

Perancangan *Electronic Nose* (E-Nose) untuk Analisis dan Klasifikasi Aroma Daging Menggunakan PCA dan LDA

Muhammad Rizki Setyawan ^{a,1,*}, Abdul Fadlil ^{b,2}, Anton Yudhana ^{b,3}

^aProgram Studi Informatika, Universitas Ahmad Dahlan, Yogyakarta, 55191, Indonesia
^aProgram Studi Teknik Informatika, Universitas Muhammadiyah Sorong, Sorong, 98416, Indonesia
^{b,c}Program Studi Teknik Elektro, Universitas Ahmad Dahlan, Yogyakarta, 55191, Indonesia
¹2537083017@webmail.uad.ac.id*; ²fadlil@mti.uad.ac.id; ³eyudhana@ee.uad.ac.id
* Korespondensi penulis

Submission:28/12/2025, Revision: 07/04/2026, Accepted : 08/04/2026

Abstract

Meat is a vital food commodity prone to adulteration through species mixing or chemical contamination such as formalin and borax. This study aimed to design and test an Electronic Nose (E-Nose) system for aroma pattern analysis and meat classification using Principal Component Analysis (PCA) and Linear Discriminant Analysis (LDA). Samples included pure meat (beef, chicken, pork), mixed meat, and chemically contaminated meat. Aroma data were captured using an array of gas sensors sensitive to Volatile Organic Compounds (VOCs) and standardized prior to analysis. PCA reduced eight sensor features into three principal components explaining a total variance of 79.63%. PC1, PC2, and PC3 accounted for 46.10%, 20.58%, and 12.96% of variance, respectively, showing clustering patterns among samples with minor overlap. LDA provided clearer class separation with three discriminant components LD1, LD2, and LD3 explaining 77.13%, 16.63%, and 4.59% of between-class variance, totaling 98.34%. LD1 separated pure, mixed, and contaminated meat, LD2 distinguished variations due to contaminant type and species, and LD3 refined separation of similar classes. Classification evaluation achieved an overall accuracy of 82%. Most classes were well classified, while classes 1 and 10 experienced misclassification due to similar aroma patterns. The findings confirm that E-Nose combined with PCA and LDA is a rapid, non-destructive, and efficient method for detecting meat authenticity and adulteration, showing strong potential for food quality monitoring in the field.

Keywords: Adulteration, Electronic Nose, PCA, LDA, Meat.

Abstrak

Daging merupakan komoditas pangan vital yang rawan pemalsuan melalui pencampuran spesies atau kontaminasi kimia seperti formalin dan boraks. Penelitian ini bertujuan merancang dan menguji sistem *Electronic Nose* (E-Nose) untuk analisis pola dan klasifikasi aroma daging menggunakan *Principal Component Analysis* (PCA) dan *Linear Discriminant Analysis* (LDA). Sampel yang digunakan meliputi daging asli (sapi, ayam, babi), daging campuran, dan daging yang terkontaminasi bahan kimia. Data aroma diperoleh melalui array sensor gas yang sensitif terhadap Senyawa Organik Volatil, kemudian distandarisasi sebelum dianalisis. PCA mereduksi delapan fitur sensor menjadi tiga komponen utama, dengan total variansi yang dijelaskan sebesar 79,63%. PC1, PC2, dan PC3 masing-masing menjelaskan 46,10%, 20,58%, dan 12,96% variansi, menampilkan pola pengelompokan sampel meskipun terdapat tumpang tindih minor. LDA menghasilkan pemisahan kelas yang lebih jelas, dengan tiga komponen diskriminan LD1, LD2, dan LD3 menjelaskan 77,13%, 16,63%, dan 4,59% variansi antar kelas sehingga totalnya 98,34%. LD1 memisahkan daging murni, campuran, dan terkontaminasi, LD2 membedakan variasi akibat jenis kontaminan dan spesies, sedangkan LD3 memperhalus pemisahan kelas mirip. Evaluasi klasifikasi menunjukkan akurasi keseluruhan 82%. Sebagian besar kelas berhasil diklasifikasikan dengan baik, meskipun kelas 1 dan 10 masih mengalami kesalahan akibat kemiripan pola aroma. Hasil ini menegaskan bahwa E-Nose berbasis PCA dan LDA merupakan metode cepat, non-destruktif, dan efisien untuk mendeteksi keaslian serta pemalsuan daging, sehingga potensial untuk pengawasan mutu pangan di lapangan.

Kata kunci: Pemalsuan, Electronic Nose, PCA, LDA, Daging.

This is an open access article under the [CC BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license.



1. Pendahuluan

Daging merupakan komoditas pangan vital yang menjadi salah satu sumber protein terbaik bagi manusia, dikonsumsi secara global, dan memiliki nilai ekonomis tinggi [1], [2]. Kondisi ini menciptakan celah besar bagi praktik kecurangan, sehingga pemalsuan daging telah menjadi masalah serius di banyak negara. Pemalsuan ini tidak hanya merusak kepercayaan konsumen terhadap industri makanan, tetapi juga berpotensi membahayakan kesehatan publik [3], [4]. Praktik curang melibatkan dua bentuk utama: kontaminasi kimiawi dan pencampuran spesies. Kontaminasi terjadi dengan penggunaan bahan terlarang seperti formalin atau boraks, yang bertujuan untuk pengawetan atau perbaikan tampilan pada daging sapi, babi, maupun ayam [5], [6]. Sementara itu, kasus pencampuran spesies sering dilakukan dengan substitusi daging mahal (sapi) menggunakan daging yang lebih murah [7], [8]. Skenario yang paling mengkhawatirkan adalah kombinasi keduanya: daging babi dapat diberi boraks untuk memanipulasi tekstur dan warna agar menyerupai daging sapi sebelum dicampur atau disubstitusikan ke dalam produk. Tindakan-tindakan ini sangat merugikan, terutama bagi konsumen Muslim yang dilarang mengonsumsi daging babi (haram), serta meningkatkan potensi risiko kesehatan akibat paparan bahan kimia berbahaya [9], [10], [11].

Upaya deteksi keaslian daging saat ini menghadapi tantangan besar karena manipulasi yang dirancang agar sulit dibedakan secara visual. Secara tradisional, pengawasan mutu mengandalkan inspeksi *organoleptik* atau metode laboratorium invasif. Meskipun metode laboratorium seperti uji DNA (PCR) untuk identifikasi spesies dan analisis kimia untuk deteksi formalin dan boraks menawarkan tingkat presisi yang sangat tinggi, metode-metode tersebut tidak efisien untuk pengujian lapangan [12], [13]. Kelemahan ini mencakup biaya operasional yang tinggi, waktu analisis yang lama (seringkali membutuhkan waktu berjam-jam hingga hitungan hari untuk hasil definitif), serta keharusan menggunakan peralatan khusus yang tidak portabel. Akibatnya, pengawas pangan kesulitan melakukan pengujian cepat real-time dan masif di pasar, yang pada akhirnya menghambat efektivitas sistem pengawasan mutu pangan nasional [14], [15].

Menanggapi kebutuhan mendesak akan teknologi alternatif yang mampu menyediakan data kualifikasi cepat, non-destruktif, dan biaya-efisien, Teknologi *Electronic Nose* (E-nose) menawarkan solusi yang transformatif. E-nose bekerja dengan prinsip biomimetik, meniru mekanisme penciuman manusia melalui larik sensor gas yang sangat sensitif terhadap Senyawa Organik Volatil (VOCs) [16], [17]. Setiap jenis daging yang diuji baik daging asli (sapi, ayam, babi) maupun daging yang mengalami pemalsuan (kontaminasi formalin/boraks atau pencampuran babi) akan melepaskan profil aroma yang unik [18], [19]. Perubahan kimiawi akibat *adulterasi* akan menghasilkan pola respons sensor yang berbeda dari daging murni. Data yang dihasilkan E-nose bersifat multivariat dan kompleks, sehingga diperlukan integrasi dengan metode komputasi yang dikenal sebagai kemometrik [20]. Metode yang umum digunakan untuk menangani data multivariat adalah *Principal Component Analysis* (PCA) dan *Linear Discriminant Analysis* (LDA). PCA berfungsi untuk mereduksi dimensi data, mengekstraksi fitur paling signifikan, sekaligus memudahkan visualisasi pola utama [21], [22]. Dengan metode ini, variabel yang saling berkorelasi diubah menjadi sejumlah komponen utama yang mewakili sebagian besar variasi data, sehingga informasi penting tetap terjaga. Sebaliknya, LDA berfungsi untuk mengekstraksi fitur yang relevan sekaligus membangun model klasifikasi, dengan fokus pada pemisahan antar kelas agar setiap sampel dapat diidentifikasi secara lebih akurat [23], [24].

Pemanfaatan E-nose dengan dukungan metode PCA dan LDA menunjukkan potensi yang signifikan dalam analisis kualitas dan karakterisasi aroma produk pangan. Penelitian [25] menggunakan LDA sebagai ekstraksi fitur dan klasifikasi aroma teh hijau, dengan dua fungsi diskriminan pertama merepresentasikan 84,4% variasi data dan membentuk cluster yang membedakan merek teh, meski beberapa merek berkarakteristik mirip. Penelitian [26] mendeteksi kerusakan mikroba pada sarden segar, di mana LDA mampu membedakan sarden berdasarkan lama penyimpanan dengan akurat, dan data E-Nose berkorelasi tinggi dengan jumlah mikroba.

Penelitian [27] menggunakan E-Nose untuk menilai kemurnian minyak kayu putih yang dicampur alkohol. PCA membedakan aroma sampel berdasarkan respon tegangan sensor, dengan PC1 dan PC2 mewakili 99,64% variasi data. Klasifikasi menggunakan neural network dan decision tree menunjukkan akurasi tinggi dalam membedakan campuran. Penelitian [28] menggunakan E-Nose untuk mengidentifikasi tingkat populasi *Trichoderma sp.* pada tiga bahan organik, yaitu ampas tebu, dedak, dan gambut. PCA diterapkan untuk mengekstraksi komponen utama, dengan PC1 dan PC2 menjelaskan 92,41% variasi data, sehingga distribusi antar bahan organik dapat diamati. Selanjutnya, LDA digunakan untuk memaksimalkan pemisahan antar kelas populasi jamur, di mana LD1 dan LD2 menjelaskan 100% variansi dan membentuk *cluster* terpisah, memungkinkan identifikasi tiap tingkat populasi berdasarkan pola aroma yang dihasilkan E-Nose.

Berdasarkan permasalahan tersebut, penelitian ini bertujuan merancang dan menguji sistem E-Nose untuk analisis pola dan klasifikasi aroma daging menggunakan PCA dan LDA. Pendekatan ini memungkinkan sistem


membedakan daging asli dari berbagai spesies, daging yang tercampur spesies, serta sampel yang terkontaminasi kimia seperti formalin maupun boraks.

2. Metode Penelitian

Penelitian ini dilakukan melalui tiga tahapan utama, yaitu perancangan perangkat Electronic Nose (E-Nose), persiapan sampel, dan pengolahan data.

2.1 Tahap Perancangan *Electronic Nose* (E-Nose)

Perancangan Electronic Nose (E-Nose) dilakukan untuk menghasilkan perangkat yang mampu menangkap pola gas volatil dari setiap sampel daging secara konsisten dan berulang. Rangkaian elektronik yang digunakan pada sistem E-Nose ditunjukkan pada Gambar 1.



Gambar 1. Rangkaian Elektronik

Gambar 1 menunjukkan konfigurasi perangkat keras E-Nose, yang menggunakan Arduino Mega 2560 sebagai unit akuisisi data yang terhubung dengan array sensor MQ (MQ-2, MQ-4, MQ-9, MQ-135, MQ-137, MQ-138) dan sensor suhu-kelembapan DHT22. Sinyal analog dari seluruh sensor dibaca melalui pin ADC Arduino, kemudian dikirim ke Raspberry Pi 4 untuk perekaman, penyimpanan, dan visualisasi secara real-time melalui antarmuka Python dan modul LCD. Untuk menjaga kestabilan kinerja sensor dan komponen elektronik selama pengukuran, sistem dilengkapi dengan beberapa kipas yang berfungsi sebagai sirkulasi udara dan pendingin aktif.

2.2 Tahap Persiapan Sampel

Sampel daging dengan berat 250 g disiapkan dan dikategorikan ke dalam 10 kelas berdasarkan jenis daging dan kontaminannya. Pemalsuan dilakukan dengan merendam sampel selama 5 menit dalam larutan formalin (37%) atau boraks (15 g/L), diikuti perebusan 3 menit untuk sampel boraks guna memicu pelepasan senyawa volatil. Sampel kemudian didinginkan hingga suhu ruang agar karakteristik uap stabil saat pengukuran.

2.3 Tahap Pengolahan Data

Pengolahan data dalam penelitian ini meliputi akuisisi data aroma menggunakan E-Nose, pra-pemrosesan, ekstraksi ciri, dan evaluasi hasil. Alur tahapan pengolahan data ditunjukkan pada Gambar 2.



Gambar 2. Alur Pengolahan Data

Adapun penjelasan tahapan analisis data berdasarkan alur pada Gambar 2 adalah sebagai berikut:

2.2.1 Akuisisi Data dengan E-Nose

Akuisisi data merupakan tahap pengambilan sinyal aroma dari sampel menggunakan perangkat E-Nose. Sebelum akuisisi, dilakukan sensing selama 1 menit untuk memastikan senyawa volatil mengalir ke sensor. Setiap sampel direkam dalam 5 sesi, masing-masing 2 menit dengan frekuensi 5 Hz. Sinyal analog dikonversi menjadi digital melalui ADC dan disimpan dalam format CSV. Setelah setiap sesi, dilakukan flushing 10 menit menggunakan udara bersih untuk mengembalikan sensor ke kondisi dasar (baseline). Rincian jenis sampel dan jumlah data ditunjukkan pada Tabel 1.

Tabel 1. Sampel dan Data

No	Jenis Sampel	Komposisi	Data per Sesi	Total Data (5 sesi)
1	Sapi	250 g sapi	600	3.000
2	Sapi + formalin	250 g sapi + formalin	600	3.000
3	Sapi + boraks	250 g sapi + boraks	600	3.000

No	Jenis Sampel	Komposisi	Data per Sesi	Total Data (5 sesi)
4	Babi	250 g babi	600	3.000
5	Babi + formalin	250 g babi + formalin	600	3.000
6	Babi + boraks	250 g babi + boraks	600	3.000
7	Ayam	250 g ayam	600	3.000
8	Ayam + formalin	250 g ayam + formalin	600	3.000
9	Ayam + boraks	250 g ayam + boraks	600	3.000
10	Campuran sapi-babi	125 g sapi + 125 g babi	600	3.000
Total Data			6.000	30.000

2.2.2 Pra-Pemrosesan Data

Data hasil akuisisi selanjutnya melalui tahap pra-pemrosesan untuk memastikan kualitas data sebelum dianalisis lebih lanjut. Pada tahap ini, pembagian dataset hanya diterapkan untuk proses klasifikasi menggunakan LDA, dengan membagi data menjadi data latih dan data uji pada rasio 70:30, sebagaimana ditunjukkan pada Tabel 2.

Tabel 2. Pembagian Dataset

No	Split	Rasio	Dataset
1	Training	70%	21.000
2	Testing	30%	9.000

Setelah pembagian dataset, setiap fitur sensor dilakukan standarisasi [29]. Pada PCA, standarisasi diterapkan pada seluruh dataset karena PCA digunakan untuk keperluan eksplorasi dan visualisasi sebaran data. Sementara itu, pada LDA, standarisasi dilakukan setelah pembagian dataset untuk menghindari terjadinya data leakage, sesuai dengan persamaan berikut:

$$z_i = \frac{x_i - \mu_i}{\sigma_i} \quad (1)$$

Pada Persamaan (1), z_i adalah nilai standar untuk fitur ke- i , x_i adalah nilai data asli fitur ke- i , μ_i adalah rata-rata fitur ke- i , dan σ_i adalah standar deviasi fitur ke- i . Transformasi ini menghasilkan distribusi dengan rata-rata 0 dan standar deviasi 1, sehingga setiap fitur berkontribusi seimbang.

2.2.3 Ekstraksi Ciri

Tahap ekstraksi ciri dilakukan untuk memperoleh representasi fitur yang paling informatif dari data sensor gas. Pada penelitian ini, ekstraksi ciri dilakukan menggunakan dua pendekatan, yaitu *Principal Component Analysis* (PCA) dan *Linear Discriminant Analysis* (LDA), yang diterapkan secara terpisah sesuai dengan tujuan analisisnya.

A. *Principal Component Analysis* (PCA)

PCA digunakan sebagai metode ekstraksi ciri secara *unsupervised* untuk mereduksi dimensi data dengan membentuk variabel baru melalui kombinasi linear dari fitur yang telah distandarisasi [30]. Secara sederhana, PCA membantu kita melihat "pola utama" dalam kumpulan data yang besar dan rumit. Alur pembentukan komponen utama dimulai dengan menghitung matriks kovarians Σ untuk menangkap hubungan antar fitur:

$$\Sigma = \frac{1}{N-1} Z^T Z \quad (2)$$

Pada Persamaan (2), N adalah jumlah sampel dan Z adalah rata-rata fitur. Selanjutnya, dilakukan dekomposisi eigen pada matriks kovarians tersebut untuk menentukan arah variansi maksimum:

$$\Sigma w_i = w_i \lambda_i \quad (3)$$

Pada Persamaan (3), w_i adalah vektor eigen yang menunjukkan arah sumbu komponen utama, dan λ_i adalah nilai eigen yang menunjukkan besar variansi data sepanjang arah tersebut. Setelah bobot w_{ji} diperoleh dari vektor eigen, skor komponen utama ke- i dapat dibentuk melalui kombinasi linear sebagai berikut:

$$t_i(k) = \sum_{j=1}^p w_{ji} Z_{kj} \quad (4)$$

Pada Persamaan (4), $t_i(k)$ adalah skor komponen utama ke- i untuk sampel ke- k , w_{ji} adalah bobot kontribusi fitur ke- j pada komponen ke- i , Z_{kj} adalah nilai fitur ke- j pada sampel ke- k yang telah distandarisasi, dan p adalah jumlah fitur. Tiga vektor eigen dengan nilai eigen terbesar dipilih sebagai sumbu utama (PC1,

PC2, PC3) untuk menangkap variansi maksimum. Proyeksi ini memfasilitasi identifikasi pola pengelompokan sampel secara intuitif melalui scatter plot 3D berdasarkan kemiripan karakteristik fiturnya.

B. Linear Discriminant Analysis (LDA)

LDA digunakan sebagai metode ekstraksi ciri secara *supervised* yang bertujuan untuk memaksimalkan keterpisahan antar-kelas dengan meminimalkan variasi di dalam kelas [31]. Hal ini dilakukan untuk mendapatkan proyeksi fitur yang optimal dalam membedakan antar kategori data. Proses LDA diawali dengan perhitungan matriks scatter untuk menilai sebaran data. Matriks sebaran dalam-kelas S_W mengukur variasi data di dalam masing-masing kelas dan dirumuskan sebagai:

$$S_W = \sum_{c=1}^C \sum_{i=1}^{N_c} (x_{c,i} - u_c) (x_{c,i} - u_c)^T \quad (5)$$

Pada Persamaan (5), S_W adalah matriks sebaran dalam-kelas, C adalah jumlah kelas, N_c adalah jumlah sampel pada kelas ke- c , $x_{c,i}$ adalah vektor fitur sampel ke- i pada kelas ke- c , dan u_c adalah rata-rata fitur kelas ke- c . Semakin kecil S_W , sampel dalam kelas semakin rapat.

Selanjutnya, matriks sebaran antar-kelas S_B mengukur jarak antara pusat kelas terhadap rata-rata global dan dihitung menggunakan persamaan:

$$S_B = \sum_{c=1}^C n_c (u_c - u) (u_c - u)^T \quad (6)$$

Pada Persamaan (6), S_B adalah matriks sebaran antar-kelas, C adalah jumlah kelas, n_c adalah jumlah sampel pada kelas ke- c , u_c adalah rata-rata kelas ke- c , dan u adalah rata-rata global dari semua sampel. Semakin besar S_B , semakin terpisah pusat kelas, sehingga kelas-kelas lebih mudah dibedakan.

Berdasarkan kedua matriks scatter tersebut, LDA menentukan vektor bobot w dengan memaksimalkan fungsi diskriminan Fisher:

$$j(w) = \frac{w^T S_B w}{w^T S_W w} \quad (7)$$

Pada Persamaan (7), $J(w)$ adalah fungsi objektif Fisher, w adalah vektor proyeksi, S_B adalah matriks sebaran antar-kelas, dan S_W adalah matriks sebaran dalam-kelas. Nilai $J(w)$ yang besar menunjukkan arah proyeksi yang optimal, yaitu memaksimalkan jarak antar pusat kelas sekaligus meminimalkan variasi dalam kelas.

Untuk memperoleh vektor proyeksi pe yang memaksimalkan fungsi objektif tersebut, masalah ini ditransformasikan menjadi penyelesaian persamaan karakteristik melalui dekomposisi nilai eigen (*eigenvalue decomposition*):

$$S_W^{-1} S_B w = \lambda w \quad (8)$$

Pada Persamaan (8), $S_W^{-1} S_B$ adalah hasil perkalian invers matriks sebaran dalam-kelas dengan matriks sebaran antar-kelas, w adalah vektor eigen, dan λ adalah nilai eigen yang merepresentasikan rasio variasi antar-kelas terhadap variasi dalam-kelas. Vektor eigen dengan nilai eigen terbesar digunakan sebagai arah proyeksi optimal.

Setelah matriks bobot diperoleh, data diproyeksikan ke dimensi rendah melalui transformasi linear untuk menghasilkan vektor skor. Mengingat jumlah kelas $C > 3$, tiga komponen utama teratas digunakan sebagai sumbu visualisasi scatter plot 3D. Proyeksi ini berfungsi untuk memetakan pengelompokan sampel berdasarkan kesamaan karakteristiknya secara intuitif.

2.2.4 Klasifikasi dan Evaluasi

Setelah ciri diekstraksi menggunakan LDA, tahap selanjutnya adalah melakukan klasifikasi untuk menentukan identitas sampel. Fungsi diskriminan digunakan berdasarkan rumus:

$$\delta_c(x) = x^T \Sigma^{-1} \mu_c - \frac{1}{2} \mu_c^T \Sigma^{-1} \mu_c + \ln P(c) \quad (9)$$

Pada Persamaan (9), $\delta_c(x)$ adalah fungsi diskriminan LDA untuk kelas c , x adalah sampel, μ_c adalah rata-rata kelas ke- c , dan Σ^{-1} adalah invers matriks kovarians. Sampel diklasifikasikan ke kelas dengan nilai $\delta_c(x)$ terbesar, sedangkan $\ln P(c)$ mempertimbangkan probabilitas prior kelas. Hasil akhir prediksi kelas ditentukan berdasarkan nilai skor tertinggi menggunakan kriteria keputusan pada rumus:

$$\hat{y} = \arg \max_c \delta_c(x) \quad (10)$$

Pada persamaan (10), \hat{y} adalah hasil prediksi kelas, c merupakan indeks kelas, dan $\delta_c(x)$ adalah nilai fungsi diskriminan untuk kelas ke- c . Dengan persamaan ini, setiap sampel dipetakan ke kelas yang memiliki nilai diskriminan tertinggi sehingga diperoleh klasifikasi yang optimal.

Selanjutnya, kinerja model dievaluasi menggunakan Confusion Matrix serta metrik *Precision*, *Recall*, *F1-score*, dan *Accuracy* [32] menggunakan rumus:

$$Precision = \frac{TP}{TP+FP} \quad (11)$$

$$Recall = \frac{TP}{TP+FN} \quad (12)$$

$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (13)$$

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (14)$$

Pada Persamaan (11)–(14), TP adalah *True Positive*, FP adalah *False Positive*, TN adalah *True Negative*, dan FN adalah *False Negative*.

3. Hasil dan Pembahasan

3.1 Tahap Implementasi Perangkat E-nose

Hasil perancangan perangkat E-Nose yang telah dirakit ditunjukkan pada Gambar 3. Perangkat ini digunakan untuk proses pengambilan data dengan menempatkan sampel pada kompartemen bawah, di mana aroma dialirkan menggunakan kipas menuju ruang sensor untuk merekam karakteristik volatilnya.



Gambar 3. Hasil Perancangan Elektronik Nose

3.2. Tahap Persiapan Sampel

Persiapan Sampel Persiapan menghasilkan 10 variasi kelas daging bermassa seragam sebagaimana ditunjukkan pada Gambar 4(a). Sampel dengan formalin dan boraks memiliki tekstur lebih padat serta aroma lebih tajam dibanding sampel murni, sebagaimana ditunjukkan pada Gambar 4(b). Pada perlakuan boraks, proses perebusan dan pengkondisian suhu dilakukan untuk memicu penguapan senyawa volatil, sebagaimana ditunjukkan pada Gambar 4(c). Seluruh sampel kemudian wadah untuk diukur menggunakan E-Nose.



(a) Penimbangan berat

(b) Perendaman dengan bahan kimia.

(c) Perebusan Sampel Boraks

Gambar 4. Tahapan Persiapan Sampel

3.3. Tahap Pengolahan Data

3.3.1 Akuisisi Data

Proses pengambilan data dilakukan pada berbagai variasi sampel daging, meliputi sampel murni, campuran, serta yang telah diperlakukan dengan formalin atau boraks. Contoh pengukuran menggunakan sistem E-Nose ditunjukkan pada Gambar 5.



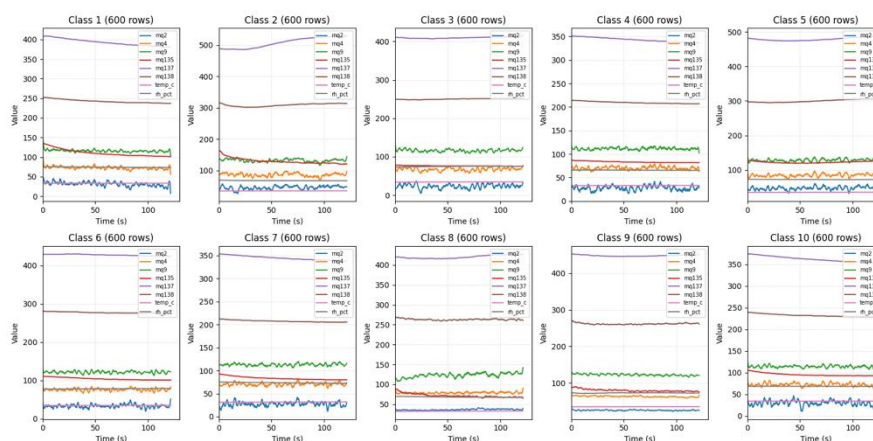
Gambar 5. Contoh Akuisisi Data Sampel

Gambar 5 memperlihatkan salah satu proses pengambilan data E-Nose pada berbagai variasi sampel daging. Dataset profil aroma yang dihasilkan mencakup nilai sensor, suhu, kelembapan, dan kelas sampel, beberapa baris contohnya ditunjukkan pada Tabel 3.

Tabel 3. Contoh Dataset Per Kelas

No	mq2	mq4	mq9	mq135	mq137	mq138	temp_c	rh_pct	class_id
1	29	117	171	135	408	252	33.1	75	1
2	59	114	159	135	408	251	33.1	75	1
...
3002	62	94	129	164	488	315	35.1	69.4	2
3003	22	86	134	164	489	316	35.1	69.4	2
...
6002	16	84	140	78	411	249	34	72.8	3
6003	19	85	141	78	411	249	34	72.8	3
...
9002	36	87	127	87	351	214	33	65.8	4
9003	7	74	121	87	351	214	33	65.8	4
...
12002	60	109	152	129	482	298	35	72.9	5
12003	18	87	139	128	482	298	35	72.9	5
...
15002	37	99	145	111	429	281	34.5	77.4	6
15003	45	75	114	111	429	281	34.5	77.4	6
...
18002	15	78	125	93	353	212	31.3	75.2	7
18003	39	72	109	93	353	212	31.3	75.2	7
...
21002	42	88	107	85	423	272	32.1	69.7	8
21003	33	93	125	92	422	270	32.1	69.7	8
...
24002	28	68	126	90	451	265	34.1	72.5	9
20003	28	70	131	90	453	265	34.1	72.5	9
...
29999	18	70	120	102	379	239	33.7	70	10
30000	24	70	117	102	379	239	33.7	70	10

Tabel 3 memperlihatkan contoh struktur dataset hasil akuisisi E-Nose yang terdiri dari 30.000 sampel dengan 10 kelas. Data ini mencakup delapan fitur input yang terdiri dari enam sensor gas seri MQ dan sensor lingkungan. Pengambilan data dilakukan dalam 5 sesi terpisah untuk setiap kelas guna menjamin variabilitas data, yang selanjutnya digunakan sebagai basis analisis reduksi dimensi menggunakan PCA dan klasifikasi menggunakan LDA. Dinamika respons sensor dari salah satu sesi pengukuran divisualisasikan dalam grafik, ditunjukkan pada Gambar 6.



Gambar 6. Contoh Grafik Respons Sensor untuk 1 Sesi

Gambar 6 memperlihatkan dinamika enam sensor gas dan dua parameter lingkungan untuk sepuluh kelas. Setiap kelas menunjukkan pola sensor khas dengan MQ137 dan MQ138 relatif tinggi dan MQ2, MQ4, serta MQ9 stabil. Temperatur dan kelembapan relatif konstan, menunjukkan kondisi lingkungan yang konsisten.

3.3.2 Pra-Pemrosesan Data

Sebelum analisis, seluruh fitur sensor distandarisasi sehingga memiliki rata-rata 0 dan standar deviasi 1, mencegah dominasi fitur dengan skala besar. Parameter awal tiap fitur ditunjukkan pada Tabel 4. Transformasi ini menghasilkan data dengan skala seragam, ditunjukkan pada lima sampel pertama pada Tabel 5.

Tabel 4. Parameter Statistik Fitur Sensor

No	Fitur Sensor	Rata-rata (μ)	Standar Deviasi (σ)
1	mq2	31.84	14.57
2	mq4	73.23	13.42
3	mq9	120.34	14.11
4	mq135	95.28	18.21
5	mq137	408.66	45.17
6	mq138	255.65	29.61
7	temp_c	33.88	1.11
8	rh_pct	70.42	3.28

Dari Tabel 4 terlihat bahwa fitur mq137 memiliki rata-rata tertinggi dan standar deviasi terbesar, menunjukkan level pengukuran yang tinggi dan fluktuatif, sedangkan fitur temp_c memiliki standar deviasi terkecil, mencerminkan pengukuran suhu yang stabil.


Tabel 5. Contoh Dataset Hasil Standarisasi

No	mq2	mq4	mq9	mq135	mq137	mq138	temp_c	rh_pct
1	-0.20	3.26	3.59	2.18	-0.01	-0.12	-0.71	1.40
2	1.86	3.04	2.74	2.18	-0.01	-0.16	-0.71	1.40
3	2.07	-0.17	-0.95	2.18	-0.01	-0.16	-0.71	1.40
4	1.66	-0.84	-1.80	2.18	-0.01	-0.12	-0.71	1.40
5	-0.06	0.80	0.76	2.18	-0.01	-0.12	-0.71	1.40

Dari Tabel 5 terlihat bahwa beberapa fitur, seperti mq4 dan mq9, memiliki nilai *z-score* positif tinggi pada data nomor 1–2, menunjukkan pengukuran lebih tinggi dari rata-rata. Fitur temp_c memiliki nilai *z-score* negatif konsisten, mencerminkan pengukuran yang lebih rendah dari rata-rata. Proses ini memastikan semua fitur berada pada skala yang sama sebelum analisis lebih lanjut, seperti PCA atau LDA.

3.3.3 Ekstraksi Ciri Menggunakan PCA dan LDA


PCA diterapkan untuk mereduksi dimensi fitur menjadi tiga komponen utama, sehingga struktur data lebih sederhana tanpa kehilangan variansi signifikan. Hasil proyeksi ke dalam komponen PC1, PC2, dan PC3 divisualisasikan dalam ruang tiga dimensi, yang ditunjukkan pada Gambar 7.



Gambar 7. Visualisasi Proyeksi PCA dalam Ruang 3D.

Gambar 7 menunjukkan hasil proyeksi data sensor E-Nose ke tiga komponen utama menggunakan PCA. Warna titik mewakili 10 kelas sampel. PC1, PC2, dan PC3 menangkap 46,10%, 20,58%, dan 12,96% variansi data, sehingga total variansi yang dijelaskan oleh ketiga komponen utama ini adalah 79,63%, menunjukkan bahwa sebagian besar variasi data berhasil direpresentasikan. Beberapa kelas membentuk kluster yang terpisah, meski ada sedikit tumpang tindih karena PCA bersifat *unsupervised*.

LDA digunakan mengoptimalkan keterpisahan antar-kelas dengan memanfaatkan informasi label kelas. Data diproyeksikan ke dalam komponen diskriminan utama LD1, LD2, dan LD3, sehingga pola pengelompokan sampel dapat dianalisis. Visualisasi proyeksi dalam ruang tiga dimensi menunjukkan masing-masing kelas membentuk cluster yang relatif terpisah, seperti ditampilkan pada Gambar 8.



Gambar 8. Visualisasi Proyeksi LDA dalam Ruang 3D.

Gambar 8 menunjukkan hasil proyeksi data sensor E-Nose ke tiga komponen LDA, dengan warna titik merepresentasikan 10 kelas sampel. Komponen LD1, LD2, dan LD3 masing-masing menjelaskan 77,13%, 16,63%, dan 4,59% variansi antar-kelas, sehingga total variansi yang dapat dijelaskan mencapai 98,34%. Hasil ini menunjukkan bahwa LDA efektif dalam mempertahankan informasi diskriminatif antar-kelas. Visualisasi menunjukkan bahwa sebagian besar kelas membentuk kluster yang jelas terpisah, meskipun beberapa kelas masih mengalami tumpang tindih minor. Secara keseluruhan, pemisahan kelas yang dihasilkan LDA lebih optimal dibandingkan dengan PCA.

3.3.4 Klasifikasi dan Evaluasi

Selanjutnya, fungsi diskriminan digunakan untuk mengklasifikasikan data uji dengan mempertimbangkan estimasi kovarians dan probabilitas prior kelas. Prediksi kelas ditentukan berdasarkan nilai diskriminan tertinggi, sedangkan kinerja klasifikasi dievaluasi menggunakan *Confusion Matrix* dan *Classification Report* untuk menilai akurasi serta konsistensi model. Hasil evaluasi tersebut ditunjukkan pada Gambar 9 dan Gambar 10.



Gambar 9. Confusion Matrix LDA.

	precision	recall	f1-score	support
1	0.35	0.34	0.34	1200
2	1.00	1.00	1.00	1200
3	1.00	0.50	0.67	1200
4	1.00	1.00	1.00	1200
5	0.97	1.00	0.98	1200
6	1.00	1.00	1.00	1200
7	1.00	1.00	1.00	1200
8	1.00	1.00	1.00	1200
9	0.71	1.00	0.83	1200
10	0.35	0.38	0.37	1200
accuracy			0.82	12000
macro avg	0.84	0.82	0.82	12000
weighted avg	0.84	0.82	0.82	12000

Gambar 10. Classification Report LDA

Gambar 9 menunjukkan dominasi nilai pada diagonal utama, menandakan mayoritas sampel berhasil diklasifikasikan dengan benar. Namun, selaras dengan tumpang tindih visual pada Gambar 9, terdapat kesalahan klasifikasi pada kelas 1 dan 10. Hal ini mengindikasikan adanya kemiripan karakteristik sinyal sensor pada kelas-kelas tersebut sehingga batas pemisahan antar-kelas menjadi kurang jelas. Temuan ini diperkuat oleh Gambar 10 yang memperlihatkan akurasi keseluruhan sebesar 82%. Mayoritas kelas seperti kelas 2 sampai 8 menunjukkan performa yang sangat tinggi, sementara penurunan kinerja pada kelas 1 dan 10 tetap konsisten dengan pola kesalahan pada matriks.

4. Kesimpulan

Penelitian ini berhasil merancang dan menguji sistem Electronic Nose untuk analisis pola dan klasifikasi aroma daging menggunakan PCA dan LDA. Sistem ini mampu membedakan daging asli dari berbagai spesies, daging campuran, serta sampel yang terkontaminasi formalin atau boraks. Hasil PCA mereduksi delapan fitur sensor menjadi tiga komponen utama dengan total variansi data sebesar 79,63%, di mana komponen pertama menjelaskan 46,10%, komponen kedua 20,58%, dan komponen ketiga 12,96%. Visualisasi PCA menunjukkan kecenderungan pengelompokan antar kelas aroma, meskipun terdapat sedikit tumpang tindih karena sifat metode yang *unsupervised*.

Sedangkan LDA menghasilkan pemisahan kelas yang lebih jelas. Tiga komponen diskriminan LD1, LD2, dan LD3 menjelaskan masing-masing 77,13%, 16,63%, dan 4,59 % variansi antar kelas sehingga total variansi data sebesar 98,34%. LD1 memisahkan kelas utama daging murni, terkontaminasi, dan campuran, LD2 membedakan variasi aroma akibat jenis kontaminan dan spesies, sedangkan LD3 memperhalus pemisahan kelas yang mirip. Visualisasi LDA menunjukkan kluster lebih terpisah dan representatif untuk klasifikasi. Pada tahap klasifikasi, model LDA mencapai akurasi 82%. Sebagian besar kelas, terutama kelas 2 hingga 8, diklasifikasikan dengan sangat baik, sedangkan kelas 1 dan 10 mengalami kesalahan akibat kemiripan pola aroma. Temuan ini menunjukkan bahwa meskipun LDA efektif, beberapa kelas masih memerlukan peningkatan fitur, sensor tambahan, atau integrasi metode klasifikasi yang lebih kompleks.

Secara keseluruhan, pendekatan *Electronic Nose* berbasis PCA dan LDA terbukti cepat, non destruktif, dan efisien untuk mendeteksi keaslian serta pemalsuan daging, dan layak dikembangkan untuk pengawasan mutu pangan di lapangan.

5. Daftar Pustaka

- [1] S. Bagas Valentino, "Klasifikasi Kualitas Daging Marmer Berdasarkan Citra Warna Daging Menggunakan Metode Convolutional Neural Network," *JATI (Jurnal Mhs. Tek. Inform., vol. 7, no. 1, pp. 125–129, 2023, doi: 10.36040/jati.v7i1.6128.*
- [2] E. P. Silmina, Sunardi, and A. Yudhana, "Comparative Analysis Of Yolo Deep Learning Model For Image-Based Beef Freshness Detection," *JTIK (Jurnal Ilmu Pengetah. Dan Teknol. Komputer), vol. 11, no. 1, pp. 250–265, 2025, doi: 10.33480/jtik.v11i1.6784.dilakukan.*
- [3] Y. Pangestu, S. Sanjaya, Jsril, S. Agustian, and N. Safaat, "Pengembangan Aplikasi Pendeteksi Daging Sapi dan Babi Menggunakan Deep Learning Arsitektur EfficientNet-B6 Berbasis Android," *J. Inform. Ekon. Bisnis, vol. 7, pp. 298–303, 2025, doi: 10.37034/infeb.v7i2.1195.*
- [4] Edi and O. Pribadi, "Aplikasi Pembeda Daging Sapi dan Babi dengan Metode Color Moment dan Local Binary Pattern Histogram," *Bull. Comput. Sci. Res., vol. 3, no. 5, pp. 336–342, 2023, doi: 10.47065/bulletincsr.v3i5.260.*
- [5] D. Sulistiyorini, "Qualitative Examination of the Borax and Formalin Content in Food Ingredients and Snack Food," *Int. J. Multidiscip. Approach Res. Sci., vol. 2, no. 02, pp. 954–963, 2024, doi: 10.59653/ijmars.v2i02.781.*
- [6] S. Abdul Azis, Z. Zulaika, A. Febriansyah, and N. Khasanah, "Identifikasi Kandungan Formalin dan Kesegaran Daging Sapi dengan Image Processing," *J. Inov. Teknol. Terap., vol. 2, no. 1, pp. 262–268, Feb. 2024, doi: 10.33504/jitt.v2i1.201.*
- [7] I. Syauckani, S. Z. B. M. Muji, and C. U. Eh Kan, "Classification of Beef and Pork Using a Hybrid Model of ResNet-50 and Support Vector Machine (SVM)," *AMPLITUDO J. Sci. Technol. Innov., vol. 4, no. 1, pp. 65–70, 2025, doi: 10.56566/amplitudo.v4i1.193.*
- [8] S. Surjith and S. M. Alex Raj, "A Custom 1D ResNet-GRU Model for Accurate Pork Adulteration Classification in Beef," *Int. Conf. Trends Eng. Syst. Technol. ICTEST 2025 - Proc., vol. 1, pp. 1–6, 2025, doi: 10.1109/ICTEST64710.2025.11042653.*
- [9] K. R. Mahmudah, M. K. Biddinika, D. C. Hakika, W. P. Tresna, I. T. Sugiarto, and I. Syafarina,

- “Automated Detection of Porcine Gelatin Using Deep Learning-Based E-Nose to Support Halal Authentication,” *J. Electron. Electromed. Eng. Med. Informatics*, vol. 7, no. 1, pp. 220–230, 2025, doi: 10.35882/jeemi.v7i1.654.
- [10] C. Huang and Y. Gu, “A Machine Learning Method for the Quantitative Detection of Adulterated Meat Using a MOS-Based E-Nose,” *Foods*, vol. 11, no. 4, pp. 1–17, 2022, doi: 10.3390/foods11040602.
- [11] W. S. M. Sanjaya *et al.*, “Electronic Nose with Artificial Neural Network Method on Raspberry Pi 4 for Detecting Pork and Beef,” *Proceeding - 2023 Int. Conf. Artif. Intell. Robot. Signal Image Process. AIRoSIP 2023*, no. August, pp. 52–57, 2023, doi: 10.1109/AIRoSIP58759.2023.10874021.
- [12] A. Nafi’, S. Avivi, B. Kuswandi, and A. Rohman, “E-nose for halal food authentication: a review,” *Food Res.*, vol. 9, no. 3, pp. 235–244, Jun. 2025, doi: 10.26656/fr.2017.9(3).061.
- [13] C. Yang *et al.*, “Detection and characterization of meat adulteration in various types of meat products by using a high-efficiency multiplex polymerase chain reaction technique,” *Front. Nutr.*, vol. 9, Sep. 2022, doi: 10.3389/fnut.2022.979977.
- [14] S. Harnsoongnoen, N. Babpan, S. Srisai, P. Kongkeaw, and N. Srisongkram, “A Portable Electronic Nose Coupled with Deep Learning for Enhanced Detection and Differentiation of Local Thai Craft Spirits,” *Chemosensors*, vol. 12, no. 10, 2024, doi: 10.3390/chemosensors12100221.
- [15] R. Vanaraj, B. I.P, G. Mayakrishnan, I. S. Kim, and S. C. Kim, “A Systematic Review of the Applications of Electronic Nose and Electronic Tongue in Food Quality Assessment and Safety,” *Chemosensors*, vol. 13, no. 5, pp. 1–23, 2025, doi: 10.3390/chemosensors13050161.
- [16] C. M. Badgular, S. Swaminathan, and A. Gerken, “Electronic Nose for Agricultural Grain Pest Detection, Identification, and Monitoring: A Review,” May 2025, doi: 10.48550/arXiv.2505.01301.
- [17] V. A. Binson and S. Thomas, “The Development of a Mobile E-Nose System for Real-Time Beef Quality Monitoring and Spoilage Detection †,” *Eng. Proc.*, vol. 56, no. 1, pp. 1–6, 2023, doi: 10.3390/ASEC2023-15960.
- [18] A. Feyzioglu and Y. S. Taspinar, “Beef Quality Classification with Reduced E-Nose Data Features According to Beef Cut Types,” *Sensors*, vol. 23, no. 4, pp. 12–14, 2023, doi: 10.3390/s23042222.
- [19] A. A. S. Pradhana *et al.*, “Sensor Array System Based on Electronic Nose to Detect Borax in Meatballs with Artificial Neural Network,” *J. Electr. Comput. Eng.*, vol. 2023, 2023, doi: 10.1155/2023/8847929.
- [20] C. Zang *et al.*, “Electronic nose based on multiple electrospinning nanofibers sensor array and application in gas classification,” *Front. Sensors*, vol. 4, May 2023, doi: 10.3389/fsens.2023.1170280.
- [21] S. D. Astuti, A. B. Muhamad, A. Rahmatillah, A. K. Yaqubi, Y. Susilo, and A. K. Aji, “Electronic Nose (E-Nose) for Quality Detection of Tuna (*Thunnus thynnus*) Contaminated Bacteria,” *Indones. J. Trop. Infect. Dis.*, vol. 11, no. 1, pp. 52–65, 2023, doi: 10.20473/ijtid.v11i1.39206.
- [22] I. Carotti, D. R. Billson, D. A. Hutchins, P. Liddicott, and J. A. Covington, “Detection of Rust Corrosion in Mild Steel and Stainless Steel Through Headspace Analysis by Electronic Noses,” *IEEE Sens. J.*, vol. 25, no. 12, pp. 22573–22579, 2025, doi: 10.1109/JSEN.2025.3562033.
- [23] M. I. A. Saputro, K. Setyadjit, and L. A. Swarga, “Klasifikasi Aroma Jenis Kopi Menggunakan Sensor Gas dan Algoritma LDA,” *Uranus J. Ilm. Tek. Elektro, Sains dan Inform.*, vol. 3, no. 1, pp. 01–13, 2025, doi: 10.61132/uranus.v3i1.623.
- [24] K. O. Kombo *et al.*, “Enhancing classification rate of electronic nose system and piecewise feature extraction method to classify black tea with superior quality,” *Sci. African*, vol. 24, p. e02153, 2024, doi: 10.1016/j.sciaf.2024.e02153.
- [25] K. Kusairi, M. Muthmainnah, Imam Tazi, and Moh. Fajrul Falah, “Klasifikasi Pola Aroma Teh Hijau Menggunakan Hidung Elektronik (E-Nose) Berbasis Linear Diskriminan Analisis (LDA),” *J. Pendidik. Mipa*, vol. 12, no. 3, pp. 868–874, 2022, doi: 10.37630/jpm.v12i3.682.
- [26] H. S. Al-Hooti, I. M. Al-Bulushi, Z. H. Al-Attabi, M. S. Rahman, L. K. Al-Subhi, and N. A. Al-Habsi, “Efficiency of Electronic Nose in Detecting the Microbial Spoilage of Fresh Sardines (*Sardinella longiceps*),” *Foods*, vol. 13, no. 3, 2024, doi: 10.3390/foods13030428.
- [27] A. Mujadin, S. Putra Rifaldi, O. Nur Samijayani, H. Suyono, A. Lastryanto, and P. Teknik Elektro, “Pengujian Kemurnian Minyak Kayu Putih Berbasis Electronic Nose Menggunakan Metode PCA Dan Neural Network,” *BULLET J. Multidisiplin Ilmu*, vol. 3, no. 01, pp. 40–47, 2024.
- [28] M. Rizki, B. H. Iswanto, and A. S. Mulyatni, “Identifikasi Tingkat Populasi Jamur *Trichoderma* Sp . Pada Bahan Organik Menggunakan Electronic Nose (E-Nose),” in *Prosiding Seminar Nasional Fisika (E-Journal)*, 2025, pp. 237–243.
- [29] D. Ignasius, R. D. Levandra, R. R. Sani, and I. N. Dewi, “Comparative Evaluation of Machine Learning Algorithms with Data Balancing Approach and Hyperparameter Tuning in Predicting Thyroid Disorder Recurrence,” *J. Masy. Inform.*, vol. 16, no. 2, pp. 284–300, 2025, doi: 10.14710/jmasif.16.2.75073.
- [30] M. A. B. Al-tarawneh, A. Al-khresheh, O. Al-irr, and A. Kulaglic, “Towards Accurate Fake News

- Detection : Evaluating Machine Learning Approaches and Feature Selection Strategies,” vol. 18, no. 2, pp. 1–39, 2025.
- [31] L. Q. Y. Pei, “A Comprehensive Review on Discriminant Analysis for Addressing Challenges of Class-Level Limitations, Small Sample Size, and Robustness,” *Processes*, vol. 12, no. 7, pp. 1–32, 2024, doi: doi.org/10.3390/pr12071382.
- [32] S. Helmiyah, R. Pramestiawan, and R. Lampung, “Analisis Komparatif Algoritma Machine Learning dengan Metrik Akurasi, Presisi, Recall, dan F1-Score pada Dataset Kacang Kering,” *J. ILMU Komput. DAN Teknol.*, vol. 6, no. 3, pp. 152–159, 2025, doi: doi.org/10.35960/ikomti.v6i3.2031.