

TEKNOLOGI PANGAN CERDAS: OPTIMASI E-NOSE UNTUK DETEKSI MUTU KOPI

Shanti Pujilestari^{1*}, Handono Bayuadji²

¹Program Studi Teknologi Pangan, Universitas Sahid, Jakarta

²Program Studi Teknik Industri, Universitas Sahid, Jakarta

ABSTRAK: Penelitian ini bertujuan mengembangkan sistem deteksi mutu kopi berbasis *Electronic Nose* (E-Nose) dengan optimasi konfigurasi sensor dan penerapan algoritma kecerdasan buatan (AI). Evaluasi mutu kopi melalui pengujian organoleptik (penilaian sensori) bersifat subyektif, tergantung pada persepsi panelis, serta memakan waktu, yang dapat menghasilkan penilaian yang tidak konsisten. Teknologi sensor elektronik akan digunakan untuk memberikan evaluasi yang lebih objektif dan konsisten. Delapan sensor gas (SP-12A, SP-31, TGS-813, TGS-842, SP-AQ3, TGS-823, ST-31, dan TGS-800) digunakan untuk mendeteksi mutu kopi. Empat algoritma AI, yaitu *Random Forest*, *Neural Network*, *Decision Tree*, dan *Naive Bayes*, diterapkan untuk menilai akurasi prediksi mutu kopi berdasarkan data sensor. Selain itu, konfigurasi sensor ekonomis seperti seri MQ juga dievaluasi untuk mengatasi keterbatasan biaya dan ketersediaan sensor di pasar lokal. Hasil penelitian menunjukkan bahwa algoritma *Random Forest* memberikan akurasi tertinggi, yaitu 99,48% dengan penggunaan semua sensor. Namun, penggunaan sensor TGS secara eksklusif menurunkan akurasi hingga 88,74%. Penelitian ini juga menemukan bahwa kombinasi sensor TGS dan seri MQ memberikan solusi lebih ekonomis dengan performa yang tetap optimal. Optimasi sensor elektronik dan algoritma AI dapat menghasilkan sistem deteksi mutu kopi yang handal dan terjangkau. Penelitian ini memberikan kontribusi signifikan bagi pengembangan teknologi evaluasi mutu pangan yang lebih efisien, khususnya pada industri kopi lokal.

Kata Kunci: e-nose, optimasi, pangan cerdas, kopi, mutu

ABSTRACT: This study aims to develop a coffee quality detection system based on *Electronic Nose* (E-Nose) by optimizing sensor configurations and applying artificial intelligence (AI) algorithms. Coffee quality is often evaluated through organoleptic testing (sensory evaluation), which is subjective, depends on panelists, and is time-consuming. This method has limitations as it is influenced by individual panelists' perceptions and environmental conditions, which can lead to inconsistent assessments. To address these limitations, this research explores sensor-based technology to provide a more objective and consistent evaluation. Data used in this study was obtained from eight gas sensors (SP-12A, SP-31, TGS-813, TGS-842, SP-AQ3, TGS-823, ST-31, and TGS-800), which have been previously used for detecting coffee quality. Four AI algorithms, namely *Random Forest*, *Neural Network*, *Decision Tree*, and *Naive Bayes*, were applied to assess the accuracy of coffee quality predictions based on sensor data. Additionally, alternative, more economical sensor configurations, such as the MQ series, were evaluated to overcome cost and availability limitations in the local market. The results of the study showed that the *Random Forest* algorithm provided the highest accuracy, reaching 99.48% using the full sensor set. However, the use of TGS sensors exclusively reduced the accuracy to 88.74%. This study also found that combining TGS sensors with the MQ series provided an economical solution while maintaining optimal performance. In conclusion, optimizing electronic sensors and AI algorithms can create a reliable and affordable coffee quality detection system. This research contributes significantly to the development of more efficient food quality evaluation technologies, particularly for the local coffee industry.

Keywords: Coffee, e-nose, optimization, quality, smart food

PENDAHULUAN

Penelitian ini bertujuan untuk mengidentifikasi pengaruh algoritma AI dan konfigurasi sensor terhadap akurasi alat pendeteksi mutu kopi. Mutu kopi merupakan elemen krusial dalam menjaga nilai ekonomis serta daya saing produk kopi di pasar global. Sebagai salah satu komoditas unggulan dunia,

tantangan utama adalah menilai mutu kopi secara akurat di tengah metode pengujian tradisional yang masih bersifat subjektif. Penelitian sebelumnya berjudul *Electronic Nose for Quality Control of Colombian Coffee through the Detection of Defects in 'Cup Tests'*, yang memanfaatkan delapan jenis sensor gas (SP-12A, SP-31, TGS-813, TGS-842, SP-AQ3, TGS-

¹ Email korespondensi: shanti_pujilestari@usahid.ac.id

823, ST-31, dan TGS-800) (Rodríguez, Durán and Reyes, 2009). Sensor-sensor tersebut digunakan untuk mendeteksi mutu kopi Kolombia selama pengujian uji rasa (*cup tests*). Temuan penelitian menunjukkan bahwa teknologi *E-Nose* yang dipadukan dengan algoritma seperti *Principal Component Analysis* (PCA) dan *Artificial Neural Networks* (ANN) mampu menggantikan metode subyektif dengan hasil akurasi tinggi (Rodríguez, Durán and Reyes, 2009).

Penelitian ini menggunakan kopi Arabika, yang secara luas diakui sebagai salah satu varietas kopi terbaik di dunia karena karakteristik rasa dan aromanya yang kompleks. Kopi arabika saat ini telah mendominasi sebagian besar pasar kopi dunia dan harganya jauh lebih tinggi daripada jenis kopi lainnya (Marahadi, 2021).

Kadar kafein pada kopi arabika sebesar 11,23 – 13,93% (Arabika, 2023). Kafein dapat digolongkan sebagai obat pemacu saraf pusat yang berguna untuk meningkatkan semangat kerja, melawan kantuk dan kelelahan mental (stres) dan mencegah alzheimer. Oleh karena itu, setelah minum kopi seseorang akan merasakan kesegaran psikis (Nazariah, Indriani and Kasymir, 2021). Kandungan lain dalam kopi adalah adanya asam klorogenat, polifenol, antioksidan yang dapat mencegah kenaikan gula darah, penghambat sel kanker dan meredakan peradangan (Husodo, 2020; Anwari, 2021).

Namun, mutu akhir kopi Arabika tidak hanya ditentukan oleh varietasnya, tetapi juga oleh berbagai faktor lain, terutama metode proses pengolahan pascapanen. Tahapan seperti fermentasi, pengeringan, dan pencucian memiliki peran signifikan dalam meningkatkan mutu dan mempertahankan karakteristik unik kopi. Sebagai contoh, fermentasi dengan metode *full washed* telah terbukti menjadi faktor penting dalam menentukan mutu kopi Arabika, terutama di wilayah dataran tinggi di mana kontrol mutu yang ketat diterapkan untuk memastikan hasil panen premium (Sucipta *et al.*, 2023).

Selain itu, teknik-teknik pemrosesan pascapanen yang lebih canggih, seperti fermentasi terkendali dan pengeringan alami, berkontribusi secara langsung terhadap pengembangan rasa khas kopi Arabika. Dataran tinggi barat daya Ethiopia terkenal memproduksi kopi Arabika dengan profil rasa

unik yang ditingkatkan melalui kombinasi pengeringan alami dan fermentasi terkendali (Firdissa *et al.*, 2022).

Tidak hanya itu, pengelolaan waktu fermentasi dalam proses basah juga menjadi faktor yang sangat penting dalam mempertahankan aroma khas kopi Arabika, seperti aroma buah-buahan dan kacang-kacangan. Praktik pengelolaan lahan dan teknik penanganan pascapanen yang optimal, seperti pengaturan waktu fermentasi, telah terbukti sangat berpengaruh terhadap mutu kopi dari dataran tinggi. Fermentasi sendiri memiliki pengaruh besar terhadap aroma khas kopi Arabika, seperti aroma nutty dan apel, yang membuat kopi ini sangat diminati di pasar premium (Reta *et al.*, 2021).

Dari paparan tersebut, diperlukan metode yang dapat secara objektif menentukan mutu kopi. Metode organoleptik, seperti uji rasa dan aroma oleh para ahli, telah lama digunakan dalam industri kopi. Namun, perkembangan teknologi menghadirkan alternatif modern berupa penggunaan sensor dan kecerdasan buatan (AI) untuk mengevaluasi mutu kopi. Sensor elektronik dapat mendeteksi senyawa volatil yang menjadi indikator mutu, sementara AI mampu menganalisis pola data dari sensor untuk memberikan hasil yang akurat dan konsisten.

Mutu kopi dapat dinilai melalui analisis senyawa volatil yang terlepas (Ayseli, 2024). Senyawa-senyawa ini, yang meliputi ester, alkohol, keton, asam, dan senyawa aromatik lainnya, memainkan peran krusial dalam membentuk karakteristik aroma dan rasa kopi (Sittipod *et al.*, 2020). Perbedaan komposisi gas-gas ini disebabkan oleh variasi dalam pemrosesan, yang menyebabkan perbedaan mutu kopi. Oleh karena itu, deteksi terhadap senyawa volatil ini sangat penting dalam menilai mutu kopi secara objektif.

Selama ini, pengujian mutu kopi sebagian besar dilakukan menggunakan metode organoleptik. Metode ini melibatkan penilaian sensorik oleh panelis ahli atau pencicip kopi yang terlatih (Steen *et al.*, 2023) untuk mengevaluasi karakteristik seperti aroma, rasa, keasaman, dan after taste. Pendekatan ini telah menjadi standar industri karena mampu menangkap kompleksitas rasa dan aroma kopi secara mendetail. Namun, karena bersifat subyektif, hasil dari pengujian organoleptik dapat bervariasi tergantung pada pengalaman

dan persepsi individu yang melakukan penilaian. Keterbatasan ini mendorong pengembangan teknologi tambahan, seperti penggunaan sensor dan kecerdasan buatan (AI), untuk mendukung penilaian mutu kopi secara lebih objektif dan konsisten.

E-Nose adalah teknologi sensor elektronik yang menawarkan solusi modern untuk mengatasi tantangan dalam evaluasi mutu kopi. Alat ini menggunakan berbagai jenis sensor gas yang dirancang untuk mendeteksi pola senyawa volatil dari setiap sampel kopi (Andre *et al.*, 2021). Dengan memanfaatkan teknologi ini, proses evaluasi mutu menjadi lebih konsisten dan tidak lagi bergantung pada pengujian organoleptik yang seringkali bersifat subjektif dan memerlukan keahlian panelis manusia. E-Nose dapat mengenali pola aroma unik yang mencerminkan karakteristik dan mutu kopi, memberikan hasil yang lebih terukur dan dapat diandalkan.

Namun, penerapan teknologi ini di pasar lokal menghadapi kendala utama, yaitu keterbatasan ketersediaan serta biaya tinggi dari beberapa sensor gas yang digunakan. Oleh karena itu, penelitian ini mengevaluasi konfigurasi sensor alternatif yang lebih ekonomis dan mudah diperoleh, serta pengaruhnya terhadap performa algoritma AI. Selain menguji konfigurasi sensor yang sudah ada, penelitian ini juga memperkenalkan penggunaan sensor substitusi yang mudah didapatkan dan dengan harga yang lebih terjangkau seperti seri MQ. Tujuannya adalah memastikan teknologi E-Nose berbasis AI menjadi solusi yang lebih praktis dan ekonomis, tanpa mengorbankan akurasi deteksi mutu kopi. Dengan pendekatan ini, penelitian diharapkan mendukung pengembangan teknologi pangan cerdas yang efisien dan inklusif, sekaligus meningkatkan daya saing produk kopi di pasar global.

Dalam teknologi pangan, inovasi dalam pendeteksian mutu kopi terus berkembang untuk mendukung peningkatan nilai tambah produk. Penerapan teknologi pangan yang memanfaatkan sensor elektronik dan algoritma AI menjadi salah satu pendekatan utama dalam menghadirkan metode evaluasi yang lebih akurat, efisien, dan ekonomis. Teknologi AI memungkinkan analisis data sensor yang kompleks dengan cepat dan presisi tinggi. Dengan demikian, integrasi teknologi pangan cerdas ini tidak hanya memberikan solusi teknis

yang unggul tetapi juga mendukung keberlanjutan dan daya saing industri kopi lokal di pasar global.

METODE

Sumber Data

Data yang digunakan dalam penelitian ini mengacu pada data hasil penelitian sebelumnya (Rodríguez, Durán and Reyes, 2009; Rodríguez and Durán, 2020). Dalam penelitian tersebut, berbagai jenis sensor gas digunakan untuk mengumpulkan data terkait karakteristik kopi. Sensor-sensor tersebut mencakup SP-12A, SP-31, TGS-813, TGS-842, SP-AQ3, TGS-823, ST-31, dan TGS-800 (Tabel 1).

Tabel 1. Deskripsi susunan sensor

No.	Sensor	Application
1	SP-12A	Flammable Gases
2	SP-31	Organic Solvents
3	TGS-813	Combustible gas
4	TGS-842	Methane, natural gas
5	SP-AQ3	Air Quality Control
6	TGS-823	Combustible Gases
7	ST-31	Organic Solvents
8	TGS-800	Air Quality, Smoke, Benzene

Data yang dikumpulkan dari penelitian tersebut dijadikan dasar untuk penelitian ini, yang bertujuan untuk mengeksplorasi dan mengembangkan penggunaan AI dalam mengevaluasi mutu kopi. Penggunaan data yang telah ada sebelumnya memberikan keunggulan tersendiri dalam hal ketersediaan informasi. Hal ini memungkinkan peneliti untuk memanfaatkan data yang sudah ada dan fokus pada pengembangan model-model AI yang dapat memberikan prediksi mutu kopi dengan akurat dan efisien.

Dengan menggunakan dataset yang telah dikumpulkan sebelumnya, penelitian ini dapat lebih fokus pada analisis dan pengolahan data untuk melatih model-model AI. Langkah-langkah ini memungkinkan peneliti untuk menjelajahi berbagai algoritma dan metode evaluasi model yang dapat menghasilkan hasil yang optimal dalam mengevaluasi mutu kopi. Dengan demikian, pengumpulan data dari penelitian sebelumnya memberikan fondasi yang kokoh untuk penelitian ini dan memungkinkan peneliti untuk mencapai tujuan penelitian dengan lebih efektif.

Pengolahan Data

Metoda pengolahan data dalam penelitian ini dimulai dengan memuat dataset dari penelitian sebelumnya ke dalam database MySQL agar pengelolaan data lebih efisien. Proses pembersihan data dilakukan dengan menghapus data yang tidak lengkap, tidak relevan, atau memiliki nilai ekstrem untuk memastikan dataset bersih dan konsisten. Langkah berikutnya adalah normalisasi data, yang menyelaraskan nilai-nilai dalam dataset ke skala yang seragam untuk menghindari bias dalam analisis.

Dataset yang telah diproses kemudian dibagi menjadi tiga bagian, yaitu set pelatihan, validasi, dan pengujian. Set pelatihan digunakan untuk melatih model AI, set validasi untuk menyetel parameter model dan mencegah *overfitting*, sedangkan set pengujian untuk mengukur kinerja model pada data yang belum pernah dilihat sebelumnya, memberikan evaluasi objektif terhadap akurasi prediksi.

Label dalam dataset ini mempresentasikan mutu kopi berdasarkan data senyawa volatil yang dideteksi oleh sensor. Label ini menjadi target prediksi yang digunakan model AI. Oleh karena itu, validasi terhadap keakuratan dan konsistensi label sangat penting agar model dapat mempelajari pola dengan baik.

Pemilihan Algoritma

Dalam penelitian ini, empat algoritma AI yang berbeda diterapkan, yaitu *Random Forest*, *Neural Network*, *Decision Tree*, dan *Naive Bayes*. Algoritma-algoritma ini dipilih karena keefektifannya dalam memproses data yang kompleks dan membuat prediksi berdasarkan pola yang ditemukan dalam data sensor.

Random Forest adalah salah satu metode *ensemble learning* yang berbasis pada konsep pembentukan sejumlah besar pohon keputusan yang bekerja secara independen dan menghasilkan prediksi. Setiap pohon dalam hutan acak dibangun menggunakan sampel acak dari data pelatihan dan fitur-fitur yang dipilih secara acak. Kemudian, prediksi dari setiap pohon diambil, dan mayoritas suara digunakan untuk menentukan prediksi akhir. *Random Forest* memiliki keunggulan dalam menangani data yang kompleks, tahan terhadap *overfitting*, dan sering memberikan hasil yang akurat. *Random Forest* adalah salah satu algoritma prediksi di bidang pembelajaran mesin. Ini lebih mudah beradaptasi dengan

pendekatan ansambel. Itu dapat dengan mudah menangani kumpulan data besar (Alehegn, Joshi and Mulay, 2019).

Neural Network adalah model matematika yang terinspirasi dari struktur dan fungsi otak manusia. Ini terdiri dari sejumlah besar neuron atau unit pemrosesan yang saling terhubung dalam lapisan-lapisan. *Neural Network* mempelajari pola-pola yang ada dalam data melalui proses pelatihan yang mengoptimalkan parameter-parameter internalnya. Dengan arsitektur yang fleksibel, *Neural Network* dapat menangani masalah klasifikasi dan regresi yang kompleks serta memberikan prediksi yang akurat dalam berbagai aplikasi. *Neural Network* selain dapat digunakan untuk klasifikasi label nominal juga dapat digunakan untuk prediksi numerik (Singh, 2014).

Decision Tree adalah model prediktif yang menggunakan struktur pohon untuk menggambarkan serangkaian keputusan dan konsekuensinya. Setiap simpul dalam pohon mewakili keputusan berdasarkan nilai dari satu fitur, dengan cabang-cabang yang mewakili kemungkinan hasil dari keputusan tersebut. *Decision Tree* cocok untuk data yang terstruktur dan dapat dengan mudah diinterpretasikan. Namun, kelemahan utamanya adalah kecenderungan untuk *overfitting* jika tidak diatur dengan baik (Charbuty and Abdulazeez, 2021).

Naive Bayes adalah algoritma klasifikasi probabilistik yang berdasarkan *Teorema Bayes* dengan asumsi bahwa semua fitur dalam data independen satu sama lain (Berrar, 2024). *Naive Bayes* sering memberikan hasil yang baik dalam klasifikasi teks dan klasifikasi sederhana lainnya (Priyambodo and Prihati, 2020). Algoritma ini mudah diimplementasikan dan memiliki kinerja yang baik.

Pemilihan algoritma ini dilakukan berdasarkan kemampuan masing-masing algoritma dalam menangani kompleksitas data sensor serta kemampuan mereka untuk memberikan prediksi yang akurat dalam menilai mutu kopi. Setelah dipilih, masing-masing algoritma akan diuji dan dievaluasi kinerjanya pada data yang tersedia dalam penelitian ini.

Pelatihan dan Evaluasi Model

Proses pelatihan model dilakukan dengan mempertimbangkan berbagai konfigurasi sensor yang berbeda untuk mengoptimalkan

kinerja model AI. Setiap konfigurasi sensor diuji secara terpisah dalam proses pelatihan untuk mengevaluasi kemampuannya dalam mengenali pola-pola data yang berkaitan dengan mutu kopi. Data pelatihan yang telah dipersiapkan sebelumnya digunakan untuk melatih model dengan setiap konfigurasi sensor. Selama proses pelatihan, model mencoba memahami hubungan antara nilai-nilai sensor yang diperoleh dan mutu kopi yang terkait, sehingga dapat memberikan prediksi yang akurat.

Matriks evaluasi memberikan gambaran tentang kinerja model dalam mengenali pola-pola (Aryadi and Suhendar, 2024; Bintang and Imaduddin, 2024), terutama pada skenario data spesifik. Evaluasi dilakukan dengan membagi data menjadi tiga set: pelatihan, validasi, dan pengujian (Shafi and Chinnappan, 2024) untuk memastikan hasil prediksi yang akurat dan seimbang.

Confusion matrix digunakan dalam evaluasi model, yang menggambarkan performa model dengan membandingkan prediksi yang benar dan prediksi yang salah dalam bentuk matriks (Sumarsono *et al.*, 2023). Setiap sel dalam matriks mewakili jumlah sampel dari kelas sebenarnya yang diprediksi dengan benar atau salah oleh model. *Confusion matrix* memberikan informasi yang lebih rinci tentang kinerja model, terutama dalam mengidentifikasi di mana model cenderung membuat kesalahan klasifikasi. *Confusion matrix* memberikan data mentah tentang bagaimana model klasifikasi memprediksi berbagai kelas dalam dataset, yang kemudian digunakan untuk menghitung metrik evaluasi model selanjutnya.

Evaluasi model dilakukan dengan menggunakan berbagai metrik evaluasi yang meliputi akurasi, presisi, *recall*, dan nilai F1 (Al Baid, 2020; Maneno *et al.*, 2023; Praneswara and Cahyono, 2023). Akurasi mengukur seberapa banyak prediksi yang benar dari total prediksi yang dibuat oleh model. Presisi mengukur tingkat ketepatan dalam mengklasifikasikan hasil positif yang diprediksi oleh model, sementara *recall* mengukur kemampuan model dalam mengidentifikasi semua hasil positif yang sebenarnya. Nilai F1, sebagai gabungan dari presisi dan *recall*, memberikan gambaran keseluruhan tentang kinerja model dalam memprediksi mutu kopi.

Dengan mempertimbangkan hasil evaluasi model, dapat dilakukan analisis yang lebih

mendalam tentang kinerja masing-masing model. Informasi yang diperoleh dari evaluasi ini menjadi dasar untuk mengidentifikasi kelemahan dan kekuatan dari setiap model, serta untuk merumuskan langkah-langkah perbaikan yang diperlukan untuk meningkatkan performa prediksi.

HASIL DAN PEMBAHASAN Pengolahan Data

Dalam proses pengolahan data, langkah awalnya adalah mengambil data dari file teks yang berisi informasi tentang mutu kopi. Data ini kemudian dimasukkan ke dalam database MySQL, untuk selanjutnya dilakukan serangkaian langkah pemrosesan untuk membersihkan dan menormalkan data sebelum digunakan untuk melatih model AI (Gambar 1).

Name	Type	Length	Decimals	Allow Null
ID	int	11	0	<input type="checkbox"/>
SP-12A	decimal	9	6	<input checked="" type="checkbox"/>
SP-31	decimal	9	6	<input checked="" type="checkbox"/>
TGS-813	decimal	9	6	<input checked="" type="checkbox"/>
TGS-842	decimal	9	6	<input checked="" type="checkbox"/>
SP-AQ3	decimal	9	6	<input checked="" type="checkbox"/>
TGS-823	decimal	9	6	<input checked="" type="checkbox"/>
ST-31	decimal	9	6	<input checked="" type="checkbox"/>
TGS-800	decimal	9	6	<input checked="" type="checkbox"/>
Class	varchar	30	0	<input checked="" type="checkbox"/>
SAMPEL	varchar	30	0	<input checked="" type="checkbox"/>

Gambar 1. Struktur Tabel Database MySQL

Jumlah data yang digunakan dalam penelitian ini dibagi berdasarkan label mutu kopi yang terdiri dari tiga kelas mutu kopi, yaitu RENDAH, SEDANG, dan TINGGI. Untuk label RENDAH, terdapat 28 sampel dengan total 8,400 pengambilan data. Sementara untuk label SEDANG, terdapat 10 sampel dengan total 3,000 pengambilan data. Label TINGGI terdiri dari 20 sampel dengan 6,000 pengambilan data.

ID	SP-12A	SP-31	TGS-813	TGS-842	SP-AQ3	TGS-823	ST-31	TGS-800	Class	SAMPEL
1	34.895871	82.192729	25.809616	27.211314	22.980706	56.240288	54.261723	45.484726	TINGGI	H01
2	34.558525	80.980393	25.658821	27.156147	22.652165	54.061348	54.079617	45.621764	TINGGI	H01
3	35.152711	82.604501	26.013023	27.377967	23.447964	56.442509	54.079617	46.17748	TINGGI	H01
4	35.152711	81.380729	26.013023	27.659625	23.023237	55.444606	54.641569	46.459967	TINGGI	H01
5	34.981116	81.784823	25.809616	27.490004	22.897838	55.444606	54.641569	46.17748	TINGGI	H01
6	34.642321	81.784823	25.70892	27.046383	22.815465	55.839833	53.516433	45.212878	TINGGI	H01
7	34.475084	81.784823	25.509509	26.883149	22.733582	55.641572	53.516433	45.212878	TINGGI	H01
8	34.558525	80.583764	25.509509	27.156147	22.611668	54.861348	54.261723	45.759552	TINGGI	H01
9	34.810992	81.784823	25.410781	26.991785	22.733582	55.248922	53.700984	45.759552	TINGGI	H01
10	34.475084	81.784823	25.591116	26.937373	22.733582	55.641572	53.700984	45.078056	TINGGI	H01
11	34.391998	81.380729	25.70892	26.991785	22.733582	55.444606	53.700984	45.484726	TINGGI	H01
12	34.726476	82.604501	25.410781	27.046383	22.774463	55.248922	53.886708	45.348433	TINGGI	H01
13	34.558525	80.583764	25.70892	27.156147	22.652165	55.054506	54.079617	45.348433	TINGGI	H01
14	34.726476	81.784823	25.410781	27.046383	22.733582	55.248922	53.516433	45.759552	TINGGI	H01
15	34.810992	83.020194	25.410781	27.046383	22.85659	55.248922	53.886708	45.759552	TINGGI	H01
16	34.726476	81.784823	25.608886	26.937373	22.733582	55.333046	45.078056	TINGGI	H01	
17	34.895871	81.380729	26.115746	27.377967	22.980706	55.641572	54.451036	45.888096	TINGGI	H01
18	35.066728	81.380729	25.961917	27.490004	22.897838	55.641572	54.641569	45.888096	TINGGI	H01
19	34.558525	82.192729	25.759185	27.156147	22.733582	55.444606	53.886708	45.621764	TINGGI	H01
20	34.391998	80.583764	25.658821	27.211314	22.611668	55.248922	54.261723	45.348433	TINGGI	H01

Gambar 2. Data Sensor Gas dan Kelas mutu Kopi sebagai Label

Secara rinci, pengambilan data untuk masing-masing kategori terbagi lebih lanjut ke dalam sampel yang memiliki jumlah pengambilan data masing-masing 300. Untuk kategori RENDAH, sampel yang digunakan adalah L01 hingga L28, dengan setiap sampel memiliki 300 pengambilan data. Kategori SEDANG mencakup sampel A01 hingga A10, juga dengan 300 pengambilan data per sampel. Sementara itu, kategori TINGGI mencakup sampel H01 hingga H20, dengan setiap sampel terdiri dari 300 pengambilan data.

Dengan total 17,400 pengambilan data yang digunakan, penelitian ini bertujuan untuk mengevaluasi kinerja model dalam memprediksi mutu kopi berdasarkan konfigurasi sensor yang berbeda. Data yang telah dipersiapkan sebelumnya akan diolah untuk membangun dan menguji model deteksi mutu kopi yang akurat dan dapat diandalkan.

Pelatihan dan Evaluasi Model

Dalam tahap pelatihan model, empat algoritma AI yang berbeda diterapkan. Setiap algoritma memiliki keunggulan dan kelemahan masing-masing dalam mengolah data dan membuat prediksi. Dengan menggunakan berbagai algoritma ini, penelitian ini bertujuan untuk membandingkan kinerja dan akurasi prediksi dari masing-masing model dalam mengevaluasi mutu kopi.

Dalam proses pelatihan, setiap algoritma dilatih menggunakan data pelatihan untuk mengenali pola-pola yang berkaitan dengan nilai sensor untuk setiap tingkat mutu kopi yang telah ditentukan sebelumnya. Model-model ini belajar dari data pelatihan untuk mengoptimalkan prediksi mereka terhadap data yang belum pernah dilihat sebelumnya. Evaluasi model kemudian dilakukan untuk memastikan bahwa model-model yang dihasilkan memiliki kinerja yang baik dan dapat diandalkan dalam memberikan prediksi yang akurat dan konsisten.

Akurasi Alat dengan Semua Jenis Sensor

Pada penelitian ini, dilakukan evaluasi terhadap akurasi alat pendeteksi mutu kopi yang menggunakan berbagai jenis sensor gas yang tersedia dalam dataset penelitian sebelumnya, "Electronic Nose for Quality Control of Colombian Coffee through the Detection of Defects in 'Cup Tests'" oleh Juan Rodríguez, Cristhian Durán, dan Adriana Reyes.

Sensor-sensor yang digunakan dalam penelitian ini mencakup SP-12A, SP-31, TGS-813, TGS-842, SP-AQ3, TGS-823, ST-31, dan TGS-800, yang dapat mendeteksi berbagai senyawa volatil dalam kopi yang berhubungan dengan mutu dan cita rasa kopi.

Pengujian dilakukan dengan menggunakan empat algoritma AI, untuk memproses data sensor yang dihasilkan dan memprediksi mutu kopi berdasarkan karakteristik aroma yang terdeteksi.

Tabel 2. Confusion Matrix Random Forest Semua Jenis Sensor

accuracy: 99.48%

	true TINGGI	true SEDANG	true RENDAH	class precision
pred. TINGGI	1196	1	7	99.34%
pred. SEDANG	0	594	1	99.83%
pred. RENDAH	4	5	1672	99.46%
class recall	99.67%	99.00%	99.52%	

Tabel 3. Confusion Matrix Neural Network Semua Jenis Sensor

accuracy: 98.30%

	true TINGGI	true SEDANG	true RENDAH	class precision
pred. TINGGI	1175	1	19	98.33%
pred. SEDANG	0	586	1	99.83%
pred. RENDAH	25	13	1660	97.76%
class recall	97.92%	97.67%	98.81%	

Tabel 4. Confusion Matrix Decision Tree Semua Jenis Sensor

accuracy: 84.74%

	true TINGGI	true SEDANG	true RENDAH	class precision
pred. TINGGI	932	0	32	96.68%
pred. SEDANG	0	406	37	91.65%
pred. RENDAH	268	194	1611	77.71%
class recall	77.67%	67.67%	95.89%	

Tabel 5. Confusion Matrix Naive Bayes Semua Jenis Sensor

accuracy: 67.99%

	true TINGGI	true SEDANG	true RENDAH	class precision
pred. TINGGI	917	125	265	70.16%
pred. SEDANG	84	435	401	47.28%
pred. RENDAH	199	40	1014	80.93%
class recall	76.42%	72.50%	60.36%	

Algoritma Random Forest menunjukkan performa terbaik di antara semua algoritma ketika menggunakan data dari semua sensor, dengan akurasi sebesar 99.48%. Model ini

mencatat 3.462 prediksi benar dan hanya 13 prediksi salah dari total data. Nilai rata-rata presisi adalah 99.43%, recall 99.51%, dan F1 99.47%. Berdasarkan *Confusion Matrix*, kelas TINGGI memiliki nilai F1 sebesar 99.25% (1.196 prediksi benar dan 8 salah), kelas SEDANG mencapai F1 99.66% (594 benar dan 1 salah), dan kelas RENDAH mendapatkan F1 99.43% (1.672 benar dan 9 salah). Distribusi prediksi menunjukkan konsistensi yang sangat tinggi, menjadikan *Random Forest* sebagai algoritma paling handal dalam penelitian ini.

Neural Network juga memberikan hasil yang sangat baik dengan akurasi sebesar 98.30%. Model ini menghasilkan 3.421 prediksi benar dan 54 prediksi salah. Rata-rata presisi adalah 98.21%, recall 98.32%, dan nilai F1 98.26%. Pada kelas TINGGI, nilai F1 adalah 97.75% (1.175 benar dan 20 salah), kelas SEDANG memiliki nilai F1 99.15% (586 benar dan 1 salah), dan kelas RENDAH mendapatkan nilai F1 98.50% (1.660 benar dan 38 salah). *Neural Network* tetap unggul dalam mendeteksi kelas dengan baik, meskipun berada sedikit di bawah *Random Forest*.

Sebaliknya, *Decision Tree* menunjukkan performa yang lebih rendah dengan akurasi sebesar 84.74%. Model ini mencatat 2.949 prediksi benar dan 526 prediksi salah. Nilai rata-rata presisi adalah 84.15%, recall 84.78%, dan F1 84.46%. Kelas TINGGI memiliki nilai F1 sebesar 85.71% (932 benar dan 32 salah), kelas SEDANG mencapai F1 sebesar 82.92% (406 benar dan 37 salah), dan kelas RENDAH mendapatkan nilai F1 84.34% (1.611 benar dan 462 salah). Meskipun memiliki kekuatan pada kelas RENDAH, algoritma ini menunjukkan kelemahan dalam konsistensi antar kelas lainnya.

Naive Bayes menunjukkan performa terendah dengan akurasi sebesar 67.99%. Model ini mencatat 2.366 prediksi benar dan 1.109 prediksi salah. Nilai rata-rata presisi adalah 67.21%, recall 67.62%, dan F1 67.41%. Pada kelas TINGGI, nilai F1 adalah 74.15% (917 benar dan 390 salah), kelas SEDANG hanya mencapai F1 sebesar 57.36% (435 benar dan 485 salah), dan kelas RENDAH mendapatkan nilai F1 70.98% (1.014 benar dan 239 salah). Hasil ini mencerminkan keterbatasan *Naive Bayes* dalam menangani distribusi data yang kompleks, terutama dalam membedakan antara kelas SEDANG dan RENDAH.

Secara keseluruhan, *Random Forest* dan *Neural Network* memberikan performa terbaik ketika menggunakan data dari semua sensor. Dengan prediksi benar yang jauh lebih banyak dan tingkat kesalahan minimal, *Random Forest* unggul dalam semua metrik evaluasi. *Neural Network* menjadi alternatif kuat dengan hasil yang hampir sebanding. Sebaliknya, *Decision Tree* dan *Naive Bayes* menunjukkan performa yang lebih rendah.

Akurasi Alat dengan Sensor TGS Saja

Pada bagian ini, dilakukan analisis lebih lanjut mengenai akurasi alat pendeteksi mutu kopi yang hanya menggunakan sensor jenis TGS, tanpa menggabungkan sensor lainnya. Hal ini dilakukan untuk mengidentifikasi bagaimana pengaruh penggunaan sensor TGS terhadap kinerja algoritma AI dalam memprediksi mutu kopi.

Tabel 6. Confusion Matrix Random Forest Sensor TGS

accuracy: 88.74%

	true TINGGI	true SEDANG	true RENDAH	class precision
pred. TINGGI	1189	16	300	79.00%
pred. SEDANG	1	534	15	97.09%
pred. RENDAH	10	50	1365	95.79%
class recall	99.08%	89.00%	81.25%	

Tabel 7. Confusion Matrix Neural Network Sensor TGS

accuracy: 83.59%

	true TINGGI	true SEDANG	true RENDAH	class precision
pred. TINGGI	1112	32	268	78.75%
pred. SEDANG	0	431	46	90.36%
pred. RENDAH	88	137	1366	85.86%
class recall	92.67%	71.83%	81.31%	

Tabel 8. Confusion Matrix Decision Tree Sensor TGS

accuracy: 59.86%

	true TINGGI	true SEDANG	true RENDAH	class precision
pred. TINGGI	1192	235	1094	47.28%
pred. SEDANG	6	331	26	91.18%
pred. RENDAH	2	34	560	93.96%
class recall	99.33%	55.17%	33.33%	

Tabel 9. Confusion Matrix Naive Bayes Sensor TGS

accuracy: 59.51%

	true TINGGI	true SEDANG	true RENDAH	class precision
pred. TINGGI	789	151	398	58.97%
pred. SEDANG	0	0	0	0.00%
pred. RENDAH	411	449	1282	59.85%
class recall	65.75%	0.00%	76.31%	

Random Forest mencatat performa terbaik ketika menggunakan data dari sensor TGS dengan akurasi 88.74%. Model ini menghasilkan 3.088 prediksi benar dan 381 prediksi salah. Nilai rata-rata presisi mencapai 89.78%, recall 90.63%, dan F1 89.57%. Pada kelas TINGGI, model memiliki nilai F1 sebesar 88.03% (1.189 prediksi benar dan 316 salah), kelas SEDANG mencapai F1 90.80% (534 benar dan 16 salah), dan kelas RENDAH mendapatkan nilai F1 90.69% (1.365 benar dan 60 salah). *Random Forest* berhasil menjaga keseimbangan yang baik antara presisi dan *recall* di semua kelas, bahkan hanya dengan data dari sensor TGS.

Neural Network memberikan hasil yang cukup baik dengan akurasi 83.59%. Model ini mencatat 2.909 prediksi benar dan 560 prediksi salah. Nilai rata-rata presisi adalah 81.94%, recall 84.99%, dan F1 82.90%. Kelas TINGGI memiliki nilai F1 sebesar 80.64% (1.112 benar dan 300 salah), kelas SEDANG mencatat F1 83.80% (431 benar dan 78 salah), dan kelas RENDAH mendapatkan nilai F1 84.79% (1.366 benar dan 225 salah). *Neural Network* menunjukkan kekuatan dalam mendeteksi kelas SEDANG dan RENDAH, meskipun kinerjanya sedikit di bawah *Random Forest*.

Sebaliknya, *Naive Bayes* menunjukkan performa yang kurang baik dengan akurasi sebesar 59.51%. Model ini mencatat 2.071 prediksi benar dan 1.398 prediksi salah. Nilai rata-rata presisi adalah 47.35%, *recall* 39.61%, dan F1 43.09%. Tidak ada prediksi yang benar untuk kelas SEDANG, sehingga F1 untuk kelas ini adalah 0%. Kelas TINGGI memiliki nilai F1 sebesar 62.51% (789 benar dan 549 salah), dan kelas RENDAH mendapatkan F1 73.52% (1.282 benar dan 860 salah). Hasil ini mencerminkan keterbatasan algoritma *Naive Bayes* dalam membedakan kelas secara akurat, terutama pada kelas SEDANG.

Decision Tree memiliki akurasi sebesar 59.86%, dengan 2.083 prediksi benar dan 1.386

prediksi salah. Rata-rata presisi adalah 62.61%, recall 77.48%, dan F1 60.67%. Kelas TINGGI mencatat nilai F1 sebesar 67.65% (1.192 benar dan 1.329 salah), kelas SEDANG mencatat F1 62.18% (331 benar dan 32 salah), dan kelas RENDAH memiliki F1 sebesar 48.73% (560 benar dan 596 salah). *Decision Tree* menunjukkan kelemahan dalam mendeteksi kelas RENDAH, meskipun memiliki presisi tinggi pada kelas TINGGI.

Secara keseluruhan, *Random Forest* dan *Neural Network* memberikan performa terbaik dengan data dari sensor TGS saja. Sebaliknya, *Naive Bayes* dan *Decision Tree* memiliki performa yang jauh lebih rendah.

Tabel 10. Perbandingan Akurasi Berdasarkan Jenis Sensor

Algoritma	Semua Jenis Sensor	Sensor TGS Saja
	Random Forest	99.48%
Neural Network	98.30%	83.59%
Decision Tree	84.74%	66.93%
Naive Bayes	67.99%	59.51%

Hal ini menunjukkan bahwa penggunaan hanya sensor TGS dapat menyebabkan penurunan akurasi prediksi mutu kopi, dibandingkan dengan kombinasi sensor yang lebih beragam.

Penggunaan Sensor Substitusi

Dalam penelitian ini, sensor yang digunakan untuk deteksi mutu kopi dibagi menjadi dua kategori utama, yaitu sensor TGS dan sensor non-TGS. Beberapa sensor non-TGS sulit didapatkan di pasar lokal dan memiliki harga yang tinggi, sehingga diperlukan analisis penggunaan sensor substitusi yang lebih murah dan mudah diakses.

Sensor jenis MQ, menjadi alternatif yang mampu mendeteksi beberapa senyawa yang sama dengan sensor non-TGS. Berikut beberapa jenis sensor MQ yang dapat digunakan sebagai sensor pengganti.

Tabel 11. Substitusi Sensor

Sensor Asli	Sensor Substitusi	Deskripsi
SP-12A	MQ-3	Sensor MQ-3 dapat menggantikan SP-12A dalam deteksi senyawa organik volatil

SP-31	MQ-7	MQ-7 dapat menggantikan SP-31 dalam mendeteksi gas berbahaya dan karbon monoksida
SP-AQ3	MQ-2	MQ-2 dapat menggantikan SP-AQ3 dalam mendeteksi berbagai senyawa gas berbahaya
TGS-31	MQ-5	MQ-5 bisa menjadi pengganti untuk TGS-31 dalam mendeteksi gas alam dan senyawa lainnya

SIMPULAN

Penelitian ini telah mengidentifikasi beberapa aspek penting dalam penggunaan teknologi E-Nose untuk deteksi mutu kopi dengan mengintegrasikan algoritma AI dan sensor gas. Hasil penelitian menunjukkan bahwa penggunaan algoritma *Random Forest* memberikan akurasi tertinggi, baik dengan kombinasi semua jenis sensor maupun hanya dengan sensor TGS yang tersedia di pasar lokal. Dalam pengujian menggunakan semua jenis sensor, *Random Forest* mencapai akurasi 99.48%, diikuti oleh *Neural Network* dengan 98.30%, *Decision Tree* dengan 84.74%, dan *Naive Bayes* dengan 67.99%.

Namun, ketika hanya menggunakan sensor TGS, yang lebih mudah didapatkan di pasar lokal, hasil akurasi mengalami penurunan. Untuk penggunaan sensor TGS saja, *Random Forest* masih menunjukkan akurasi tertinggi, yaitu 88.74%, disusul oleh *Neural Network* dengan 83.59%, *Decision Tree* dengan 66.93%, dan *Naive Bayes* dengan 59.51%. Penurunan akurasi ini menunjukkan pentingnya penggunaan sensor tambahan untuk meningkatkan hasil analisis dan prediksi mutu kopi, terutama dalam kasus keterbatasan akses terhadap sensor non-TGS yang lebih mahal dan sulit ditemukan di pasar lokal.

Dari temuan ini, dapat disimpulkan bahwa meskipun penggunaan algoritma *Random Forest* dan *Neural Network* menunjukkan hasil yang sangat baik, keberagaman sensor tetap menjadi faktor krusial dalam mencapai akurasi yang tinggi. Oleh karena itu, penggunaan sensor MQ series sebagai pengganti sensor non-TGS yang sulit didapatkan dapat meningkatkan akurasi sistem deteksi mutu kopi.

UCAPAN TERIMA KASIH

Ucapan terima kasih kepada Juan Carlos Rodriguez Gamboa dan Cristhian Manuel Duran

Acevedo yang telah mendistribusikan data hasil penelitian untuk dapat diolah lebih lanjut pada penelitian ini.

DAFTAR PUSTAKA

- Alehegn, M., Joshi, R.R. and Mulya, P. (2019) 'Diabetes analysis and prediction using random forest, KNN, Naive Bayes, and J48: An ensemble approach', *International Journal of Scientific and Technology Research*, 8(9), pp. 1346–1354.
- Andre, R.S. *et al.* (2021) 'Nanocomposite-based chemiresistive electronic nose and application in coffee analysis', *ACS Food Science & Technology*, 1(8), pp. 1464–1471.
- Anwari, R.H. (2021) 'Dampak Konsumsi Kopi pada Penurunan Kadar Glukosa Darah Penderita Diabetes Mellitus Tipe 2', *Jurnal Penelitian Perawat Profesional*, 3(3), pp. 531–540.
- Arabika, A.K.K.B.K. (2023) 'Caffeine Content Analysis of Arabica Coffee Beans with Variation Roasting Temperatures Grown in Aek Sabaon South Tapanuli Analisis Kadar Kafein Biji Kopi Arabika Dengan Variasi Temperatur Sangrai Yang Tumbuh Di Aek Sabaon Tapanuli Selatan Mey Linda Hasibu', *Journal of Pharmaceutical and Sciences/ Volume*, 6(2), pp. 681–691.
- Aryadi, I. and Suhendar, A. (2024) 'Implementasi Arsitektur Xception Dalam Menentukan Kematangan Tandan Buah Segar Kelapa Sawit', *Jutisi: Jurnal Ilmiah Teknik Informatika dan Sistem Informasi*, 13(3).
- Ayseli, M.T. (2024) 'The role of volatile and non-volatile as compounds quality indicators and marker candidates in coffee: A systematic review', *Journal of Food Composition and Analysis*, p. 106846.
- Al Baid, M.S.A. (2020) *Identifikasi Tingkat Kematangan Buah Durian Dengan Menggunakan Deret Sensor Gas Elektrokimia Dan Artificial Neural Network*. ITS.
- Berrar, D. (2024) 'Bayes' Theorem and Naive Bayes Classifier', in *Reference Module in Life Sciences*. Elsevier. Available at: <https://doi.org/https://doi.org/10.1016/B978-0-323-95502-7.00118-4>.
- Bintang, Y.K. and Imaduddin, H. (2024) 'Pengembangan Model Deep learning untuk Deteksi Retinopati Diabetik Menggunakan Metode Transfer Learning', *JUPI (Jurnal Ilmiah Penelitian dan Pembelajaran*

- Informatika*), 9(3), pp. 1442–1455.
- Charbuty, B. and Abdulazeez, A. (2021) 'Classification Based on Decision Tree Algorithm for Machine Learning', *Journal of Applied Science and Technology Trends*, 2(01), pp. 20–28. Available at: <https://doi.org/10.38094/jastt20165>.
- Firdissa, E. et al. (2022) 'Coffee drying and processing method influence quality of arabica coffee varieties (Coffee arabica L.) at Gomma I and Limmu Kossa, Southwest Ethiopia', *Journal of Food Quality*, 2022(1), p. 9184374.
- Husodo, B. (2020) 'Konsumsi kopi untuk mencegah penyakit alzheimer', *Jurnal Ilmiah Kesehatan Sandi Husada*, 12(2), pp. 996–1002.
- Maneno, R. et al. (2023) 'Deteksi tingkat kematangan buah pinang menggunakan metode support vector machine berdasarkan warna dan tekstur', *Journal of Information and Technology*, 3(2), pp. 60–66.
- Marahadi, I. (2021) 'Analisis Strategi Pengembangan Usaha Kopi Arabika Di masa Pandemi Covid-19 (Studi kasus Kopi Gayo Atulintang).(studi Kasus kopi gayo Atulintang', *Jurnal AKAMI*, 2, pp. 387–401.
- Nazariah, N., Indriani, Y. and Kasymir, E. (2021) 'Pola konsumsi dan sikap mahasiswa Universitas Lampung terhadap kopi robusta', *Jurnal Ilmu Ilmu Agribisnis: Journal of Agribusiness Science*, 9(3), pp. 477–484.
- Praneswara, A.O. and Cahyono, N. (2023) 'Analisis Sentimen Ulasan Aplikasi TikTok Shop Seller Center di Google Playstore Menggunakan Algoritma Naive Bayes', *The Indonesian Journal of Computer Science*, 12(6).
- Priyambodo, A. and Prihati, P. (2020) 'Evaluasi ekstraksi fitur klasifikasi teks untuk peningkatan akurasi klasifikasi menggunakan naive bayes', *Elkom: Jurnal Elektronika dan Komputer*, 13(1), pp. 159–175.
- Reta, R. et al. (2021) 'Aroma Profile of Arabica Coffee Based on Ohmic Fermentation', in M. Laranjo (ed.) *Fermentation - Processes, Benefits and Risks*. Rijeka: IntechOpen. Available at: <https://doi.org/10.5772/intechopen.98638>.
- Rodríguez, J. and Durán, C. (2020) 'Dataset: Electronic Nose for Quality Control of Colombian Coffee through the Detection of Defects in "Cup Tests"'. Mendeley. Available at: <https://doi.org/10.17632/7spd6fpvyk.1>.
- Rodríguez, J., Durán, C. and Reyes, A. (2009) 'Electronic nose for quality control of Colombian coffee through the detection of defects in "Cup Tests"', *Sensors*, 10(1), pp. 36–46. Available at: <https://doi.org/10.3390/s100100036>.
- Shafi, S.M. and Chinnappan, S.K. (2024) 'Hybrid transformer-CNN and LSTM model for lung disease segmentation and classification', *PeerJ Computer Science*, 10, p. e2444. Available at: <https://doi.org/10.7717/peerj-cs.2444>.
- Singh, S. (2014) 'Comparative Study Id3 , Cart and C4 . 5 Decision Tree Algorithm: a Survey', *International Journal of Advanced Information Science and Technology (IJAIST)*, 27(27), pp. 97–103. Available at: <https://doi.org/10.15693/ijaist/2014.v3i7.47-52>.
- Sittipod, S. et al. (2020) 'Identification of compounds that negatively impact coffee flavor quality using untargeted liquid chromatography/mass spectrometry analysis', *Journal of Agricultural and Food Chemistry*, 68(38), pp. 10424–10431.
- Steen, I. et al. (2023) 'Evaluation of a sensory and cognitive online training tool for odor recognition in professional coffee tasters', *Journal of Sensory Studies*, 38(3), p. e12819.
- Sucipta, I.N. et al. (2023) 'Quality of Kintamani Arabica and Pupuan Robusta Green Bean Coffee Based on Defects of Fermentation Process with Full Washed Method', *Food Science and Quality Management*, 122, pp. 31–41. Available at: <https://doi.org/10.7176/fsqm/122-05>.
- Sumarsono, J. et al. (2023) 'The Best Combination of Gas Sensor and Machine Learning Classification Algorithm in Detecting Mango (*Mangifera indica* L.) Quality', *Advances in Biological Sciences Research*, pp. 130–142. Available at: https://doi.org/10.2991/978-94-6463-274-3_11.