. Penentuan harga buah dapat

dilakukan dengan memberikan *barcode* dan label harga pada buah yang sudah dikemas, namun ada kalanya pembeli ingin memilih buah sendiri (tidak dikemas) untuk kemudian ditimbang. Untuk menentukan harga buah yang ditimbang, karyawan supermarket perlu mengingat jenis dan kode buah atau harga setiap buah per kilogramnya. Hal ini dapat berakibat terjadinya kesalahan penentuan harga jika karyawan supermarket salah mengingatnya. Dengan menggunakan buku kecil yang berisi gambar, kode dan harga dari setiap jenis buah dapat meminimalkan kesalahan penentuan harga. Namun membalik halaman dari buku itu setiap kali akan menimbang akan memakan waktu [2]. Oleh karena itu, penulis menyarankan untuk membuat sistem yang dapat mengenali atau mengklasifikasikan jenis buah secara otomatis melalui citra. Sehingga, diharapkan dapat membantu masyarakat dalam mengenali berbagai jenis buah secara otomatis. Dengan sistem tersebut, juga diharapkan dapat mempermudah proses penentuan harga buah.

Penelitian tentang pengenalan buah ini sebelumnya pernah dilakukan oleh beberapa peneliti. Pada tahun 2018, Edgar Utama dkk. melakukan penelitian identifikasi jenis mangga berdasarkan bentuk menggunakan fitur HOG dan jaringan syaraf tiruan. Pada penelitian ini, diperoleh hasil akurasi mencapai 90% [3]. Baculo juga pernah meneliti tentang pendeteksian buah mangga. Penelitian yang dilakukan oleh Baculo menggunakan metode HOG-SVM dan dapat mendeteksi citra mangga baik maupun cacat dengan latar berbeda dengan F-score 89,93% [4]. Penelitian Jana [5] tentang pengenalan buah dengan menggunakan fitur tekstur dan warna. Penelitian ini juga membandingkan sistem pengenalan buah dengan fitur tekstur saja, warna saja, dan menggunakan keduanya. Diperoleh akurasi 47.92% saat menggunakan warna saja, 80.20% saat menggunakan fitur tekstur dan 83.33% saat menggunakan kedua fitur. Xiaoyang Liu pernah melakukan penelitian tentang deteksi buah apel berdasarkan fitur warna dan bentuk. Penelitian ini, menggunakan metode ekstraksi fitur HOG dan klasifikasi SVM dengan rata-rata nilai *Recall*, *Precision*, dan F1 adalah 89,80%; 95,12%; dan 92,38% [6].

Penggunaan metode HOG cukup populer untuk mencirikan bentuk struktural dan penampilan objek, serta menghasilkan akurasi yang cukup tinggi. Namun selain menggunakan bentuk struktural, buah juga dapat dibedakan berdasarkan warna kulitnya. Sehingga, penulis memilih menggunakan gabungan metode HOG dan Histogram HSV untuk diterapkan pada sistem klasifikasi pengenalan buah yang akan dirancang. Buah yang akan diklasifikasikan adalah 131 jenis buah dari dataset Fruits-360 [7]. Klasifikasi yang digunakan adalah Random Forest. Klasifikasi Random Forest dinilai cocok untuk klasifikasi dengan dataset yang banyak [8].

Topik dan Batasannya

Berdasarkan latar belakang yang sudah dijelaskan sebelumnya maka rumusan masalah dari penelitian ini adalah bagaimana cara membangun sistem yang dapat mengenali berbagai jenis buah menggunakan metode ekstraksi fitur *Histogram of Oriented Gradient (HOG)* dan ekstraksi fitur warna HSV dengan klasifikasi menggunakan *Random Forest*, serta bagaimana kinerja sistem tersebut.

Adapun batasan masalah dari penelitian ini antara lain: data yang digunakan adalah citra training dan testing pada fruits-360 versi 5 dengan 131 kelas buah/sayur. Dalam satu citra hanya terdapat satu jenis buah/sayur dengan ukuran citra 100x100 piksel.

Tujuan

Tujuan dari penelitian ini adalah membangun sebuah sistem pengenalan citra buah menggunakan metode ekstraksi fitur *Histogram of Oriented Gradient (HOG)* dan fitur warna dari histogram HSV dengan klasifikasi menggunakan *Random Forest (RF)*, serta menganalisis hasil kerja dari sistem yang dibuat.

Organisasi Tulisan

Tulisan dari penelitian ini akan diatur sebagai berikut. Landasan teori yang berkaitan dengan penelitian yang telah dilakukan dijelaskan pada bagian kedua. Perancangan sistem dijelaskan pada bagian ketiga. Hasil dan analisis dari penelitian dibahas pada bagian keempat, dan kesimpulan dari penelitian ini dijelaskan pada bagian kelima.

2. Landasan Teori

2.1 Pemrosesan Citra Digital

Citra digital adalah citra yang terdiri dari banyak piksel, dengan setiap pikselnya merupakan nilai terbatas, dan berbentuk representasi angka numerik diskrit yang menunjukkan intensitasnya atau tingkat kecerahan. Citra digital merupakan keluaran dari fungsi 2-dimensi dengan masukan berupa koordinat spasial dengan notasi x , dan y pada masing-masing sumbu- x dan sumbu- y . [9]

Citra digital ataupun raster memiliki set dari nilai digital terbatas, yang disebut elemen gambar atau piksel. Citra digital berwarna umumnya terdiri dari beberapa channel, dengan contoh RGB, merupakan susunan piksel dengan warna *Red*, *Green*, dan *Blue* pada masing-masing *channel* yang ditumpuk menjadi satu sehingga membentuk beragam warna.

2.2 Pengenalan Pola

Sistem pengenalan adalah bidang penting dalam ilmu komputer yang berkaitan dengan pola pengenalan, terutama pola visual dan suara [10]. Pengenalan pola merupakan bidang dalam pembelajaran mesin dan dapat diartikan sebagai "tindakan mengambil data mentah dan bertindak berdasarkan klasifikasi data". Dengan demikian, ia merupakan himpunan kaidah bagi pembelajaran diselia (*supervised learning*). Ada beberapa definisi lain tentang pengenalan pola, di antaranya:

- Penentuan suatu objek fisik atau kejadian ke dalam salah satu atau beberapa kategori.
- Ilmu pengetahuan yang menitikberatkan pada deskripsi dan klasifikasi (pengenalan) dari suatu pengukuran.
- Suatu pengenalan secara otomatis suatu bentuk, sifat, keadaan, kondisi, susunan tanpa keikutsertaan manusia secara aktif dalam proses pemutusan.

Berdasar beberapa definisi di atas, pengenalan pola bisa didefinisikan sebagai cabang kecerdasan yang menitik beratkan pada metode pengklasifikasian objek ke dalam klas - klas tertentu untuk menyelesaikan masalah tertentu.[11]

2.3 Histogram of Oriented Gradient (HOG)

Histogram of Oriented Gradient (HOG) adalah sebuah metode yang digunakan dalam *image processing* dengan tujuan untuk mendeteksi objek. Teknik ini menghitung nilai gradien dalam daerah tertentu pada suatu citra. Tiap citra mempunyai karakteristik yang ditunjukkan oleh distribusi gradien. Karakteristik ini diperoleh dengan membagi citra ke dalam daerah kecil yang disebut *cell*. Tiap *cell* disusun sebuah histogram dari sebuah gradien. Kombinasi dari histogram ini dijadikan sebagai deskriptor yang mewakili sebuah objek. Tahapan dalam *Histogram of Oriented Gradient (HOG)*, antara lain [12]:

- 1) Menghitung gradien citra secara horizontal (G_H) dan vertikal (G_V) dengan *filtering* pada citra $[-1 \ 0 \ 1]$
- 2) Menghitung *magnitude* (N) dan orientasi (O) dari gradien:

$$N_{G(x,y)} = \sqrt{G_H(x,y)^2 + G_V(x,y)^2} \quad (1)$$

$$O_{G(x,y)} = \text{atan} \frac{G_H(x,y)}{G_V(x,y)} \quad (2)$$

- 3) Membagi citra ke dalam *cell*
- 4) Menghitung histogram pada tiap *cell*
- 5) Normalisasi semua histogram dalam satu blok

2.4 HSV

HSV merupakan ruang warna yang sangat cocok untuk mengidentifikasi warna-warna dasar, dimana warna dasar ini digunakan dalam penelitian sebagai warna identifikasi robot. Selain itu, HSV menoleransi terhadap perubahan intensitas cahaya. Inilah yang menjadi keunggulan HSV dibandingkan dengan ruang warna lainnya [13]. *Hue* adalah atribut yang menunjukkan warna yang mirip dengan salah satu warna yang dapat dilihat seperti merah, hijau, kuning, biru, ungu atau gabungan dua diantaranya. *Saturation* menyatakan tingkat kemurnian suatu warna, yaitu mengindikasikan seberapa banyak warna putih diberikan pada warna. Semakin kecil nilai *saturation* maka warna yang ditampilkan cenderung abu-abu. *Value* adalah mengukur intensitas dari cahaya yang sering disebut dengan *intensity* [14,15]. Untuk mendapatkan nilai H, S, dan V berdasarkan R, G, dan B, terdapat beberapa cara seperti yang dikemukakan oleh Acharya & Ray (2005) dengan rumus sebagai berikut [16].

$$r = \frac{R}{(R+G+B)}, \quad g = \frac{G}{(R+G+B)}, \quad b = \frac{B}{(R+G+B)} \quad (3)$$

$$V = \max(r, g, b) \quad (4)$$

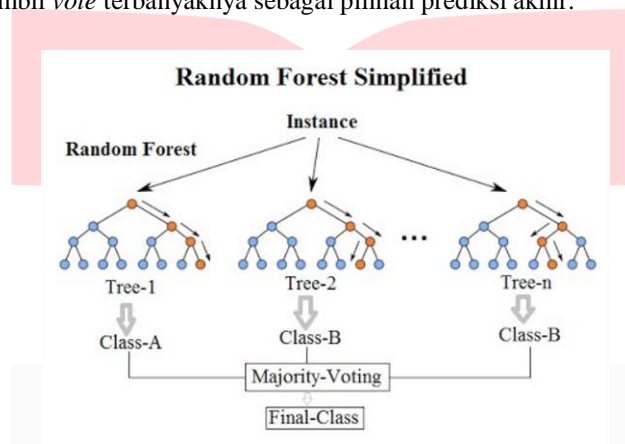
$$S = \begin{cases} 0, & \text{jika } V = 0 \\ 1 - \frac{\min(r,g,b)}{V}, & \text{jika } V > 0 \end{cases} \quad (5)$$

$$H = \begin{cases} 0, & \text{jika } S = 0 \\ 60 \times \frac{g-b}{S \times V}, & \text{jika } V = r \\ 60 \times [2 + \frac{b-r}{S \times V}], & \text{jika } V = g \\ 60 \times [4 + \frac{r-g}{S \times V}], & \text{jika } V = b \end{cases} \quad (6)$$

$$H = H + 360, \text{ jika } H < 0 \quad (7)$$

2.5 Random Forest (RF)

Random Forest merupakan salah satu pembelajaran mesin dengan jenis pembelajaran Supervised learning, yaitu metode pembelajaran yang membutuhkan data input dan data output untuk melatih pemodelan. Metode *random forest* ini dapat digunakan sebagai klasifikasi, regresi dari suatu masukan [17]. *Random forest* secara umum adalah pengembangan lebih lanjut dari *decision trees*. Pada Gambar 1 terlihat bahwa susunan dari *random forest* berisi lebih dari 1 *decision trees* dengan fungsi yang berbeda-beda, kemudian hasil dari masing-masing *decision trees* tersebut diambil *vote* terbanyaknya sebagai pilihan prediksi akhir.



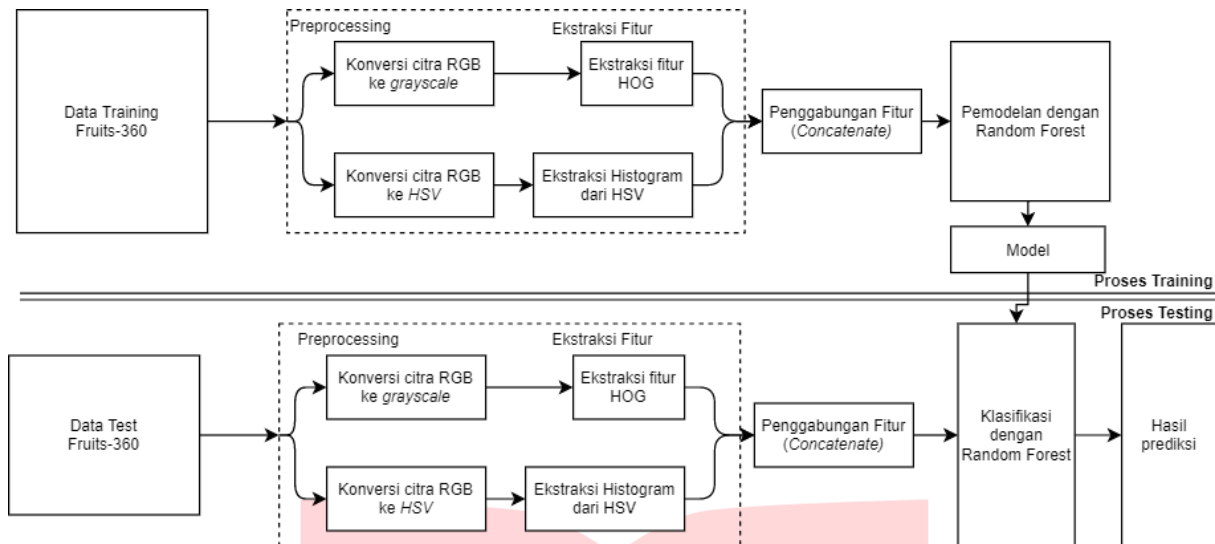
Gambar 1. Diagram *random forest*.

Jumlah fitur pada setiap *node* dan jumlah *tree* merupakan parameter yang ditetapkan oleh pengguna. Setiap *tree* dipengaruhi oleh strategi *out-of-bag* (*sampling* dengan penggantian) yang membuat sebagian fitur keluar dari sampel. Strategi ini memungkinkan *Random Forest* (RF) untuk melakukan estimasi kesalahan klasifikasi yang tidak bias dan untuk menghitung tingkat pentingnya fitur. Selama prediksi, kelas diperoleh dari setiap *decision tree* (skema pemungutan suara). Algoritma ini memilih klasifikasi yang memiliki suara terbanyak atas semua *tree* pada *forest*. *Random decision forest* memperbaiki kebiasaan *decision tree* yang *overfitting* terhadap data latih dan dapat mengatasi masalah klasifikasi multi-kelas dengan *dataset* yang tidak seimbang atau jumlahnya sedikit tanpa pra-pemrosesan [18].

Ada tiga aspek penting dalam metode *random forest*, yaitu: (1) melakukan *bootstrap sampling* untuk membangun *decision tree*; (2) masing-masing *decision tree* memprediksi dengan prediktor acak; (3) *random forest* melakukan prediksi dengan mengkombinasikan hasil dari setiap *decision tree* dengan cara *majority vote* untuk klasifikasi atau rata-rata untuk regresi [19].

3. Sistem yang dibangun

Sistem yang dibangun adalah sistem yang dapat mengenali jenis buah menggunakan HOG dan Histogram HSV. Tahapan yang dilakukan adalah *input data*, *preprocessing*, ekstraksi fitur dan tahap klasifikasi. Desain sistem yang akan dibangun dapat dilihat pada Gambar 2.



Gambar 2. Blok diagram sistem

Dataset

Dalam membangun sistem pengenalan buah, diperlukan banyak data *input* berupa citra dan data output berupa label sebagai media pembelajaran dari model yang akan digunakan. Untuk itu dataset yang digunakan merupakan dataset dengan jumlah yang banyak dan sudah terdapat label pada masing-masing citra. Pada penelitian ini, dataset yang digunakan adalah Fruits-360. Fruits-360 berisi total 90380 citra dengan ukuran citra 100x100 piksel berwarna. Citra tersebut memiliki 131 jenis buah/sayur. Dari keseluruhan citra yang ada, citra tersebut dibagi menjadi 67692 data *training*, dan 22688 data *testing*. Format citra yang digunakan adalah jpg.

Citra dari Fruits-360 diperoleh dari pengambilan citra buah/sayur yang masing-masing buah/sayur diputar dengan *low speed motor* dan mengambil foto pada setiap sudut tertentu. Dalam satu folder citra berisi satu buah/sayur yang diletakkan di atas kertas putih, dan diambil menggunakan kamera Logitech C920. Beberapa kutipan citra dari Fruits-360 ditampilkan pada Gambar 3 [20].



Gambar 3. Kutipan citra buah yang ada di dataset Fruits-360.

Pre-processing

Tahap pertama yang dilakukan pada citra masukan adalah *pre-processing*. Tahap *pre-processing* ini dilakukan dengan dua metode, yaitu konversi citra ke *grayscale* dan HSV.

1. Konversi citra RGB ke grayscale
 Konversi dari RGB ke *grayscale* dapat dilakukan dengan menggunakan rumus berikut pada masing-masing piksel citra [21]:

$$Y = 0.299 \cdot R + 0.587 \cdot G + 0.114 \cdot B \quad (8)$$

dengan Y adalah nilai intensitas keabuan, dan R, G, B masing-masing adalah nilai intensitas *channel red*, *green* dan *blue*. Proses ini dilakukan karena proses ekstraksi fitur HOG hanya dapat digunakan pada citra *grayscale* saja. Gambar 4 mengilustrasikan citra sebelum dan sesudah *pre-processing grayscale*.



Gambar 4. Apel braeburn sebelum *preprocessing* (a) dan setelah *preprocessing grayscale* (b)

2. Konversi citra RGB ke HSV

Proses ini dilakukan dengan menggunakan rumus (3, 4, 5, 6, 7) pada masing-masing piksel citra. Sehingga diperoleh citra HSV untuk kemudian digunakan pada ekstraksi fitur HSV. Citra hasil konversi ke HSV dapat dilihat pada Gambar 5.



Gambar 5. Apel Braeburn sebelum *pre-processing* (a) dan setelah dikonversi ke dalam HSV (b)

Ekstraksi fitur

Pada Gambar 2 dapat dilihat proses ekstraksi fitur dilakukan dengan dua metode, yaitu metode HOG untuk memperoleh fitur bentuk, dan fitur HSV untuk memperoleh fitur warna. Kedua fitur ini digunakan untuk memperoleh akurasi prediksi agar semakin tinggi. Berikut penjelasan setiap ekstraksi fitur pada subbab di bawah.

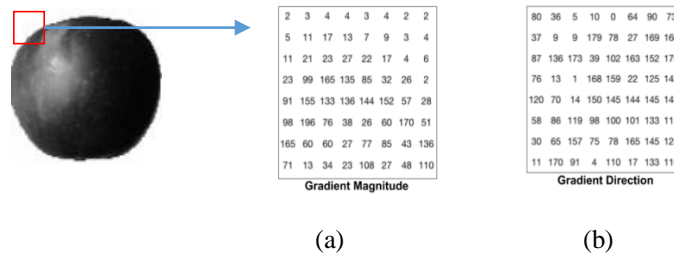
1. Ekstraksi fitur bentuk

Setelah mendapatkan citra *grayscale* seperti pada Gambar 4(b), citra tersebut selanjutnya diproses menggunakan HOG untuk mendapatkan bentuk fitur. Pada proses ini, sudah banyak *library* yang dapat langsung digunakan untuk memperoleh ekstraksi HOG dalam bentuk arah dan histogramnya. Pada *library scikit image* di Python, masukan yang diperlukan adalah *orientation* (jumlah orientasi), *pixel per cell* (ukuran piksel per sel), dan *cell per block* (jumlah sel dalam satu blok). Parameter yang diujikan pada proses ini dapat dilihat dalam tabel dibawah ini:

Tabel 1. Parameter HOG yang digunakan

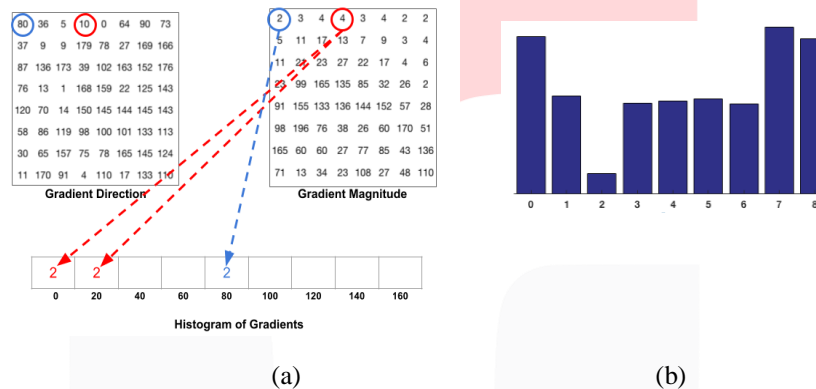
Jenis Parameter	Ukuran
Orientation	8,9
<i>Pixel per cell</i>	8x8, 10x10, 16x16, 20x20
<i>Cell per block</i>	1x1, 2x2

Citra grayscale akan difilter secara horizontal dan vertikal sehingga diperoleh gradient horizontal (G_H) dan vertikal (G_V). Setelah itu dihitung nilai magnitude dan orientation dari gradien dengan menggunakan rumus (1) dan (2).



Gambar 6. Ilustrasi hasil nilai magnitude (a) dan orientasi gradien (b)


Selanjutnya, citra dibagi ke dalam *cell*. Pada setiap *cell*, dihitung histogram dengan memasukkan *votes* nilai magnitude ke bins untuk setiap *orientation* kemudian dinormalisasi berdasarkan bloknya. Semua histogram pada tiap *cell* kemudian digabungkan menjadi satu histogram panjang.



Gambar 6. Ilustrasi proses voting (a) dan hasil histogram salah satu cell (b)

2. Ekstraksi fitur warna

Pada proses ekstraksi fitur HSV, nilai *hue*, *saturation*, dan *value* dari masing-masing piksel citra HSV dikelompokkan berdasarkan bin yang digunakan, lalu disimpan ke dalam satu histogram sebagai fitur seperti pada Gambar 7 di bawah ini. Pada histogram untuk HSV 32 bin, bin 0-31 menyimpan nilai histogram Hue, bin 32-63 menyimpan nilai histogram Saturation, dan bin 64-95 menyimpan nilai histogram Value dari HSV.



Gambar 7. Histogram HSV pada salah satu citra

Penggabungan Fitur

Setelah didapatkan fitur bentuk dan warna, kedua fitur tersebut digabungkan menjadi satu fitur yang berisi fitur bentuk dan warna. Sebagai contoh pada fitur tekstur (X) berdimensi 5, dan pada fitur bentuk (Y) berdimensi 4. Proses penggabungan fitur ini dapat dirumuskan sebagai berikut [22]

$$X = [x_1, x_2, x_3, x_4, x_5]$$

$$Y = [y_1, y_2, y_3, y_4]$$

$$XY = [X] + [Y] \rightarrow [x_1, x_2, x_3, x_4, x_5, y_1, y_2, y_3, y_4] \quad (9)$$

Sehingga diperoleh satu fitur baru yaitu fitur XY yang merupakan gabungan dari keduanya. Proses penggabungan fitur pada penelitian ini juga menggunakan rumus tersebut untuk mendapatkan satu fitur baru yang akan digunakan pada proses klasifikasi.

Klasifikasi

Kemudian dilakukan pelatihan data menggunakan *Random Forest Classifier* sehingga didapatkan model yang kemudian digunakan untuk memprediksi kelas pada data uji. Algoritma dari tahap pemodelan *Random Forest* adalah sebagai berikut.

Pseudocode Pemodelan Random Forest	
Input : fitur	
Output : tree	
	<ol style="list-style-type: none"> 1. Buat sampel bootstrap fitur dengan mengambil dari total fitur secara acak dengan pengembalian (replacement). 2. Gunakan bootstrap fitur untuk membangun decision tree ke-i (i=1, 2, ..., 100). 3. Ulangi langkah satu dan dua sampai 100 tree dibangun.

Sedangkan untuk proses klasifikasi *Random Forest* dapat dilihat dalam algoritma berikut.

Pseudocode Klasifikasi Random Forest	
Input : fitur	
Output : kelas	
	<ol style="list-style-type: none"> 1. Gunakan fitur data test pada setiap decision tree yang sudah dibangun secara random untuk mendapatkan kelas prediksi, dan simpan hasil kelas. 2. Hitung votes kelas untuk setiap tree. 3. Kelas dengan jumlah votes terbanyak akan menjadi hasil akhir dari algoritma <i>Random Forest</i>.

Kinerja Sistem

Kinerja pada sistem ini diukur dengan nilai akurasi yang didapatkan. Akurasi merupakan ukuran kedekatan antara prediksi dengan aktual. Perhitungan akurasi dalam sistem ini menggunakan rumus sebagai berikut

$$Akurasi = \frac{\text{jumlah data benar}}{\text{jumlah data keseluruhan}} \times 100\% \quad (10)$$

4. Hasil Pengujian dan Analisis

Dengan menggunakan dataset Fruits-360, dilakukan percobaan dengan menggunakan metode ekstraksi fitur yang berbeda. Hasil akurasi pengujian pada setiap metode yang digunakan dapat dilihat pada bagian Lampiran 1. Berikut hasil akurasi terbaik dari setiap metode yang digunakan.

Tabel 2. Hasil akurasi pada metode ekstraksi fitur yang berbeda

Metode Ekstraksi Fitur	Akurasi
HOG	85.40197%
HSV	98.11354%
HOG + Hue	95.97143%





HOG + Saturation	93.36654%
HOG + Value	92.55113%
HOG + HSV	98.11795%

Pada tabel 2 hasil akurasi yang paling rendah didapatkan saat menggunakan metode ekstraksi fitur HOG. Hal ini dikarenakan HOG mencirikan bentuk struktural objek. Pada dataset ini terdapat beberapa jenis buah yang memiliki bentuk struktural sama. Pada tabel ini diperlihatkan bahwa dengan menambahkan hasil ekstraksi fitur warna, ekstraksi fitur HOG dapat meningkat. Hasil akurasi terbaik didapatkan saat menggunakan ekstraksi fitur HOG + HSV dan selisih sedikit dengan saat menggunakan HSV, dengan akurasi 98.11795%. Hal ini menunjukkan sistem pengenalan jenis buah citra paling baik saat menggunakan fitur bentuk dan warna (HOG dan HSV).

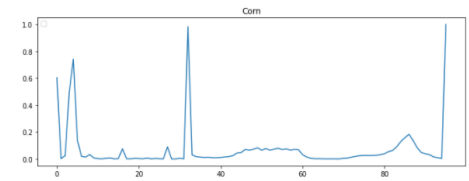
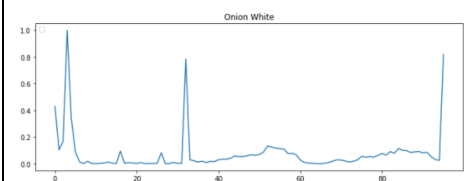
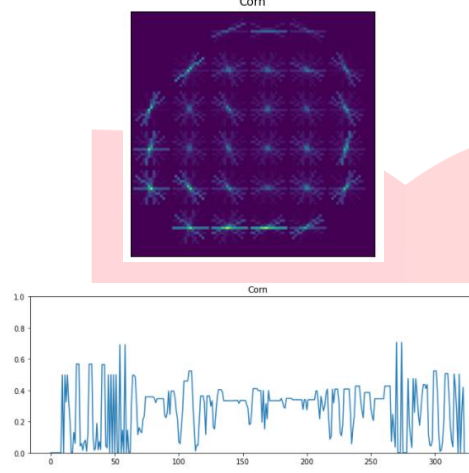
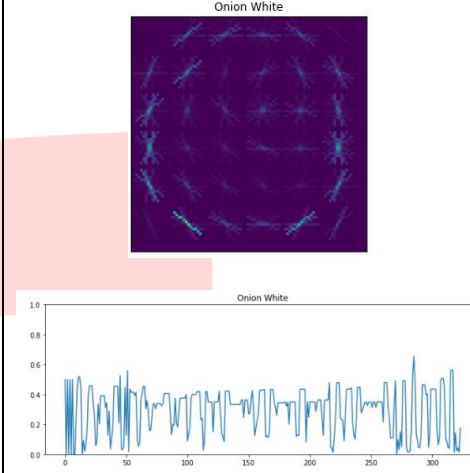
Meskipun dengan metode HOG + HSV yang menghasilkan akurasi terbaik pada penelitian ini, masih terdapat beberapa kelas yang salah prediksi. Hasil akurasi pada setiap kelas buah dapat dilihat pada bagian Lampiran 2. Kelas yang paling banyak salah diklasifikasi adalah kelas Corn, dengan akurasi 49.33%. Kelas lainnya dengan akurasi dibawah 90% antara lain kelas Apple Braeburn (82.33%), Apple Crimson Snow (74.33%), Banana Red (89.16%), Corn Husk (71.43%), Eggplant (74.36%), Peach (78.66%), Pear 2 (83.62%), Potato Red Washed (80.79%), dan Potato Sweet (82%).

Pada tabel 3 ditunjukkan beberapa sampel kelas yang salah prediksi saat menggunakan metode HOG+HSV. Tabel 4 menampilkan masing-masing fitur dari salah satu sampel kelas yang salah prediksi, yaitu kelas Corn dan kelas Onion White. Pada tabel ini ditunjukkan adanya kemiripan fitur pada kelas Corn dan Onion White. Hal inilah yang menyebabkan terjadinya salah prediksi saat dilakukan klasifikasi.

Tabel 3. Sampel data salah prediksi saat menggunakan HOG + HSV

Citra kelas sebenarnya	Kelas Sebenarnya	Prediksi	Citra kelas prediksi
	Apple Braeburn	Apple Red 2	
	Apple Crimson Snow	Apple Pink Lady	
	Corn	Onion White	
	Eggplant	Pear Stone	
	Peach	Grape Pink	

Tabel 4. Perbedaan fitur pada kelas Corn dan Onion White

Fitur	Corn	Onion White
HSV		
HOG		

5. Kesimpulan

Berdasarkan penelitian ini, kinerja sistem pengenalan buah dengan HOG dapat ditingkatkan dengan menambahkan fitur warna. Hasil penelitian ini menunjukkan akurasi sistem pengenalan buah dari dataset Fruits-360 dengan menggunakan ekstraksi fitur HOG 85.40197%, HSV 98.11354%, HOG + Hue 95.97143%, HOG + Saturation 93.36654%, HOG + Value 92.55113%, HOG + HSV 98.11795%. Sehingga didapatkan bahwa ekstraksi fitur terbaik dalam penelitian ini untuk sistem pengenalan buah Fruits-360 adalah menggunakan HOG + Histogram HSV

Reference

- [1] E. K. Ratnasari dan A. Wikaningrum. 2016. "Pengenalan Jenis Buah pada Citra Menggunakan Pendekatan Klasifikasi Berdasarkan Fitur Warna Lab dan Tekstur Co-Occurrence," *Jurnal INFORM*, vol. 1, no. 2, pp. 88-97.
- [2] I. Hussain, Q. He dan Z. Chen. 2018. "AUTOMATIC FRUIT RECOGNITION BASED ON DCNN FOR COMMERCIAL SOURCE TRACE SYSTEM," *International Journal on Computational Science & Applications (IJCSA)*, vol. 8, no. 2/3, pp. 1-14.
- [3] E. Utama, F. Yapputra dan G. 2018. "Identifikasi Jenis Mangga Berdasarkan Bentuk Menggunakan Fitur HOG dan Jaringan Syaraf Tiruan," *JURNAL ILMIAH INFORMATIKA GLOBAL*, vol. 9, no. 1, pp. 1-6.
- [4] M. J. C. Baculo dan N. Marcos. 2018. "Automatic Mango Detection using Image Processing and HOG-SVM," in *International Conference on Network, Communication and Computing VII*, Taipei.
- [5] B. J. Samajpati dan S. D. Degadwala. 2016. "Hybrid approach for apple fruit diseases detection and classification using random forest classifier," *Int. Conf. Commun. Signal Process. ICCSP 2016*, pp. 1015–1019.
- [6] X. Liu, D. Zhao, W. Jia, W. Ji and Y. Sun. 2019. "A Detection Method for Apple Fruits Based on Color and Shape Features," *IEEE Access*, vol. 7, pp. 67923-67933.
- [7] M. Oltean, "Fruits 360 dataset: A dataset of images containing fruits and vegetables," Kaggle, 2020. [Online]. Available: <https://www.kaggle.com/moltean/fruits>. Version: 2020.05.18.0 [Diakses pada 17 Juli 2020].
- [8] B. J. Samajpati dan S. D. Degadwala. 2016. "Hybrid approach for apple fruit diseases detection and classification using random forest classifier," *Int. Conf. Commun. Signal Process. ICCSP 2016*, pp. 1015–1019.
- [9] Gonzalez, Rafael (2018). *Digital image processing*. New York, NY: Pearson. ISBN 978-0-13-335672-4. OCLC 966609831.
- [10] Woo Chaw Seng and S. H. Mirisae, "A new method for fruits recognition system," 2009 International Conference on Electrical Engineering and Informatics, Selangor, 2009, pp. 130-134, doi: 10.1109/ICEEL.2009.5254804.
- [11] https://id.wikipedia.org/wiki/Pengenalan_pola (diakses tanggal 2 Desember 2021)
- [12] M. Bertozzi, A. Broggi, M. Del Rose, M. Felisa, A. Rakotomamonjy and F. Suard. 2007. "A Pedestrian Detector Using Histograms of Oriented Gradients and a Support Vector Machine Classifier," 2007 IEEE Intelligent Transportation Systems Conference, Seattle, WA, pp. 143-148, doi: 10.1109/ITSC.2007.4357692.
- [13] Nur Khamdi, Muhammad Susantok, Piter Leopard. 2019. "PENDETEKSIAN OBJEK BOLA DENGAN METODE COLOR FILTERING HSV PADA ROBOT SOCCER HUMANOID", *Jurnal SISFOKOM*, vol. 08, no 01
- [14] Marko. 2003. "Colour spaces - perceptual, historical and applicational background," University of Ljubljana,
- [15] Fairchild, Mark D. 2005. *Color Appearance Models* (2nd ed.). Addison-Wesley
- [16] Acharaya, T., & Ray, A. K. 2005. *Image Processing Principles and Application*. New Jersey: A John Wiley & Sons.
- [17] Ho, Tin Kam. 1995. *Random Decision Forests*. Proceedings of the 3rd International Conference on Document Analysis and Recognition, Montreal, QC, 14–16 Agustus 1995. hlm. 278–282
- [18] F. S. L. Pereira, S. B. Jr, N. A. Valous dan D. F. Barbin. 2018. "Predicting the ripening of papaya fruit with digital imaging and random forests," *Computers and Electronics in Agriculture*, vol. 145, pp. 76-82.
- [19] A. Primajaya dan B. N. Sari. 2018. "Random Forest Algorithm for Prediction of Precipitation," *Indonesian Journal of Artificial Intelligence and Data Mining (IJAIMD)*, vol. 1, no. 1, pp. 27-31.
- [20] Horea Muresan, Mihai Oltean. 2018. Fruit recognition from images using deep learning, *Acta Univ. Sapientiae, Informatica* Vol. 10, Issue 1, pp. 26-42.
- [21] https://docs.opencv.org/3.4/de/d25/imgproc_color_conversions.html (diakses pada 30 November 2020)
- [22] Firdaus, F., Rachmawati, E., & Sthevanie, F. 2020. Hybrid Approach for Fruit Recognition in High Data Variance.

LAMPIRAN

Lampiran 1. Tabel Pengujian pada Metode Berbeda

Tabel 5. Hasil Pengujian Metode HOG

Pixel per cell	Cell per block	orientation	Akurasi (%)
8	1	8	77.83
8	2	9	80.2671
10	1	8	78.4952
10	1	9	78.75088152
10	2	9	82.92930183
10	3	9	83.52873765
16	1	8	80.97232017
16	1	8	81.02521157
16	1	9	81.421897
20	2	9	85.401974

Tabel 6. Hasil Pengujian Metode HSV

Jumlah Bin	Akurasi (%)
10	97.5052
16	97.769
20	97.9813
24	97.77874
25	97.80941
26	97.75212
29	97.92842
30	98.11354
31	97.95927
32	97.778
35	97.94164

Tabel 7. Hasil Pengujian Metode HOG+Hue

Pixel per cell	Cell per block	Orientation	Jumlah bin HSV	Akurasi (%)
8	1	8	32	91.12
10	1	9	32	94.18635
10	1	8	32	95.87888
16	1	8	32	95.84362
16	1	9	30	95.64528
20	2	9	30	95.52186
20	2	9	32	95.97144

Tabel 8. Hasil Pengujian Metode HOG+Saturation

Pixel per cell	Cell per block	Orientation	Jumlah bin HSV	Akurasi (%)
8	1	8	32	83.38
10	1	8	32	90.51040197
10	2	9	10	89.8184
10	2	9	30	91.08779972
16	1	8	32	92.11
16	1	8	32	81.1442172
16	1	9	32	91.72690409
20	1	9	32	92.31311707
20	2	9	30	93.36653738
20	2	9	32	92.9962976

Tabel 9. Hasil Pengujian dengan Metode HOG+Value

Pixel per cell	Cell per block	Orientation	Jumlah bin HSV	Akurasi (%)
8	1	8	32	90.04
8	1	8	32	89.99471086
10	1	8	32	91.3744
10	1	9	10	89.8448519
16	1	8	30	92.36600846
20	2	9	32	92.47619887
20	2	9	30	92.55112835

Tabel 10. Hasil Pengujian dengan Metode HOG+HSV

Pixel per cell	Cell per block	Orientation	Jumlah bin HSV	Akurasi (%)
8	1	8	32	96.74
8	1	9	32	96.69
8	2	8	32	95.53
8	2	9	32	95.46
16	1	8	30	98.10032
16	1	8	32	98.07
16	1	9	32	97.9989
16	1	9	32	98.11795
16	2	8	32	97.306
16	2	9	32	97.28
20	2	9	30	97.99013

Lampiran 2. Hasil Pengujian dengan Metode HOG+HSV pada setiap kelas

Tabel 11. Akurasi pada masing-masing kelas

Kelas	Total citra	TRUE	FALSE	Akurasi (%)
Apple Braeburn	164	135	29	82.31707
Apple Crimson Snow	148	110	38	74.32432
Apple Golden 1	160	156	4	97.5
Apple Golden 2	164	164	0	100
Apple Golden 3	161	161	0	100
Apple Granny Smith	164	164	0	100
Apple Pink Lady	152	152	0	100
Apple Red 1	164	162	2	98.78049
Apple Red 2	164	163	1	99.39024
Apple Red 3	144	144	0	100
Apple Red Delicious	166	166	0	100
Apple Red Yellow 1	164	164	0	100
Apple Red Yellow 2	219	219	0	100
Apricot	164	164	0	100
Avocado	143	143	0	100
Avocado ripe	166	166	0	100
Banana	166	166	0	100
Banana Lady Finger	152	152	0	100
Banana Red	166	148	18	89.15663
Beetroot	150	150	0	100
Blueberry	154	154	0	100
Cactus fruit	166	166	0	100
Cantaloupe 1	164	164	0	100
Cantaloupe 2	164	164	0	100
Carambula	166	164	2	98.79518
Cauliflower	234	234	0	100
Cherry 1	164	164	0	100
Cherry 2	246	246	0	100
Cherry Rainier	246	246	0	100
Cherry Wax Black	164	164	0	100
Cherry Wax Red	164	164	0	100
Cherry Wax Yellow	164	164	0	100
Chestnut	153	153	0	100
Clementine	166	166	0	100
Cocos	166	166	0	100
Corn	150	74	76	49.33333
Corn Husk	154	110	44	71.42857
Cucumber Ripe	130	130	0	100
Cucumber Ripe 2	156	156	0	100
Dates	166	166	0	100
Eggplant	156	116	40	74.35897

Fig	234	234	0	100
Ginger Root	99	99	0	100
Granadilla	166	166	0	100
Grape Blue	328	328	0	100
Grape Pink	164	164	0	100
Grape White	166	166	0	100
Grape White 2	166	166	0	100
Grape White 3	164	164	0	100
Grape White 4	158	158	0	100
Grapefruit Pink	166	166	0	100
Grapefruit White	164	164	0	100
Guava	166	166	0	100
Hazelnut	157	157	0	100
Huckleberry	166	166	0	100
Kaki	166	165	1	99.39759
Kiwi	156	156	0	100
Kohlrabi	157	157	0	100
Kumquats	166	166	0	100
Lemon	164	164	0	100
Lemon Meyer	166	166	0	100
Limes	166	166	0	100
Lychee	166	166	0	100
Mandarine	166	166	0	100
Mango	166	166	0	100
Mango Red	142	142	0	100
Mangostan	102	102	0	100
Maracuja	166	166	0	100
Melon Piel de Sapo	246	246	0	100
Mulberry	164	164	0	100
Nectarine	164	160	4	97.56098
Nectarine Flat	160	160	0	100
Nut Forest	218	218	0	100
Nut Pecan	178	175	3	98.31461
Onion Red	150	150	0	100
Onion Red Peeled	155	155	0	100
Onion White	146	146	0	100
Orange	160	160	0	100
Papaya	164	164	0	100
Passion Fruit	166	166	0	100
Peach	164	129	35	78.65854
Peach 2	246	246	0	100
Peach Flat	164	164	0	100
Pear	164	164	0	100
Pear 2	232	194	38	83.62069
Pear Abate	166	166	0	100

Pear Forelle	234	234	0	100
Pear Kaiser	102	102	0	100
Pear Monster	166	163	3	98.19277
Pear Red	222	222	0	100
Pear Stone	237	237	0	100
Pear Williams	166	166	0	100
Pepino	166	166	0	100
Pepper Green	148	148	0	100
Pepper Orange	234	231	3	98.71795
Pepper Red	222	222	0	100
Pepper Yellow	222	222	0	100
Physalis	164	164	0	100
Physalis with Husk	164	158	6	96.34146
Pineapple	166	166	0	100
Pineapple Mini	163	163	0	100
Pitahaya Red	166	166	0	100
Plum	151	151	0	100
Plum 2	142	142	0	100
Plum 3	304	304	0	100
Pomegranate	164	151	13	92.07317
Pomelo Sweetie	153	153	0	100
Potato Red	150	145	5	96.66667
Potato Red Washed	151	122	29	80.7947
Potato Sweet	150	123	27	82
Potato White	150	148	2	98.66667
Quince	166	166	0	100
Rambutan	164	164	0	100
Raspberry	166	166	0	100
Redcurrant	164	164	0	100
Salak	162	162	0	100
Strawberry	164	163	1	99.39024
Strawberry Wedge	246	243	3	98.78049
Tamarillo	166	166	0	100
Tangelo	166	166	0	100
Tomato 1	246	246	0	100
Tomato 2	225	225	0	100
Tomato 3	246	246	0	100
Tomato 4	160	160	0	100
Tomato Cherry Red	164	164	0	100
Tomato Heart	228	228	0	100
Tomato Maroon	127	127	0	100
Tomato Yellow	153	153	0	100
Tomato not Ripened	158	158	0	100
Walnut	249	249	0	100
Watermelon	157	157	0	100