

Sistem Pendeteksi Kerusakan Buah Mangga Menggunakan Sensor Gas Dengan Metode DCS - LCA

(Mango Damage Detection System Using Gas Sensor With DCS - LCA Method)

Murad^[1], Sukmawaty^[2], Ansar^[3], Rahmat Sabani^[4], Syahroni Hidayat^{[5]*}

^{[1]-[5]}Program Studi Teknik Pertanian, Universitas Mataram

^[5]Lembaga Pengembangan Ilmu Pengetahuan dan Teknologi, Sekawan Institute

E-mail: muradfatepa@unram.ac.id, Sukmawaty14@unram.ac.id, Ansar72@unram.ac.id,
rahmat.sabani@unram.ac.id, syahronihidayat@unram.ac.id

KEYWORDS:

Mango, Gas Sensor, Ensemble learning, Dynamic Classifier Selection (DCS), Local Class Accuracy (LCA)

ABSTRACT

Fruits, including mangoes, produce a wide variety of volatile organic compounds that give them their distinct aroma. Characteristics of fruit aroma is one of the important keys in determining consumer acceptance in the commercial fruit market based on individual preferences. So a possible way to determine the level of ripeness/damage is to feel the distinctive aroma presented by the fruit using a gas sensor. This study aims to build a system that can detect mango damage based on its aroma. The sensors used are TGS 2600, MQ3, MQ4, MQ2, and MQ8 which are connected to the Arduino Mega 2560. The learning model used is an ensemble learning model of Dynamic Classifier Selection (DCS) with Local Class Accuracy (LCA)/DCS-LCA. This algorithm combines Logistic Regression, Selection Tree, Support Vector Machine (SVM), Naïve Bayes, Random Forest, and Neural Networks. The model was then tested with a comparison of the amount of test data and training data of 70%:30%. The test results showed that the overall system Accuracy was 75% and the ability to detect mango fruit damage was 71%. The DCS-LCA classifier model outperforms each of its constituent base classifiers.

KATA KUNCI:

Mangga, Sensor Gas, Ensemble learning, Dynamic Classifier Selection (DCS), Local Class Accuracy (LCA)

ABSTRAK

Buah-buahan, termasuk mangga, menghasilkan berbagai macam senyawa organik yang mudah menguap yang memberikan aroma khas yang berbeda. Karakteristik aroma buah merupakan salah satu kunci penting dalam menentukan penerimaan konsumen di pasar buah komersial berdasarkan preferensi individu. Oleh karena itu, cara yang mungkin untuk menentukan tingkat kematangan/kerusakan adalah dengan merasakan aroma khas yang disajikan oleh buah menggunakan sensor gas. Penelitian ini bertujuan untuk membangun sistem yang dapat mendeteksi kerusakan buah mangga berdasarkan aromanya. Sensor yang digunakan adalah TGS 2600, MQ3, MQ4, MQ2, dan MQ8 yang dikoneksikan dengan Arduino Mega 2560. Model pembelajaran yang digunakan adalah model ensemble learning Dynamic Classifier Selection (DCS) dengan Local Class Accuracy (LCA)/DCS-LCA. Algoritma ini menggabungkan Regresi Logistik, Pohon Pemilihan, Support Vector Machine (SVM), Naïve Bayes, Random Forest, dan Jaringan Syaraf Tiruan. Model kemudian diuji dengan perbandingan jumlah data uji dan data latih sebesar 70%:30%. Hasil pengujian menunjukkan akurasi sistem secara keseluruhan 75% dan kemampuan mendeteksi kerusakan buah mangga mencapai 71%. Model pengklasifikasi DCS-LCA mengungguli performa masing-masing pengklasifikasi dasar pembentuknya.

I. PENDAHULUAN

Persepsi konsumen dalam menilai kualitas buah didasarkan pada karakteristik seperti daya tarik visual (kurang noda, warna, ukuran, dan tekstur), kematangan, aroma, dan rasa. Kualitas buah akan berubah seiring bertambahnya waktu, mulai dari pra

panen hingga pasca panen, tahap saat buah tumbuh dan matang, dan selama pemeliharaan dalam penyimpanan [1]. Kondisi ini disebut penuaan (*Senescence*) pada buah. Penuaan pada buah mengacu pada tahap pertumbuhan di mana tanaman melebihi puncak kematangan dan memulai fase

ireversibel dari kerusakan yang pada akhirnya akan menyebabkan kematian. Selama tahap ini, sel-sel rusak dan buah kehilangan banyak karakteristik yang membuatnya menarik [2]. Penuaan buah-buahan dikaitkan dengan emisi berbagai jenis gas seperti etilen. Dengan demikian, pemantauan penuaan berdasarkan aroma dapat memberikan indikasi kesegaran penting buah-buahan [3].

Aroma buah seringkali menjadi karakteristik paling berharga yang menentukan kualitas buah dan pilihan konsumen karena aroma biasanya merupakan indikator terbaik dari rasa buah [4]. Oleh karena itu, estimasi kematangan merupakan bagian penting dari penentuan kualitas karena kematangan saat panen dapat mempengaruhi sifat sensorik dan penyimpanan buah. Cara yang mungkin untuk menentukan tingkat kematangan adalah merasakan volatil aromatik yang dilepaskan oleh buah menggunakan hidung elektronik (*e-nose*) [5].

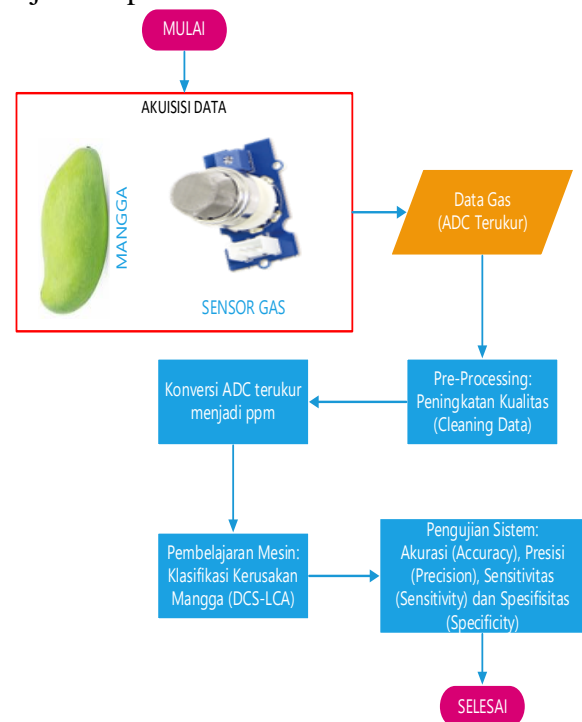
E-nose berisi susunan sensor yang mengevaluasi semua konstituen kimia yang ada dalam campuran aroma (sebagai keseluruhan sampel) dan menutupi sinyal keluaran elektronik (melalui transduser) dari semua sensor dalam susunan dan secara kolektif merakitnya untuk membentuk pola digital yang berbeda, kadang-kadang disebut sebagai *Electronic Aroma Signature Pattern* (EASP) yang sangat unik dan spesifik untuk campuran gas tertentu yang dianalisis [1]. Pengembangan hidung elektronik (*e-nose*) sudah banyak dilakukan terutama untuk mendeteksi kualitas buah mangga berdasarkan gas yang dihasilkannya [1]. Dari penelitian-penelitian tersebut sensor gas yang digunakan bervariasi, seperti sensor gas etilen [4] dan sensor gas tipe MQ dan TGS [5].

Sistem *e-nose* dikembangkan dengan algoritma pembelajaran mesin khusus pengklasifikasi, seperti jaringan saraf tiruan (JST), *Principal Component Analysis* (PCA), dan analisis diskriminan linier (LDA) [5]. Selain itu terdapat banyak metode pembelajaran mesin lain yang digunakan untuk klasifikasi dalam bidang pertanian misalnya Regresi Linier, Regresi Logistik, Pohon Pemilihan (*Decision Tree*), *Support Vector Machine* (SVM), Naïve Bayes, *K Nearest Neighbor* (KNN), dan *Random Forest* [6]. Akan tetapi, penerapan metode-metode pembelajaran tersebut dalam pengembangan *e-nose* untuk deteksi kualitas buah lebih dititikberatkan pada pemanfaatannya secara terpisah dan mandiri. Oleh karena itu, perlu dilakukan pengembangan

sistem *e-nose* yang menggunakan multi pengklasifikasi (*multi-classifier*) secara bersamaan. Penggunaan multi pengklasifikasi baik secara teori maupun penerapan terbukti memiliki performa yang lebih baik daripada menggunakan hanya pengklasifikasi sebuah pengklasifikasi [7], [8]. Teknik multi pengklasifikasi yang dapat diterapkan adalah *Ensemble learning*. Tujuan penelitian ini adalah menerapkan metode *Ensemble learning* untuk mengembangkan sebuah sistem yang dapat mendeteksi kerusakan buah menggunakan sensor gas. Buah yang digunakan pada penelitian ini adalah buah mangga dengan pilihan sensor gas tipe MQ dan TGS.

II. METODOLOGI

Pada penelitian ini pengembangan sistem pendeteksi kerusakan berbasis gas dimulai dari proses perekaman data gas buah mangga. Data gas yang terekam kemudian dibersihkan. Selanjutnya dilakukan konversi terhadap data tersebut dari nilai ADC terukur menjadi nilai ppm (*parts per million*) gas. Nilai ppm ini kemudian digunakan dalam proses pembelajaran untuk membentuk model pendeteksi kerusakan buah mangga. Model yang terbentuk dari hasil pembelajaran kemudian diuji untuk diperoleh performansinya. Singkatnya tahapan penelitian ini ditunjukkan pada Gbr. 1.



Gbr. 1 Alur Penelitian Pengembangan Sistem Pendeteksi Kerusakan Buah Mangga

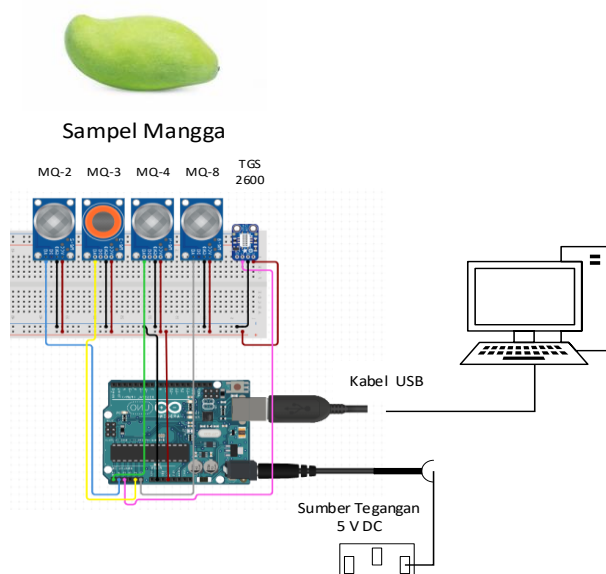
A. Dataset Gas

Proses pembuatan dataset gas menggunakan alat dan bahan seperti dijelaskan pada Tabel I. Peralatan terdiri dari lima buah sensor, yaitu Tgs 2600, MQ3, MQ4, MQ2, dan MQ8, sebuah mikrokontroler Arduino Mega 2560, dan sumber tegangan dengan keluaran 5V dc.

TABEL I
ALAT PENELITIAN

No	Alat dan Bahan	Jumlah	Spesifikasi/Jenis
1	Sensor Gas:		
	TGS 2600	1	1 ~ 30 ppm
	MQ3	1	25 to 500 ppm
	MQ4	1	300~10000 ppm
	MQ2	1	300~10000 ppm
	MQ8	1	100~1000 ppm
2	Arduino	1	Mega 2560
3	Sumber Tegangan	1	5V DC
4	Buah Mangga	40	Mangga mengkal

Data gas buah mangga direkam menggunakan sensor-sensor gas yang terhubung dengan Arduino Mega 2560 dan sumber tegangan seperti ditunjukkan pada Gbr. 2. Perakitan alat mengikuti arsitektur sistem yang telah dimodifikasi dari penerapan sensor gas untuk monitoring *green house* [9]. Digunakan wadah yang sudah dimodifikasi sebagai tempat meletakkan sensor dan sampel buah mangga. Saat terisi wadah ini ditujukan sebagai perangkat gas yang dihasilkan oleh buah mangga dan ketika kosong untuk memastikan bahwa sebelum digunakan kembali sensor hanya mengukur udara bersih.



Gbr. 2 Skema Alat Penelitian Dengan Lima Sensor Gas

Kegiatan perekaman data diawali dengan menentukan nilai set poin sensor gas. Nilai set poin ini direkam ketika sensor gas mengukur udara bersih di dalam wadah kosong. Pengukuran dan perekaman data set poin dilakukan selama 5 menit. Dari total 5 menit waktu pengukuran ini diambil data selama 1 menit (dalam kondisi *steady state*) untuk dijadikan sebagai nilai rata-rata set poin untuk setiap sensor gas. Hasil pembentukan data set poin setiap sensor ditunjukkan pada Tabel II.

TABEL II
NILAI RATA-RATA SET POIN SENSOR GAS

Variabel	Nama Sensor				
	TGS 2600	MQ3	MQ4	MQ2	MQ8
Nilai rata-rata ADC terukur	70	120	190	200	95

Selanjutnya dilakukan perekaman data gas yang dihasilkan buah mangga. Proses ini dilakukan selama 7 hari berturut-turut masa penyimpanan buah mangga di ruang terbuka. Setiap sampel buah mangga diukur gasnya selama ± 3 menit. Hasil perekaman gas berupa nilai ADC. Proses pengukuran data gas buah mangga menggunakan sebuah komputer desktop untuk menjalankan program pengambilan data dan menyimpan hasilnya. Aplikasi Arduino IDE digunakan untuk membangun dan mengeksekusi koding program. Adapun untuk menyimpan log setiap sesi perekaman digunakan perangkat lunak PuTTY. Dengan PuTTY *log file* perekaman dapat disimpan dalam format *.csv.

Contoh *log file* perekaman data gas buah mangga ditunjukkan pada Tabel III. Dapat dilihat dari data raw tersebut terdapat data yang rusak. Kerusakan pada hasil perekaman data ini berupa terpotongnya data yang terekam atau hasil pengukuran sensor bernilai nol semua. Kondisi ini mengharuskan adanya proses pembersihan (*cleaning*) data.

TABEL III
LOG DATA PENGUKURAN GAS BUAH MANGGA SAMPEL KE 35
HARI KE 7

No	==~==~ PuTTY log 2021.09.30 21:21:38 ==~==~
1	222 MQ-8= 85
2	8= 84
3	TGS2600= 95 MQ-3= 310 MQ-4= 218 MQ-2= 222 MQ-8= 84
4	TGS2600= 95 MQ-3= 311 MQ-4= 220 MQ-2= 222 MQ-8= 85
5	8= 84

No	===== PuTTY log 2021.09.30 21:21:38 =====
6	TGS2600= 95 MQ-3= 310 MQ-4= 218 MQ-2= 222 MQ-8= 84
7	TGS2600= 95 MQ-3= 311 MQ-4= 220 MQ-2= 222 MQ-8= 85
8	TGS2600= 95 MQ-3= 313 MQ-4= 223 MQ-2= 224 MQ-8= 88
.	...
.	...
.	...
302	TGS2600= 116 MQ-3= 348 MQ-4= 284 MQ-2= 240 MQ-8= 132
303	TGS2600= 116 MQ-3= 349 MQ-4= 285 MQ-2= 241 MQ-8= 133
304	TGS2600= 116 MQ-3= 345 MQ-4= 281 MQ-2= 239 MQ-8= 132
305	TGS2600= 116 MQ-3= 345 MQ-4= 281 MQ-2= 240 MQ-8= 131
306	TGS2600= 0 MQ-3= 0 MQ-4= 0 MQ-2= 0 MQ-8= 0
307	TGS2600= 0 MQ-3= 0 MQ-4= 0 MQ-2= 0 MQ-8= 0
308	TGS2600= 0 MQ-3= 0 MQ-4= 0 MQ-2= 0 MQ-8= 0
309	TGS2600= 0 MQ-3= 0 MQ-4= 0 MQ-2= 0 MQ-8= 0

Di hari ke-8 dilakukan uji lab untuk menentukan kondisi buah mangga setelah 7 hari masa penyimpanan. Mangga dikupan untuk menentukan termasuk kondisi normal (1) atau rusak (0). Dari hasil uji lab diperoleh sebanyak 19 buah dalam kondisi normal (1) dan sisanya 21 buah dalam kondisi rusak (0). Tingkat kerusakan buah mangga ini bermula dari kulit hingga mencapai ke daging buah.

B. Pembersihan Data


Perlunya pembersihan data didasarkan pada kondisi perekaman data dengan hasil yang masih salah seperti ditunjukkan pada Tabel III. Proses ini diawali dari pembacaan data, kemudian membagi-bagi sehingga hanya nilai ADC terukur dari setiap sensor yang tersisa. Luaran yang dihasilkan berupa tabel baru berukuran M x N dengan M menyatakan jumlah baris data dan N menyatakan jumlah kolom sebanyak lima sesuai jumlah sensor yang digunakan yaitu tgs26, mq3, mq4, mq2, dan mq8. Contoh data hasil pembersihan data ditunjukkan pada Tabel IV.

Grafik data ADC terukur setelah dilakukan pembersihan ditunjukkan pada Gbr 3. Dapat dilihat bahwa data yang terukur menunjukkan adanya peningkatan data ADC terukur kemudian setelah beberapa saat data ADC terukur masuk dalam kondisi *steady state*. Selain itu, grafik juga menunjukkan bahwa nilai awal ADC terukur untuk seluruh sensor tidak bermula di titik 0. Sehingga

dibutuhkan proses konversi data dan normalisasi nilai minimumnya.

TABEL IV
DATA PENGUKURAN ADC HASIL PEMBERSIHAN

Index	tgs26	mq3	mq4	mq2	mq8
1	96	271	277	199	166
2	98	302	312	200	208
3	96	271	277	199	166
4	98	302	312	200	208
.
.
.
314	260	512	549	284	390
315	259	507	548	283	389
316	259	506	547	284	390
317	260	507	551	284	392



Gbr. 3 Grafik Pengukuran Adc Terukur Hasil Pembersihan

C. Normalisasi dan Konversi Data

Normalisasi bertujuan untuk membuat nilai awal setiap sensor yang terukur bernilai 0. Normalisasi dilakukan dengan mengurangi seluruh nilai ADC terukur dengan nilai set poin menggunakan Persamaan (1). Kemudian hasil perhitungan Persamaan (1) dikurangi oleh nilai minimumnya sendiri menggunakan Persamaan (2).

$$dADC = ADC_t - SP_{ssr} \quad (1)$$

$$\Delta ADC = dADC - \min(dADC) \quad (2)$$

Konversi data dilakukan untuk mendapatkan nilai ppm dari setiap nilai ADC terukur. Data yang dibutuhkan untuk melakukan konversi adalah data

range pengukuran setiap sensor, set poin, nilai ADC terukur, skala ADC 1023, tegangan masukan maksimal V_{maks} 5 V, dan nilai DAC [10]. Nilai DAC diperoleh menggunakan Persamaan (3) berikut ini:

$$DAC = \frac{ADC \text{ terukur}}{1024} \times V_{maks} \quad (3)$$


Setelah diperoleh nilai DAC kemudian dikonversi ke ppm menggunakan Persamaan (4):

$$ppm_{ssr} = \frac{range_{max_ssr} - range_{min_ssr}}{V_{maks}} \times DAC \quad (4)$$

Hasil konversi ADC terukur menjadi ppm ditunjukkan pada Tabel V.

TABEL V
DATA KONVERSI ADC TERUKUR MENJADI PPM


Index	tgs26	mq3	mq4	mq2	mq8
1	0	0	0	0	0
2	11	40	48	2	22
3	0	0	0	0	0
4	11	40	48	2	22
.
.
.
314	362	209	73	396	8
315	363	211	76	397	9
316	360	206	72	393	6
317	360	207	72	394	6



Gbr. 4 Grafik Normalisasi Nilai ADC Terukur

Visualisasi data pada Tabel V yang ditunjukkan pada Gbr 4 memperlihatkan bahwa nilai awal ADC

terukur hasil pengukuran setiap sensor gas saat ini bermula di titik 0. Selanjutnya dalam waktu tertentu, grafik nilai ADC terukur melandai menunjukkan terjadinya kondisi *steady state*. Nilai ADC terukur setiap sensor berada pada kisaran 0 hingga 300.



Gbr. 5 Grafik Konversi Nilai Adc Terukur Menjadi Ppm
Setiap Sampel Buah Pada Pengukuran Hari ke-7


Setelah dinormalisasi, nilai ADC terukur kemudian dikonversi untuk ditentukan nilai ppm terukur semua sampel dari setiap sensor gas. Contoh hasil konversi ADC terukur ke ppm ditunjukkan pada Gbr. 5. *Range* hasil pengukuran ppm berada pada kisaran *range* kerja setiap sensor. Sensor MQ2 dan MQ4 yang memiliki *range* kerja terluas memberikan respon paling tinggi diantara ketiga sensor lainnya.

D. Pemodelan dan Simulasi

Model sistem pendeteksi kerusakan buah mangga dikembangkan dengan menggunakan metode *ensemble learning*. Metode *ensemble learning* suatu metode yang menggabungkan hasil model pembelajaran mesin yang baik untuk dikombinasikan sehingga mendapatkan model pemecahan masalah yang paling optimal [11]. Algoritma *ensemble learning* mengkombinasi model-model pembelajaran mesin dasar (*Multiple Classifier Systems*) secara dinamis untuk menyelesaikan permasalahan klasifikasi [12]. Skema umum algoritma *ensemble learning* ditunjukkan pada Gbr. 6.

Terdapat beberapa tipe metode *ensemble learning* yaitu *Dynamic Classifier Selection* (DCS) dan

Dynamic Ensemble Selection (DES). DCS menerapkan teknik dimana hanya algoritma pengklasifikasi dasar yang memperoleh level kompetensi tertinggi yang dipilih untuk proses pembelajaran klasifikasi. Adapun DES menerapkan strategi yang memilih gabungan algoritma pengklasifikasi daripada sebuah algoritma pengklasifikasi. Seluruh algoritma pengklasifikasi yang memiliki level kompetensi rendah yang dipilih sebagai gabungan pengklasifikasi [11]. Teknik DCS maupun DES memiliki banyak bentuk algoritma. Diantara bentuk algoritma tersebut, bentuk algoritma DCS yang terbaik adalah DSC-OLA (*Overall Local Accuracy*) dan DCS-LCA (*Local Class Accuracy*). Sedangkan untuk bentuk algoritma DES yang terbaik adalah KNORA-E (*k-Nearest Neighbor Oracle – Eliminate*) dan KNORA-U (*k-Nearest Neighbor Oracle – Union*) [13].



Gbr. 5 Grafik Skema Algoritma *Ensemble Learning*

Model pengklasifikasi dasar yang umum digunakan pada penerapan pembelajaran mesin di bidang pertanian adalah Regresi Linier, Regresi Logistik, Pohon Pemilihan (*Decision Tree*), *Support Vector Machine* (SVM), *Naïve Bayes*, *K Nearest Neighbor* (KNN), *Random Forest*, dan Jaringan Syaraf Tiruan [6], [14]. Dari beberapa metode dasar tersebut, pada penelitian ini digunakan algoritma-algoritma Regresi Logistik, Pohon Pemilihan (*Decision Tree*), *Support Vector Machine* (SVM),

Naïve Bayes, *Random Forest*, dan Jaringan Syaraf Tiruan sebagai algoritma dasar yang dijalankan dengan teknik DCS-LCA.

Lebih detil tentang algoritma Teknik DCS-LCA diberikan oleh pseudocode berikut ini [13]:

Input himpunan kelas/label Ω ; pilihan pengklasifikasi (*pool_classifier*) C ; dataset Tr dan Te ; dan ukuran neighborhood K ;

Output c_t^* , pengklasifikasi paling kompeten untuk setiap sampel t pada Te ;

for setiap sampel pengujian t pada Te **do**

Submit t ke seluruh pengklasifikasi pada C ;

if (seluruh pengklasifikasi sepakat dengan label sampel t) **then return** label t ;

else

for setiap pengklasifikasi c_i pada C **do**

$\omega_j = c_i(t)$, prediksi output dari c_i untuk sampel t ;

Temukan Ψ sebagai K nearest neighbors dari sampel t pada Tr yang menjadi bagian kelas ω_j ;

Hitung $LCA(i, j)$ sebagai prosentase sampel berlabel benar dari kelas ω_j oleh pengklasifikasi c_i pada Ψ ;

end for

Pilih pengklasifikasi terbaik untuk t sebagai $c_t^* = \arg \max_i \{LCA(i, j)\}$;

Gunakan c_t^* untuk mengklasifikasi t ;

end if

end for

Model DCS-LCA yang dikembangkan pada penelitian ini menggunakan parameter tuning *pool_classifier* dan nilai $k \text{ neighbor} = 2$. Di mana *pool_classifier* adalah tempat menampung pengklasifikasi dasar yang digunakan oleh DCS-LCA dan $k \text{ neighbor}$ menyatakan jumlah tetangga yang digunakan untuk memperkirakan kompetensi pengklasifikasi dasar.

E. Pengujian Sistem

Evaluasi performa sistem penting dilakukan, untuk evaluasi, digunakan matrik performa seperti akurasi, presisi, sensitifitas, dan *Specificity*. Matrik tersebut merupakan *confusion matrix* yang membentuk empat indikasi berupa *true positive* (TP), *true negative* (TN), *false positive* (FP), dan *false negative* (FN). TP menunjukkan jumlah sampel

normal yang terdeteksi dengan benar, TN menunjukkan jumlah sampel rusak yang terdeteksi dengan benar, FP menunjukkan jumlah sampel normal yang tidak terdeteksi dengan benar, dan FN menunjukkan jumlah sampel rusak yang terdeteksi salah [14], [15]. Bentuk confusion matriks ditunjukkan pada Tabel VI.

TABEL VI
CONFUSION MATRIX

Prediksi	Nilai Asli	
	Positif (1)	Negatif (0)
Positif (1)	TP	FP
Negatif (0)	FN	TN

Setiap nilai pada confusion matriks di atas digunakan untuk menentukan nilai Akurasi (*Acc*), Presisi (*Pr*), Sensitivitas (*Se*), dan *Specificity* (*Sp*) menggunakan Persamaan (5) – (8) berikut:

$$Acc = \frac{TP + TN}{TP + FP + TN + FN} \quad (5)$$

$$Pr = \frac{TP}{TP + FP} \quad (6)$$

$$Se = \frac{TP}{TP + FN} \quad (7)$$

$$Sp = \frac{TN}{FP + TN} \quad (8)$$

Acc menunjukkan keseluruhan performa model. *Pr* merupakan rasio prediksi buah normal dibandingkan dengan keseluruhan hasil yang diprediksi sebagai buah normal. *Se* mengacu pada kinerja model untuk mendeteksi sampel buah normal dengan benar. *Sp* mengacu pada kinerja model untuk mendeteksi sampel buah rusak dengan benar [14], [16].

III. HASIL DAN PEMBAHASAN

A. Hasil Pengujian Sistem

Hasil pengujian sistem pendeteksi kerusakan buah mangga dalam bentuk *confusion matrix* menggunakan model DCS-LCA ditunjukkan pada Tabel VII sampai Tabel XIII. Berdasarkan nilai *confusion matrix* tersebut kemudian dihitung nilai Akurasi (*Acc*), Presisi (*Pr*), Sensitivitas (*Se*), dan

Specificity (*Sp*) dan ditampilkan dalam bentuk grafik pada Gbr. 6.

Dari data uji sebanyak 12 buah sampel mangga, dengan masing-masing perbandingan jumlah normal (1) dan rusak (0) adalah 50:50, metode *ensemble learning* DCS-LA dapat mengenali 5 dari 6 mangga kondisi rusak (0). Sedangkan untuk mangga normal (1) 4 dari 6 mangga yang dapat dikenali.

Adapun untuk hasil pengenalan mangga oleh setiap algoritma pengklasifikasi dasar adalah Regresi Logistik rusak (0) 4 dari 6, dan normal 3 dari 6. Algoritma Pohon Pemilihan (*Decision Tree*) untuk kondisi rusak (0) dan normal (1) sama-sama mengenali 4 dari 6.

TABEL IV
CONFUSION MATRIX DCS-LCA

Prediksi	Nilai Asli	
	Normal (1)	Rusak (0)
Normal (1)	4	2
Rusak (0)	1	5

TABEL VII
CONFUSION MATRIX REGRESI LOGISTIK

Prediksi	Nilai Asli	
	Normal (1)	Rusak (0)
Normal (1)	3	3
Rusak (0)	2	4

TABEL IX
CONFUSION MATRIX POHON PEMILIHAN

Prediksi	Nilai Asli	
	Normal (1)	Rusak (0)
Normal (1)	4	2
Rusak (0)	2	4

TABEL X
CONFUSION MATRIX NAÏVE BAYES

Prediksi	Nilai Asli	
	Normal (1)	Rusak (0)
Normal (1)	5	1
Rusak (0)	4	2

TABEL XI
CONFUSION MATRIX RANDOM FOREST

Prediksi	Nilai Asli	
	Normal (1)	Rusak (0)
Normal (1)	2	4

Rusak (0)	1	5
-----------	---	---

TABEL XII

CONFUSION MATRIX SUPPORT VECTOR MACHINE (SVM)


Prediksi	Nilai Asli	
	Normal (1)	Rusak (0)
Normal (1)	1	5
Rusak (0)	0	6

TABEL XIII

CONFUSION MATRIX MLP

Prediksi	Nilai Asli	
	Normal (1)	Rusak (0)
Normal (1)	2	4
Rusak (0)	2	4

Selanjutnya untuk algoritma Naïve Bayes dapat mengenali rusak(0) 2 dari 6 dan normal (1) 5 dari 6. Algoritma Random Forest mengenali 5 dari 6 rusak (0) dan 2 dari 6 normal (1). Algoritma SVM memberikan nilai yang sempurna, 6 dari 6 untuk mengenali mangga rusak (0) akan tetapi memberikan nilai 1 dari 6 untuk mangga normal (1). Terakhir algoritma MLP mengenali 4 dari 6 rusak (0) dan 2 dari 6 normal (1).



Gbr. 6 Grafik Hasil Pengujian Sistem Pendeteksi Kerusakan Buah Mangga

B. Analisis dan Pembahasan

Dari hasil pengujian yang telah dilakukan sebagaimana ditunjukkan pada Gbr. 6 dapat disimpulkan bahwa model sistem deteksi kerusakan buah mangga yang dibangun menggunakan metode *ensemble learning* DCS-LCA memiliki akurasi

paling baik. Hal ini berdasarkan nilai akurasinya (Ac), sebesar 75%, paling tinggi dibandingkan dengan nilai akurasi metode pengklasifikasi lainnya.

Selanjutnya dari nilai *Specificity* (Sp) yang menunjukkan kinerja sistem dalam memprediksi sampel buah mangga rusak, model DCS-LCA juga memberikan nilai yang tertinggi, sebesar 71%. Oleh karena itu, tujuan dari dibuatnya sistem ini yaitu untuk dapat mendeteksi kerusakan buah mangga sudah tercapai meskipun masih ada kemungkinan untuk ditingkatkan nilai akurasi dan *Specificity* nya.

Terkait dengan sensor yang digunakan pada penelitian ini, dapat disimpulkan bahwa integrasi kelima sensor gas, tipe TGS 2600, MQ-3, MQ-4, MQ-2, dan MQ-8, dapat digunakan untuk mendeteksi kerusakan buah mangga berdasarkan nilai ppm gas yang dihasilkan. Akurasi sistem sebesar 75% secara tidak langsung menunjukkan adanya hubungan dengan kemampuan sensor dalam mendeteksi gas yang dihasilkan buah. Hal ini dikarenakan sensor-sensor yang digunakan bukan merupakan sensor yang khusus dibuat untuk mengukur gas yang dihasilkan oleh buah-buahan, melainkan gas yang digunakan untuk mendeteksi gas secara umum. Bahkan setiap sensor memiliki tingkat sensitivitas yang tinggi terhadap gas tertentu. Meskipun demikian, kombinasi sensor-sensor tersebut sudah mampu dengan baik dalam mendeteksi kerusakan buah berdasarkan gas yang dihasilkannya.

IV. KESIMPULAN

Dari penelitian yang telah dilakukan diperoleh kesimpulan sebagai berikut. Telah dibuat sistem pendeteksi kerusakan buah mangga menggunakan data ppm yang diperoleh menggunakan sensor gas dan algoritma *ensemble learning* DCS-LCA dengan akurasi sistem keseluruhan 75% dan kemampuan mendeteksi kerusakan buah mangga mencapai 71%. Integrasi sensor gas tipe TGS 2600, MQ-3, MQ-4, MQ-2, dan MQ-8 dapat digunakan sebagai *e-nose* untuk mendeteksi gas yang dihasilkan oleh mangga.

Model pengklasifikasi DCS-LCA yang digunakan memberikan performa yang lebih baik dibandingkan dengan performa masing-masing pengklasifikasi dasar pembentuknya (Regresi Logistik, Pohon Pemilihan (Decision Tree), Support Vector Machine (SVM), Naïve Bayes, Random Forest, dan Jaringan Syaraf Tiruan).

Penelitian ini masih memiliki peluang untuk ditingkatkan performanya. Untuk dapat meningkatkan kemampuan hasil pendeteksi kerusakan mangga dapat dilakukan beberapa hal diantaranya menggunakan sensor gas yang dapat digunakan khusus untuk mengukur gas yang dihasilkan oleh buah-buahan, melakukan modifikasi jumlah sensor gas, menambah jumlah dan jenis sampel buah-buahan, dan melakukan hyperparameter tuning untuk model *ensemble learning* yang akan digunakan.

UCAPAN TERIMA KASIH

Terima kasih kepada Lembaga Penelitian dan Pengabdian (LPPM) Universitas Mataram yang telah mendanai penelitian ini dengan dana hibah PNPB melalui skema Penelitian Dosen Pemula dengan nomor kontrak 2759/UN18.L1/PP/2021. Terima kasih juga kami ucapkan kepada seluruh personil di lingkungan Fakultas Teknologi Pangan dan Agroindustri yang telah mendukung berjalannya penelitian ini.

REFERENSI

- [1] M. Baietto and A. D. Wilson, "Electronic-nose applications for fruit identification, ripeness and quality grading," *Sensors (Switzerland)*, vol. 15, no. 1, pp. 899–931, 2015.
- [2] K.-T. Li, "Physiology and Classification of Fruits," in *Handbook of Fruits and Fruit Processing: Second Edition*, Second., N. K. Sinha, J. S. Sidhu, J. Barta, J. S. B. Wu, and M. P. Cano, Eds. Oxford, United Kingdom: Wiley-Blackwell, 2012, pp. 3–12.
- [3] A. U. Alam, P. Rathi, H. Beshai, G. K. Sarabha, and M. Jamal Deen, "Fruit quality monitoring with smart packaging," *Sensors*, vol. 21, no. 4, pp. 1–30, 2021.
- [4] N. Geethapriya and S. M. Praveena, "Evaluation of Fruit Ripeness Using Electronic Nose," *Int. J. Adv. Inf. Sci. Technol.*, vol. 6, no. 5, pp. 1–5, 2017.
- [5] N. Aghilinategh, M. J. Dalvand, and A. Anvar, "Detection of ripeness grades of berries using an electronic nose," *Food Sci. Nutr.*, vol. 8, no. 9, pp. 4919–4928, 2020.
- [6] K. G. Liakos, P. Busato, D. Moshou, S. Pearson, and D. Bochtis, "Machine learning in agriculture: A review," *Sensors (Switzerland)*, vol. 18, no. 8, pp. 1–29, 2018.
- [7] M. A. Souza, G. D. C. Cavalcanti, R. M. O. Cruz, and R. Sabourin, "Online local pool generation for dynamic classifier selection," *Pattern Recognit.*, vol. 85, no. 1, pp. 132–148, 2018.
- [8] P. P. K. Chan, Q. Zhang, W. W. Y. Ng, and D. S. Yeung, "DYNAMIC BASE CLASSIFIER POOL FOR CLASSIFIER SELECTION IN MULTIPLE CLASSIFIER SYSTEMS," in *Proceedings of the 2011 International Conference on Machine Learning and Cybernetics*, 2011, no. 1, pp. 1093–96.
- [9] S. A. Mane, D. Y. Nadargi, J. D. Nadargi, O. M. Aldossary, M. S. Tamboli, and V. P. Dhulap, "Design, development and validation of a portable gas sensor module: A facile approach for monitoring greenhouse gases," *Coatings*, vol. 10, no. 12, pp. 1–10, 2020.
- [10] I. Daugela, J. Suziedelyte Visockiene, J. Kumpiene, and I. Suzdalev, "Measurements of flammable gas concentration in landfill areas with a low-cost sensor," *Energies*, vol. 14, no. 13, 2021.
- [11] R. M. O. Cruz, L. G. Hafemann, R. Sabourin, and G. D. C. Cavalcanti, "DESLib: A Dynamic ensemble selection library in Python," *J. Mach. Learn. Res.*, vol. 21, pp. 1–5, 2020.
- [12] S. García, Z. L. Zhang, A. Altalhi, S. Alshomrani, and F. Herrera, "Dynamic ensemble selection for multi-class imbalanced datasets," *Inf. Sci. (Ny)*, vol. 445–446, pp. 22–37, 2018.
- [13] A. S. Britto, R. Sabourin, and L. E. S. Oliveira, "Dynamic selection of classifiers - A comprehensive review," *Pattern Recognit.*, vol. 47, no. 11, pp. 3665–3680, 2014.
- [14] M. Koklu and I. A. Ozkan, "Multiclass classification of dry beans using computer vision and machine learning techniques," *Comput. Electron. Agric.*, vol. 174, no. June 2019, p. 105507, 2020.
- [15] S. A. A. Yusuf and R. Hidayat, "Feature Extraction of ECG Signals using Discrete Wavelet Transform and MFCC," *Proceeding - 2019 5th Int. Conf. Sci. Inf. Technol. Embrac. Ind. 4.0 Towar. Innov. Cyber Phys. Syst. ICSITech 2019*, pp. 167–170, 2019.
- [16] S. A. A. Yusuf and R. Hidayat, "MFCC feature extraction and KNN classification in ECG signals," *2019 6th Int. Conf. Inf. Technol. Comput. Electr. Eng. ICITACEE 2019*, pp. 1–5, 2019.