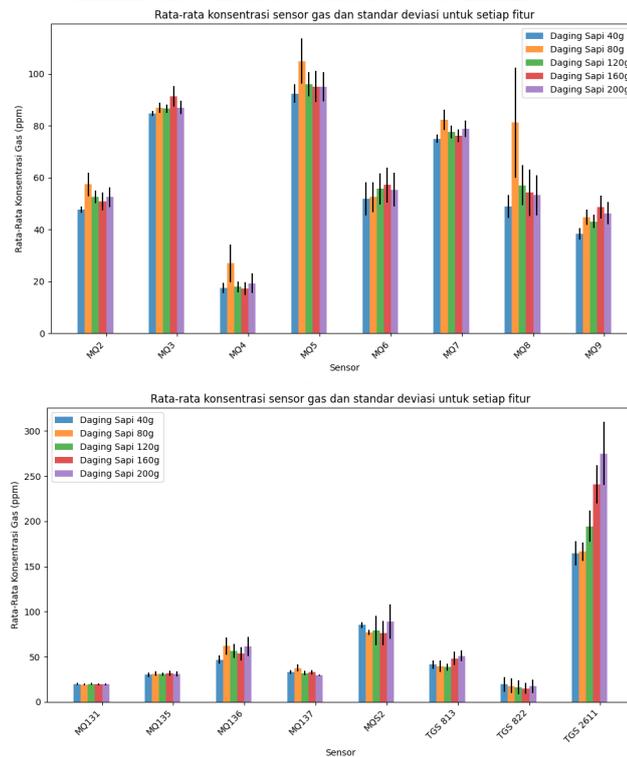


BAB 4

HASIL DAN PEMBAHASAN

4.1 Analisis Data dan Respon Sensor

4.1.1 Variasi Daging Sapi



Gambar 4.1: Rata-Rata Nilai Sensor dan Standar Deviasi Variasi Daging Sapi

Dalam penelitian ini, kami menggunakan enam belas sensor gas yang berbeda, masing-masing dengan spesifikasi uniknya sendiri sesuai tinjauan pustaka seper-

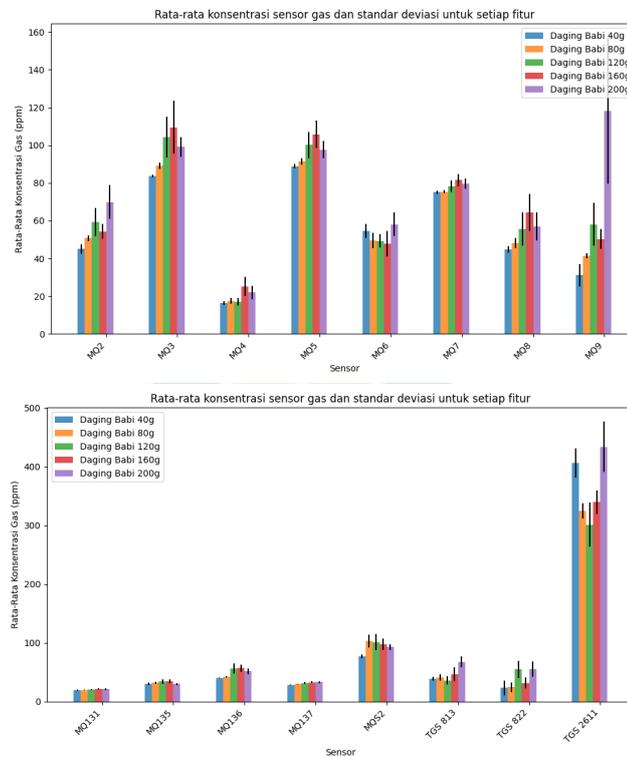
ti pada **Tabel 2.2**. Sensor gas ini memiliki rentang deteksi dan sensitivitas yang berbeda terhadap senyawa-senyawa tertentu, sehingga memberikan gambaran yang komprehensif tentang respons mereka terhadap variasi daging sapi. Untuk memperoleh sensitivitas gas yang lebih spesifik kita lakukan kalibrasi sensor seperti yang dilakukan pada metode penelitian, ditunjukkan oleh **Tabel 3.2**.

Hasil analisis pada **Gambar 4.1** menunjukkan perbedaan pola respons pada masing-masing sensor gas terhadap lima variasi daging sapi yang diuji. Meninjau hasil kalibrasi sensor pada **Tabel 3.2** maka diperoleh kandungan gas pada *MQ7* (Hidrogen Sulfida), *MQ8* (Metana), *MQ9* (Karbon Monoksida), *MQ131* (Ozon), *MQ135* (Karbon Dioksida), *MQ137* (Amonia), *TGS822* (Karbon Monoksida).

Kandungan gas yang terdeteksi oleh sensor sesuai dengan beberapa teori yang mendukung yaitu gas yang mungkin terkandung dalam atau sekitar daging sapi termasuk karbon dioksida (CO_2), yang bisa terbentuk selama proses penyimpanan dalam wadah tertutup (Hou et al., 2023). Daging sapi juga mungkin mengandung ammonia (NH_3) jika terjadi pemecahan protein, Hidrogen sulfida (H_2S) adalah senyawa yang berhubungan dengan pelapukan dan dapat memberikan aroma yang tidak diinginkan jika terlalu banyak terbentuk dalam daging, Metana (CH_4) dapat terbentuk selama proses fermentasi dalam daging sapi (Ahvanooei et al., 2023).



4.1.2 Variasi Daging Babi

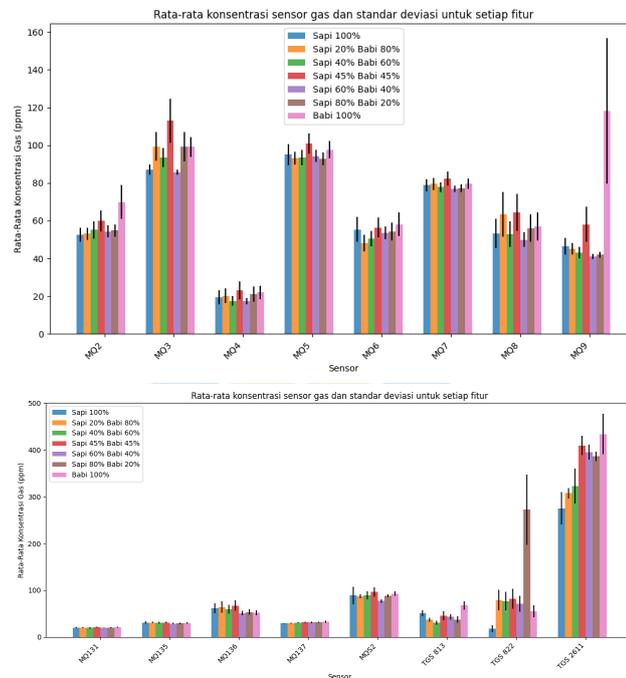


Gambar 4.2: Rata-Rata Nilai Sensor dan Standar Deviasi Variasi Daging Babi.

Selanjutnya hasil analisis pada **Gambar 4.2** menunjukkan perbedaan pola respons masing-masing sensor gas terhadap lima variasi daging babi yang diuji. Kita coba bandingkan hasil kalibrasi sensor pada 3.2 maka diperoleh kandungan gas pada *MQ7* (Hidrogen Sulfida), *MQ8* (Metana), *MQ9* (Karbon Monoksida), *MQ131* (Ozon), *MQ135* (Karbon Dioksida), *MQ137* (Amonia), *TGS822* (Karbon Monoksida), bisa terlihat pada **Gambar 4.2** dan **Gambar 4.1** bahwa terdapat sedikit perbedaan pola respon sensor gas antara variasi daging sapi dan variasi daging babi, atau perbedaan dalam konsentrasi ppm.

Kandungan gas yang terdeteksi pada daging babi juga sudah sesuai dengan teori yang ada yaitu beberapa gas termasuk karbon dioksida (CO_2), ammonia (NH_3), hidrogen sulfida (H_2S), dan metana (CH_4), yang dapat muncul dalam atau sekitar daging babi (S. Shi et al., 2023).

4.1.3 Variasi Campuran Daging Sapi dan Daging Babi

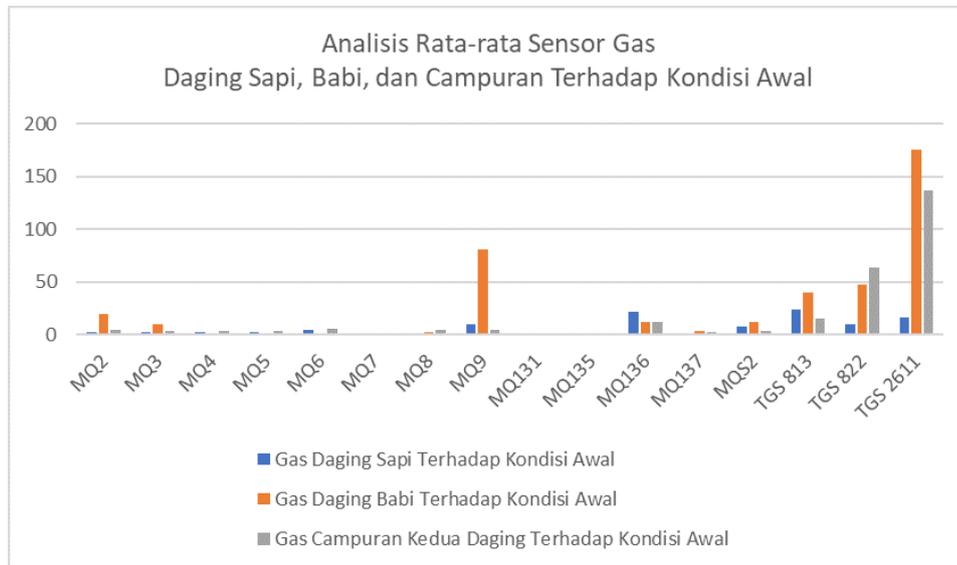


Gambar 4.3: Rata-Rata Nilai Sensor dan Standar Deviasi Variasi Campuran Daging Sapi dan Daging Babi

Dari **Gambar 4.3**, diperoleh pemahaman bahwa beberapa sensor menunjukkan reaksi yang signifikan terhadap variasi campuran daging sapi dan daging babi. Seperti hasil kalibrasi sensor pada **Tabel 3.2**, diperoleh kandungan gas untuk *MQ7* (Hydrogen Sulfida), *MQ8* (Metana), *MQ9* (Karbon Monoksida), *MQ131* (Ozon), *MQ135* (Karbon Dioksida), *MQ137* (Amonia), *TGS822* (Karbon Monoksida).

Perbedaan signifikan terlihat pada sensor *MQ9* untuk variasi babi 100% terdapat kandungan gas Karbon Monoksida yang cukup signifikan, sama dengan sensor *TGS822* yang mendeteksi kandungan gas Karbon Monoksida yang signifikan untuk variasi Sapi 80% Babi 20%. Kandungan gas Metana juga terlihat cukup signifikan pada variasi Sapi 20% dan Babi 80%, serta variasi Sapi 45% dan Babi 45% yang dideteksi oleh sensor *MQ6*. Pada sensor lainnya juga terdapat perbedaan konsentrasi PPM hanya saja tidak terlalu signifikan.

4.1.4 Perbandingan Sensor pada Kondisi Awal dengan Sampel Daging Sapi, Daging Babi, dan Campuran

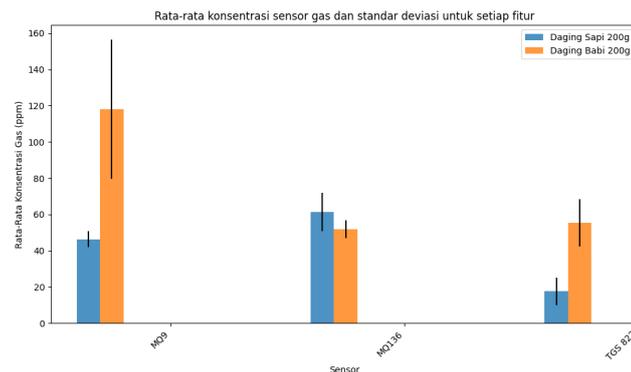


Gambar 4.4: Rata-Rata Nilai Sensor dan Standar Deviasi Variasi Daging Sapi, Daging Babi, dan Campuran Terhadap Kondisi Awal

Selanjutnya kita coba analisis perbandingan kondisi awal sensor terhadap variasi sampel daging sapi 200g, daging babi 200g, dan campuran daging sapi 160g dengan daging babi 40g pada **Gambar 4.4**, untuk mengetahui perbedaan pola dan tren pada kondisi sebelum ada sampel dan setelah ada sampel. Perbedaan tren dari kedua diagram tersebut bisa dengan jelas terlihat pada sensor MQ9 (Karbon Monoksida), MQ136 (Hidrogen Sulfida), MQS2 (*LPG*), TGS813 (Isobutana), TGS822 (Karbon Monoksida), dan TGS2611 (Etanol). Merujuk dari (S. Shi et al., 2023) maka dapat dikonfirmasi bahwa betul pada gas daging sapi dan daging babi memang mengandung Hidrogen Sulfida, ke-enam sensor tersebut mempunyai kontribusi yang besar dalam mendeteksi adanya gas. Misalnya pada sensor TGS2611 mempunyai tren yang sangat signifikan terhadap perubahan dari kondisi awal, untuk daging sapi mempunyai rata-rata konsentrasi gas sekitar 16,24 ppm, daging babi 174,86 ppm, dan untuk sampel campuran sekitar 136,40 ppm. Selanjutnya pada sensor TGS822 memiliki rata-rata untuk daging sapi 9,50 ppm, daging babi 47,60 ppm, dan sampel campuran 63,46 ppm. Begitu pula dengan sensor yang lainnya juga mengalami perubahan tren atau pola dari kondisi awal sebelum ada sampel dan ketika sudah diberi sampel. Pola-pola tersebut yang kemudian akan digunakan sebagai dataset yang di-

latih menggunakan *Machine Learning* khususnya pada penelitian ini menggunakan metode *Random Forest*.

4.1.5 Perbandingan Sensitivitas Sensor Terhadap Daging Sapi dan Daging Babi

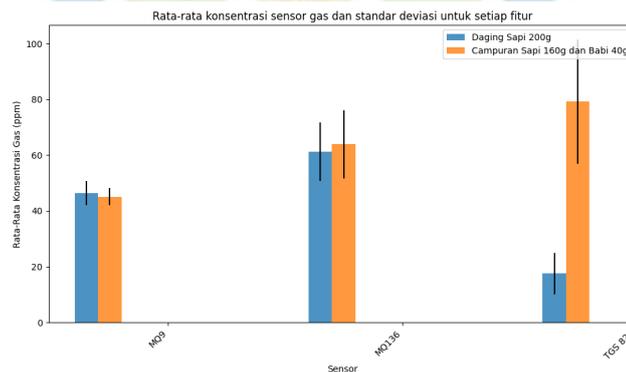


Gambar 4.5: Rata-Rata Nilai Sensor dan Standar Deviasi Terhadap Daging Sapi 200g dan Daging Babi 200g

Dari **Gambar 4.5**, kita bisa mencoba menganalisis perbedaan sensitivitas pada tiga sensor yang digunakan untuk mengetahui perbedaan konsentrasi antara daging sapi 200g dan daging babi 200g. Berdasarkan **Tabel 3.2** didapatkan hasil kalibrasi pada sensor MQ8 yaitu untuk mendeteksi gas CO atau karbon monoksida, sedangkan pada grafik di atas terlihat perbedaan konsentrasi gas daging sapi dan daging babi. Daging sapi mempunyai konsentrasi gas CO sekitar 37,31 ppm - 49,69 ppm, sedangkan daging babi mempunyai konsentrasi sekitar 38,99 ppm - 130,77 ppm. Selanjutnya sensor MQ136 yang mempunyai sensitivitas terhadap H₂S atau Hidrogen Sulfida, daging sapi mempunyai konsentrasi lebih tinggi yaitu sekitar 39,26 ppm - 76,91 ppm, sedangkan babi hanya mempunyai konsentrasi sekitar 39,7 ppm - 59,3 ppm. Dan terakhir yaitu bisa dilihat pada sensor TGS 822 yang mempunyai sensitivitas terhadap gas CO atau karbon monoksida. Daging sapi mempunyai konsentrasi lebih rendah yaitu pada rentang 7,38 ppm - 51,44 ppms sedangkan daging babi mempunyai konsentrasi karbon monoksida lebih tinggi yaitu sekitar 35,2 ppm - 124,89 ppm.

4.1.6 Perbandingan Sensitivitas Sensor Terhadap Daging Sapi dan Daging Campuran

Dari **Gambar 4.6**, kita bisa mencoba menganalisis perbedaan sensitivitas pada tiga sensor yang digunakan untuk mengetahui perbedaan konsentrasi antara daging sapi 200g dan campuran daging sapi 160g dengan daging babi 40g. Pada grafik sensor MQ9 terlihat bahwa kandungan karbon monoksida pada daging sapi yang sudah dicampur dengan daging babi, mengalami penurunan konsentrasi gas dari 49.69 ppm sampai 41.66 ppm. Sedangkan pada sensor MQ136 kandungan gas H₂S pada daging sapi juga mengalami kenaikan setelah dicampur dengan daging babi yaitu dari 76,91 ppm sampai 79,92 ppm. Terakhir pada sensor TGS822 kandungan CO atau karbon monoksida mengalami peningkatan yang sangat signifikan dari 51,14 ppm sampai 95,58 ppm.

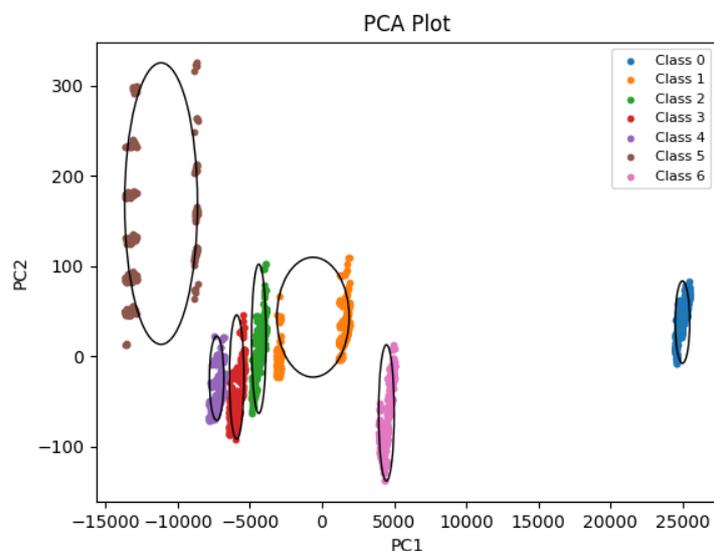


Gambar 4.6: Rata-Rata Nilai Sensor dan Standar Deviasi Terhadap Daging Sapi 200g dan Daging Campuran

4.2 Analisis PCA (*Principal Component Analysis*)

Analisis PCA pada *Electronic Nose* untuk membedakan variasi daging sapi dan daging babi dapat memberikan wawasan yang berharga dalam pengenalan pola dan pengklasifikasian seperti pada **Gambar 4.7**. Dalam kasus ini, kita membagi analisis menjadi tujuh kelas yang mencerminkan variasi berbeda dalam proporsi daging sapi dan daging babi. Kelas tersebut terdiri dari Kelas 0, Kelas 1, Kelas 2, Kelas 3, Kelas 4, Kelas 5, dan Kelas 6.

Kelas 0 digunakan untuk data dengan variasi 200 g daging sapi, kelas 1 variasi campuran daging babi 40g dan daging sapi 160g, kelas 2 variasi campuran daging



Gambar 4.7: Analisis Data dan Pengenalan Pola Pada Setiap Kelas

babi 80g dan daging sapi 120g, kelas 3 variasi campuran daging babi 120g dan daging sapi 80g, kelas 4 variasi campuran daging babi 160g dan daging sapi 40g, kelas 5 variasi campuran daging babi 90g dan daging sapi 90g, dan terakhir kelas 6 yaitu variasi daging babi 200g.

Untuk mendeteksi variasi tersebut digunakan 16 sensor. Sensor-sensor ini memberikan tanggapan atau respons terhadap komponen-komponen gas tertentu yang terkait dengan aroma atau karakteristik daging sapi dan daging babi.

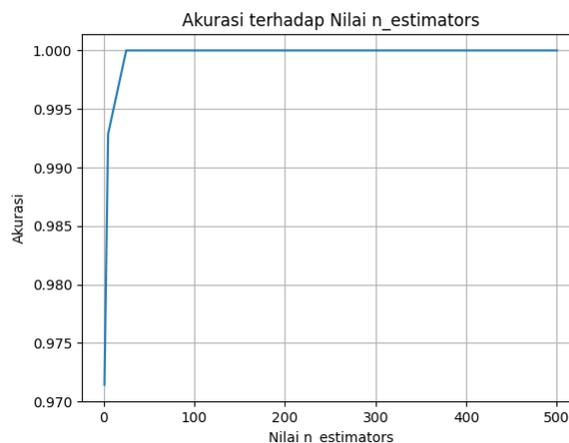
Dalam analisis PCA, data yang dihasilkan dari sensor-sensor tersebut digunakan untuk mengidentifikasi pola atau struktur yang terdapat dalam dataset. Melalui PCA, dimensi variabel yang tinggi dapat dikurangi ke dalam ruang yang lebih rendah dimensi yang disebut sebagai komponen utama. Hasil PCA akan menghasilkan pola-pola yang sesuai dengan setiap kelas yang telah ditentukan sebelumnya. Pola-pola ini mencerminkan variasi dalam proporsi daging sapi dan daging babi. Dengan mempelajari pola-pola tersebut, kita dapat mengidentifikasi karakteristik unik dalam respons sensor dan membedakan antara variasi daging sapi dan daging babi.

4.3 Evaluasi *Machine Learning* Metode *Random Forest*

4.3.1 *Parameter Tuning*

Tabel 4.1: *Parameter Tuning n_estimators Random Forest*

No	<i>n_estimators</i>	Akurasi
1	1	0,982
2	5	0,998
3	25	1,000
4	50	1,000
5	500	1,000



Gambar 4.8: *Parameter Tuning Random Forest "n_estimators"*

Dalam analisis *parameter tuning* untuk metode *Random Forest*, fokus utama adalah pada parameter *n_estimators*, yang digunakan untuk mengatur jumlah pohon dalam ensemble model. Proses *parameter tuning* ini bertujuan untuk mencari nilai *n_estimators* yang menghasilkan kinerja model yang optimal dalam melakukan analisis *machine learning*, seperti *F1 score*, *recall*, *presisi*, *support*, akurasi, *mean squared error* (MSE), dan grafik *confusion matrix*.

Dengan melakukan *parameter tuning*, seperti yang ditunjukkan pada **Tabel 4.1**, dan **Gambar 4.8** kita dapat mengidentifikasi nilai *n_estimators* yang memberikan hasil terbaik dalam kinerja model. Dalam kasus ini, setelah melakukan parameter tuning, didapatkan bahwa nilai *n_estimators* yang optimal adalah 25, 50, dan 500.

Hasil evaluasi model dengan menggunakan parameter tersebut menunjukkan akurasi yang sempurna, yaitu bernilai 1,0 atau 100%. Hal ini menandakan bahwa model yang menggunakan jumlah pohon sebanyak itu mampu melakukan klasifikasi dengan sangat baik, dengan kemampuan yang tinggi dalam mengidentifikasi dan memprediksi kelas-kelas yang ada.

Selain akurasi, parameter tuning juga memberikan informasi mengenai metrik-metrik lain seperti *F1 score*, *recall*, presisi, *support*, MSE, dan grafik *confusion matrix*. Dengan menganalisis metrik-metrik ini, kita dapat memahami lebih dalam kinerja model *Random Forest* dan melihat apakah parameter tuning membantu dalam meningkatkan kinerja model tersebut.

4.3.2 Metriks Evaluasi

Pada **Tabel 4.2**, **Tabel 4.3**, **Tabel 4.4**, **Tabel 4.5**, dan **Tabel 4.6** menunjukkan hasil evaluasi yang komprehensif yang memberikan pemahaman yang jelas tentang kinerja model yang dievaluasi dalam mengklasifikasikan sampel campuran daging sapi dan daging babi. Evaluasi ini mencakup beberapa metrik penting seperti presisi (*precision*), *recall*, *F1-score*, dan *support*, yang secara bersama-sama memberikan wawasan berharga tentang akurasi klasifikasi model.

Tabel 4.2: Metrik Evaluasi Saat Parameter $n_estimators = 1$

Variabel Evaluasi	<i>Precision</i>	<i>Recall</i>	<i>f1-score</i>	<i>Support</i>
0	1,00	1,00	1,00	62
1	1,00	0,99	0,99	85
2	0,97	0,95	0,96	76
3	0,96	0,99	0,97	86
4	1,00	0,97	0,98	90
5	1,00	1,00	0,99	94
6	1,00	1,00	0,97	77
<i>accuracy</i>			0,98	560
<i>macro avg</i>	0,98	0,98	0,98	560
<i>weighted avg</i>	0,98	0,98	0,98	560
Akurasi:	0,982142857142857			
<i>Mean Squared Error</i> :	0,048214285714285716			

Tabel 4.3: Metrik Evaluasi Saat Parameter $n_estimators = 5$

Variabel Evaluasi	<i>Precision</i>	<i>Recall</i>	<i>f1-score</i>	<i>Support</i>
0	1,00	1,00	1,00	90
1	1,00	1,00	1,00	76
2	1,00	1,00	1,00	80
3	1,00	0,99	0,99	71
4	1,00	1,00	1,00	80
5	0,99	1,00	0,99	90
6	1,00	1,00	1,00	73
<i>accuracy</i>			1,00	560
<i>macro avg</i>	1,00	1,00	1,00	560
<i>weighted avg</i>	1,00	1,00	1,00	560
Akurasi:	0,9982142857142857			
<i>Mean Squared Error</i> :	0,007142857142857143			

Tabel 4.4: Metrik Evaluasi Saat Parameter $n_estimators = 25$

Variabel Evaluasi	<i>Precision</i>	<i>Recall</i>	<i>f1-score</i>	<i>Support</i>
0	1,00	1,00	1,00	94
1	1,00	1,00	1,00	84
2	1,00	1,00	1,00	78
3	1,00	1,00	1,00	86
4	1,00	1,00	1,00	69
5	1,00	1,00	1,00	75
6	1,00	1,00	1,00	74
<i>accuracy</i>			1,00	560
<i>macro avg</i>	1,00	1,00	1,00	560
<i>weighted avg</i>	1,00	1,00	1,00	560
Akurasi:	1,0			
<i>Mean Squared Error</i> :	0,0			

Tabel 4.5: Metrik Evaluasi Saat Parameter $n_estimators = 50$

Variabel Evaluasi	<i>Precision</i>	<i>Recall</i>	<i>f1-score</i>	<i>Support</i>
0	1,00	1,00	1,00	84
1	0,99	1,00	0,99	87
2	1,00	1,00	1,00	83
3	1,00	1,00	1,00	84
4	1,00	1,00	1,00	72
5	1,00	1,00	1,00	81
6	1,00	0,99	0,99	69
<i>accuracy</i>			1,00	560
<i>macro avg</i>	1,00	1,00	1,00	560
<i>weighted avg</i>	1,00	1,00	1,00	560
Akurasi:	1,0			
<i>Mean Squared Error</i> :	0,0			

Tabel 4.6: Metrik Evaluasi Saat Parameter $n_estimators = 500$

Variabel Evaluasi	<i>Precision</i>	<i>Recall</i>	<i>f1-score</i>	<i>Support</i>
0	1,00	1,00	1,00	71
1	1,00	1,00	1,00	80
2	1,00	1,00	1,00	70
3	1,00	1,00	1,00	71
4	1,00	1,00	1,00	82
5	1,00	1,00	1,00	82
6	1,00	1,00	1,00	104
<i>accuracy</i>			1,00	560
<i>macro avg</i>	1,00	1,00	1,00	560
<i>weighted avg</i>	1,00	1,00	1,00	560
Akurasi:	1,0			
<i>Mean Squared Error</i> :	0,0			

Presisi dalam tabel mengukur akurasi model dalam mengklasifikasikan *instance* positif secara tepat. Sebagian besar kelas menunjukkan presisi tinggi, hampir mencapai 1,00 dan tiga nilai $n_estimators$ (25; 50; 500) memiliki presisi sempurna. Ini menunjukkan model mampu mengidentifikasi dan mengklasifikasikan sampel daging sapi dan babi dengan baik.

Beralih ke *recall*, yang mengevaluasi kemampuan model untuk menemukan *instance* positif, dapat dilihat bahwa hampir semua kelas dalam tabel memiliki nilai *recall* tinggi sebesar 1,00. Ini menunjukkan bahwa model berhasil mengidentifikasi sebagian besar *instance* positif untuk setiap kelas, menunjukkan kemampuannya

dalam mendeteksi dan menangkap variasi yang berbeda dalam daging sapi dan daging babi.

Metrik *F1-score*, yang menggabungkan presisi dan *recall* menjadi satu ukuran, juga menunjukkan kinerja yang baik di semua kelas dengan nilai *F1-score* tinggi sebesar 1,00. Hal ini menunjukkan keseimbangan yang baik antara presisi dan *recall*, mengimplikasikan bahwa model mencapai klasifikasi yang akurat dan kemampuan untuk menangkap sebagian besar *instance* positif untuk setiap kelas.

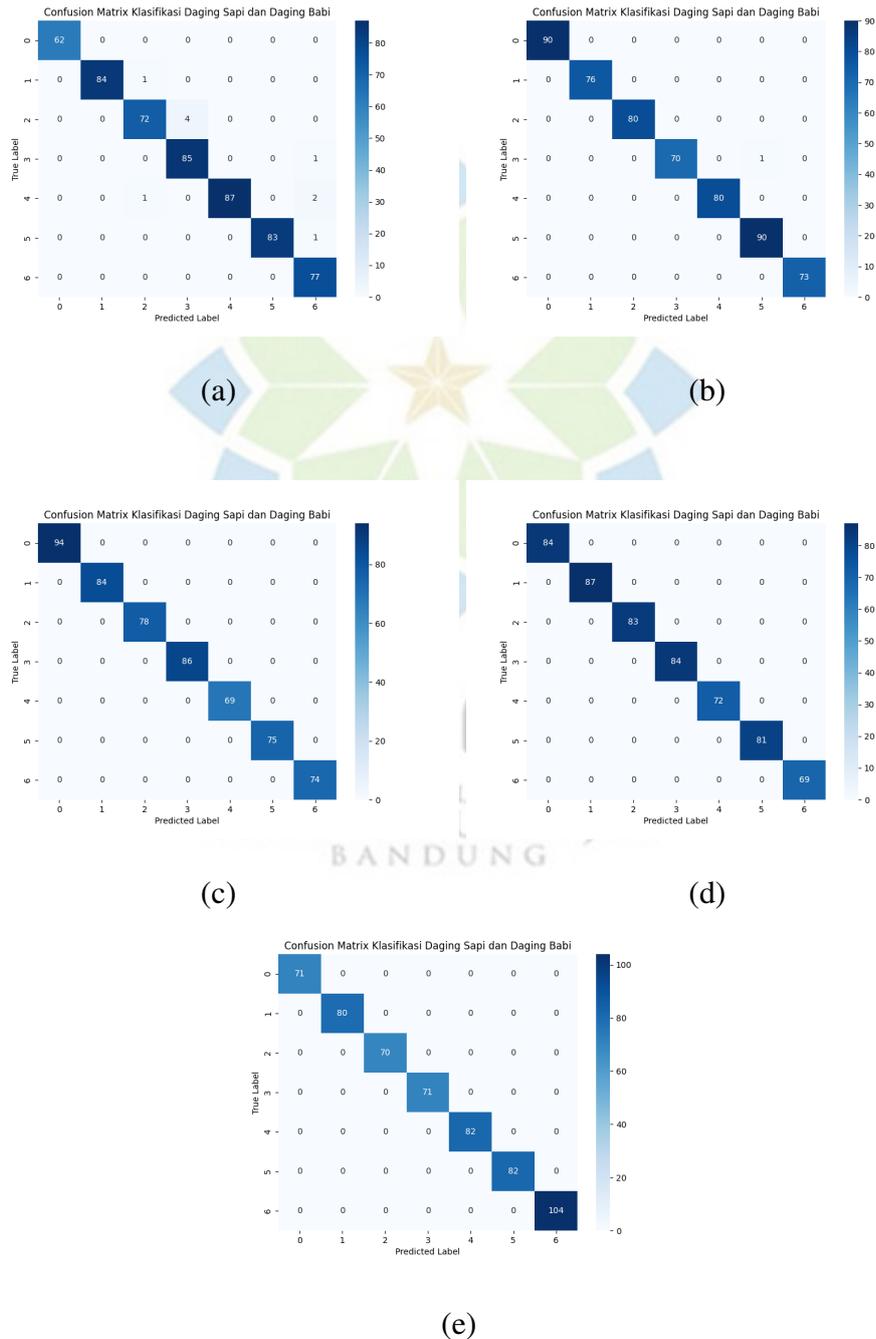
Selain itu, metrik *support* memberikan informasi tentang jumlah *instance* dalam setiap kelas. Dalam dataset ini, *support* tampaknya seimbang secara relatif di seluruh kelas, menunjukkan distribusi yang representatif dari *instance* daging sapi dan daging babi.

Secara keseluruhan, hasil evaluasi ini menunjukkan kinerja yang luar biasa dari model yang dievaluasi dalam mengklasifikasikan dan memprediksi sampel campuran daging sapi dan daging babi berdasarkan pembacaan sensor gas, khususnya untuk tiga parameter $n_estimators = (25; 50; 500)$. Nilai presisi, *recall*, dan *F1-score* yang tinggi menyoroti akurasi model dalam membedakan variasi yang berbeda dalam campuran daging sapi dan daging babi, serta memberikan keandalannya dalam aplikasi praktis seperti kontrol kualitas atau klasifikasi makanan.



4.3.3 Analisis *Confusion Matrix*

Gambar 4.9 *Confusion Matrix* merupakan salah satu alat yang berguna untuk menganalisis hasil evaluasi dari metode *Machine Learning*, seperti *Random Forest*, dalam sistem *Electronic Nose* untuk mendeteksi daging sapi dan daging babi.



Gambar 4.9: *Confusion Matrix* a). $n_{estimators} = 1$, b). $n_{estimators} = 5$, c). $n_{estimators} = 25$, d). $n_{estimators} = 50$, e). $n_{estimators} = 500$

Analisis ini melibatkan beberapa variasi yang berbeda, masing-masing mewakili parameter $n_estimators$ yang berbeda dalam metode *Random Forest*. Pertama, pada gambar dengan parameter $n_estimators$ 1, hasilnya menunjukkan kinerja yang cukup baik. Menggambarkan jumlah data yang terdeteksi dengan akurasi yang cukup tinggi yaitu 0,9821 (98,21%) dan cukup sesuai antara label prediksi dan label sebenarnya. Semua tujuh kelas (kelas 0; 1; 2; 3; 4; 5; dan 6) memiliki prediksi yang sesuai dan jumlah data yang terdeteksi sudah sesuai dengan kelasnya masing-masing.

Selanjutnya, gambar dengan parameter $n_estimators$ 5 juga menunjukkan hasil yang cukup bagus. Menunjukkan kesesuaian yang cukup baik antara prediksi dan label sebenarnya untuk semua kelas. Jumlah data yang terdeteksi pada setiap kelas juga sudah sesuai dan akurasi 0,9982 (99,82%) .

Selanjutnya gambar dengan parameter $n_estimators$ (25; 50; 500) menunjukkan hasil yang sangat baik. Menggambarkan prediksi yang sangat akurat dan jumlah data yang terdeteksi sudah sangat sesuai dengan kelasnya masing-masing, untuk nilai akurasi keduanya sudah sangat baik yaitu 1,00 (100%).

Dengan demikian, hasil analisis dari *Confusion Matrix* menunjukkan bahwa metode *Random Forest* dengan parameter $n_estimators$ (25; 50; 500) mampu memberikan prediksi yang konsisten dan akurat dalam mengklasifikasikan campuran daging sapi dan daging babi. Hal ini mengindikasikan bahwa metode ini dapat menjadi alat yang presisi dalam sistem *Electronic Nose* untuk mendeteksi variasi campuran daging sapi dan daging babi dengan tingkat keakuratan yang tinggi.

4.4 Pengujian Sampel Acak

Selanjutnya kita juga melakukan uji coba untuk beberapa sampel acak di luar database yang kita ambil. Terlihat pada **Tabel 4.7** kita melakukan uji coba pada empat variasi sampel. Pertama Sampel Daging Babi Kaleng kita lakukan uji coba pada alat Electronic Nose dengan model Random Forest dan data latih sebelumnya, kita masukan semua Daging Babi Kaleng ke dalam ruang sensor, hasil prediksi tersebut menunjukkan Daging Babi, jika dilihat dari komposisinya Daging Babi Kaleng sudah melalui berbagai proses olagan dan tercampur dengan bahan-bahan lain seperti 60% Daging Babi, Air, Pati Jagung, Protein Nabati, Pengental Karagen, Garam, *Sodium Tripolyphosphate*, Bumbu, *Sodium D-Isoascorbate*, Gula, Natrium Nitrit, meski demikian hasil prediksi sampel pertama masih sesuai antara database awal dan data prediksi.

Tabel 4.7: Uji Coba Sampel Acak

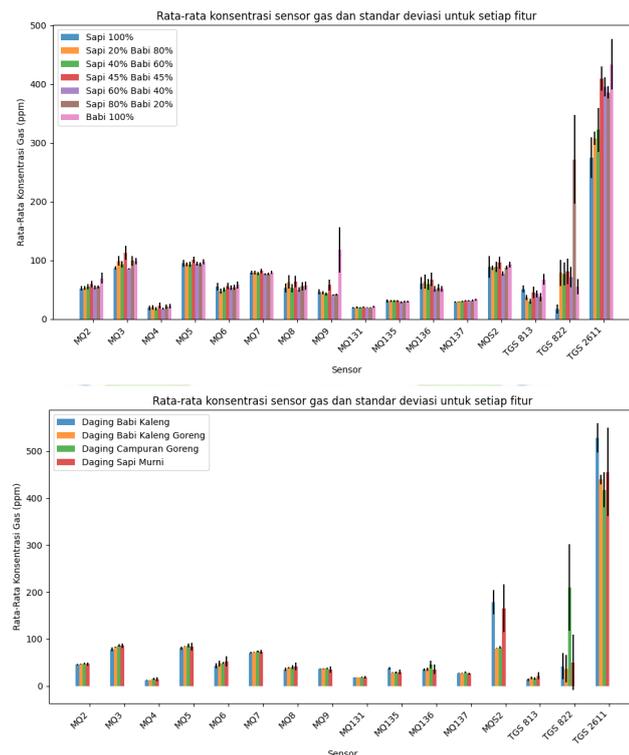
No	Sampel yang Diuji	Hasil Prediksi	Keterangan
1	Daging Babi Kaleng	Daging Babi	60% Daging Babi
2	Daging Babi Kaleng Goreng	Daging Babi	60% Daging Babi
3	Campuran Sapi dan Babi Goreng	Daging Babi	Random
4	Daging Sapi Murni	Daging Sapi	100% Daging Sapi

Untuk melakukan uji coba lebih jauh lagi, kita coba ambil sekitar tiga sendok makan Daging Babi Kaleng kemudian digoreng dalam minyak yang panas, hasil prediksinya masih menunjukkan Daging Babi, meskipun sudah tercampur dengan minyak goreng. Pengujian selanjutnya kita coba campurkan sekitar dua sendok makan daging sapi dan satu sendok daging babi kaleng, kemudian campurkan dan dibentuk bulat untuk digoreng menggunakan minyak panas, hasil prediksi masih menunjukkan Daging Babi. Terakhir kita uji coba untuk sampel 100% Daging Sapi Murni, hasil prediksi menunjukkan Daging Sapi.

Dari keempat uji coba di atas, diperoleh untuk sampel 1, 2, dan 3 menunjukkan hasil Prediksi Daging Babi. Sedangkan untuk sampel Daging Sapi Murni menunjukkan hasil prediksi Daging Sapi. Keempat sampel tersebut sudah sesuai antara database awal yang kita latih pada model Machine Learning metode Random Forest. Walaupun sampel yang diuji berada diluar database awal, hasil prediksi masih menunjukkan hasil yang cukup akurat. Hanya saja kita perlu sedikit mereduksi va-

riabel pada database awal yang asalnya ada tujuh variabel, direduksi menjadi dua variabel saja.

4.4.1 Perbandingan Sensor pada Database Awal dengan Database Hasil Prediksi



Gambar 4.10: Rata-Rata Nilai Sensor dan Standar Deviasi Database Awal dan Database Hasil Prediksi

Pada **Gambar 4.10** menunjukkan perbandingan antara database awal dengan database hasil prediksi, kedua grafik tersebut menunjukkan pola atau tren yang hampir sama, yang memungkinkan model *Machine Learning* dengan Metode *Random Forest* bisa mendeteksi dan mengklasifikasikan target dengan cukup baik. Misalnya untuk sensor TGS822 pada database awal memiliki rentang deteksi sampel terendah 35,2 ppm dan tertinggi 246 ppm, sama halnya dengan database prediksi 64,33 ppm dan tertinggi 198,34 ppm.