

Sensor MOS Hidung Elektronik untuk membedakan Thrips dan *Spodoptera* pada Stroberi

FAJRIN NURUL HAQ¹, REZA FIKRI ALFATAH², MULKI REZKA BUDI PRATAMA¹, SAHRUL RISWANTO¹, AYU SUCI RAHMAN¹

¹Teknik Elektro, Fakultas Sains dan Teknologi Universitas Muhammadiyah Bandung

²International Doctoral Program in Agriculture, College of Agriculture and Natural Resources National Chung Hsing
Email: fajrin03@umbandung.ac.id

Received 10 Desember 2024 | *Revised* 7 Maret 2025 | *Accepted* 14 April 2025

ABSTRAK

Penelitian ini mengevaluasi efektivitas hidung elektronik berbasis sensor MOS, yaitu sensor TGS dan MQ, dalam mendeteksi dan membedakan hama thrips dan Spodoptera litura pada tanaman stroberi. Data volatil yang dihasilkan oleh tanaman diamati menggunakan sensor E-nose yang terhubung dengan model jaringan saraf tiruan Backpropagation (BPPN). Dengan penyetelan GridSearchCV, akurasi deteksi meningkat secara signifikan, terutama pada sensor TGS, yang menunjukkan kinerja lebih baik dibandingkan sensor MQ. Teknologi ini menawarkan pendekatan deteksi hama yang sensitif, tidak merusak, dan ramah lingkungan, dengan potensi untuk mendukung pengelolaan hama secara berkelanjutan dalam budidaya stroberi. Penelitian ini memberikan peluang baru untuk inovasi di bidang pertanian pintar dengan pengurangan penggunaan pestisida yang berlebihan dan optimalisasi strategi pengelolaan hama.

Kata kunci: *hidung elektronik, deteksi, trips, spodoptera, stroberi*

ABSTRACT

This study evaluates the effectiveness of metal oxide semiconductor (MOS) electronic noses, specifically the TGS and MQ sensors, in detecting and distinguishing between thrips and Spodoptera litura pests on strawberry plants. Volatile compounds produced by the plants were analyzed using an E-nose connected to a Backpropagation Neural Network (BPNN) model. The GridSearchCV optimization significantly improved detection accuracy, particularly for the TGS sensor, which outperformed the MQ sensor. This technology offers a sensitive, non-invasive, and environmentally friendly approach to pest detection, supporting sustainable pest management in strawberry cultivation. The study opens new opportunities for smart agricultural innovations, reducing excessive pesticide use and optimizing pest control strategies.

Keywords: *electronic nose, detection, thrips, spodoptera, strawberry*

1. PENDAHULUAN

Budidaya stroberi merupakan kegiatan pertanian yang penting, yang berkontribusi terhadap ekonomi lokal dan pasar global. Namun, produktivitas dan kualitas tanaman stroberi sering terancam oleh berbagai hama, termasuk thrips dan *Spodoptera litura* (**Abdelmaksoud et al., 2020; Kessek et al., 2015; Yusup & Sartiami, 2015**). Deteksi dini dan identifikasi hama ini secara akurat sangat penting untuk pengelolaan hama yang efektif dan meminimalkan kerusakan tanaman (**Kim et al., 2023; Olatinwo & Hoogenboom, 2014**). Metode deteksi hama tradisional, seperti inspeksi visual dan pengambilan sampel manual, membutuhkan banyak tenaga kerja dan sering kali tidak memiliki ketepatan yang diperlukan untuk intervensi tepat waktu (**Conzemius et al., 2023; Dong et al., 2014; Tay et al., 2021**). Dalam beberapa tahun terakhir, hidung elektronik (e-nose) telah muncul sebagai teknologi yang menjanjikan untuk deteksi hama.

Potensi teknologi E-nose untuk memantau senyawa volatil yang dipancarkan oleh tanaman sebagai respons terhadap kerusakan atau serangan hama telah diselidiki (**Zhou & Wang, 2011**). E-nose adalah perangkat sensor elektronik yang dirancang untuk meniru penciuman manusia. Penciuman pada Al Quran disebutkan dalam surat Yusuf (94) "Sesungguhnya aku mencium bau Yusuf, sekiranya kamu tidak menuduhku lemah akal (tentu kamu membenarkan aku)". Berdasarkan ayat tersebut, indra penciuman dapat berfungsi tanpa ada perantara, berbeda dengan citra digital menggunakan CNN yang memerlukan perantara objek yaitu Cahaya (**Majid et al., 2017**). E-nose menggunakan sensor semikonduktor oksida logam (MOS) untuk mendeteksi senyawa organik volatil (VOC) yang dipancarkan oleh hama, sehingga menyediakan cara yang tidak invasif dan efisien untuk memantau keberadaan hama (**Amarathunga et al., 2024; Wesoly et al., 2023**). Penelitian ini berfokus pada penerapan sensor MOS, khususnya sensor TGS dan MQ, dalam membedakan hama thrips dan *Spodoptera* pada tanaman stroberi.

Sensor Gas Taguchi (TGS), yang dikembangkan oleh Figaro, terkenal karena sensitivitasnya yang tinggi dan konsumsi daya yang rendah. Sensor ini beroperasi dengan mendeteksi perubahan resistansi material penginderaan saat terpapar gas target. TGS adalah sensor gas jenis semikonduktor yang menggabungkan sensitivitas tinggi terhadap gas dengan konsumsi daya rendah dan masa pakai yang lama, sehingga cocok untuk berbagai aplikasi, termasuk detektor gas portabel (**Rao et al., 2020; Shih et al., 2022**).

Rangkaian sensor MQ bersifat serbaguna dan mampu mendeteksi berbagai macam gas, termasuk LPG, asap, alkohol, propana, hidrogen, metana, dan karbon monoksida. Sensor MQ2, salah satu yang paling banyak digunakan dalam rangkaian ini, beroperasi pada 5V DC dan mengonsumsi daya sekitar 800mW. Sensor ini umumnya digunakan dalam sistem pemantauan kualitas udara dalam ruangan, *breathalyzer*, dan sistem deteksi kebakaran dini (**Feltes et al., 2024**).

Dalam penelitian ini, kami menggunakan dua jenis pengujian BPPN (*Back Propagation Neural Network*), yaitu dengan penyetelan *GridSearchCV* dan tanpa penyetelan *GridSearchCV*. BPPN digunakan untuk membandingkan akurasi dari dua jenis sensor, yaitu TGS dan MQ, dalam mendeteksi hama thrips dan *Spodoptera*. *GridSearchCV* adalah teknik penyetelan hiperparameter yang bekerja secara sistematis melalui beberapa kombinasi parameter, melakukan validasi silang untuk menentukan penyetelan mana yang memberikan kinerja terbaik (**Rahman et al., 2024**).

Penelitian ini bertujuan untuk mengevaluasi efektivitas dua jenis sensor MOS, sensor TGS dan MQ, serta dampak penyetelan *GridSearchCV* pada pengujian BPPN. Penelitian ini

berupaya mengidentifikasi pendekatan yang paling efektif untuk deteksi hama dini dalam budidaya stroberi. Tujuan dari penelitian ini untuk mengevaluasi efektivitas sensor TGS dan MQ dalam membedakan antara thrips dan *Spodoptera litura* pada tanaman stroberi. Selain itu akurasi pengujian jaringan saraf *backpropagation* (BPPN) dengan dan tanpa penyetelan *GridSearchCV* dalam mengidentifikasi keberadaan hama juga dievaluasi dalam penelitian ini. Temuan penelitian ini berpotensi berkontribusi pada pengembangan strategi pengelolaan hama tingkat lanjut, yang pada akhirnya meningkatkan hasil dan kualitas panen.

2. METODE PENELITIAN

2.1. Deskripsi Tempat Penelitian

Ciwidey adalah kecamatan di Kabupaten Bandung, Jawa Barat, berada di kaki gunung Parahyangan yang memproduksi Stroberi. *Green Peas Organic Farm* Bandung (GPOFB) merupakan salah satu UMKM yang mengusahakan stroberi organik menggunakan rumah kaca. GPOFB telah melakukan protokol pada sistem produksi tanaman rumah kaca. Thrips dan hama *Spodoptera* merupakan hama pengganggu yang menjadi perhatian utama GPOFB dalam beberapa tahun terakhir, dengan populasi yang tinggi yaitu 17-36 hama thrips setiap tanaman.

2.2. Pengambilan data hama thrips dan *Spodoptera*

Hama thrips akan diambil secara langsung dengan mengetuk kepala bunga terlebih dahulu. Hama thrips yang terambil, akan dilakukan sortasi dengan mengambil spesimen yang utuh secara morfologinya. Spesimen thrips yang utuh, akan dilakukan analisis morfologi menggunakan digital mikroskop dan dihitung. Hama *Spodoptera* akan diamati pada daun tanaman stroberi secara langsung, kemudian telah diidentifikasi. Hasil analisis akan digunakan untuk mengidentifikasi sampai dengan tingkat jenis.

2.3. Pengambilan sampel

Sampel tanaman Stroberi dibagi menjadi beberapa kelompok yang memiliki jumlah thrips yang berbeda. Tanaman yang telah dihitung jumlah thripsnya dilabeli dan dikelompokkan sesuai dengan jumlahnya. Tanaman kontrol diperlakukan dengan cara disungkup dengan kantong para film di rumah kaca GPOFB. Tanaman sampel dipelihara dalam ruang iklim terkontrol pada suhu 20 ± 2 °C dengan RH 70-80%, yang sudah diterapkan pada rumah kaca GPOFB. Selanjutnya, kelompok tanaman tersebut digunakan untuk pengambilan sampel dan pengukuran volatil menggunakan E-nose.

2.4. Pengukuran E-nose

Untuk pengukuran E-nose, pengambilan sampel berdasarkan alat *Electronic Nose* 118 yang akan dimodifikasi (Mulyatni et al., 2022; Xu et al., 2018). Gambar skema dasar berdasarkan penelitian sebelumnya untuk pengambilan sampel ditunjukkan pada Gambar 1. Modifikasi dilakukan pada sampel chamber berupa penutup plastik (tinggi 40 cm × diameter dalam 20 cm) untuk tanaman stroberi dengan penutup wrap. wrap penutup udara awalnya dibiarkan terbuka untuk memastikan aliran udara yang cukup bersamaan dengan sensor e-nose. Laju aliran dijaga konstan pada 2 L/menit selama 2 menit untuk mengisi plastik (*Micro-pump*) dengan udara bersih. Setelah tabung kaca terisi, dilakukan pengukuran.



Gambar 1. (a) Desain Alat E-nose, (b) Implementasi Alat pada Tanaman Stroberi

Dalam penelitian ini, mengacu dari penelitian sebelumnya akan digunakan beberapa Sensor gas (Tabel 1). Eksperimen E-nose dilakukan langsung pada unit pengambilan sampel. Setiap tanaman stroberi dimasukkan ke dalam unit pengambilan sampel dan disimpan pada suhu kamar (28 ± 2 °C). Waktu pembilasan diatur ke 40 detik. Waktu pengukuran adalah 65 detik. Interval pengumpulan data adalah 1 detik. Ketika pengukuran selesai, data yang diperoleh disimpan untuk digunakan nanti (**Zhou & Wang, 2011**). Sebanyak 300 tanaman telah dijadikan sampel dalam percobaan ini. Tanaman diamati jumlah populasi hama terlebih dahulu, sebelum diukur volatilnya menggunakan E-nose.

Tabel 1. Sensor MQ dan TGS yang Digunakan

Deteksi Gas	Sensor MQ	Sensor TGS
Alkohol	MQ3	TGS822
Thoulene	MQ135	TGS822
CO (Karbon Monoksida)	MQ7	TGS2600
Hidrogen	MQ8	TGS2600
H ₂ S (Hidrogen Sulfida)	MQ136	TGS2602
Etanol	MQ3	TGS822
Nitrogen Oksida	MICS 6814	MICS 6814
NH ₃ (Amonia)	MICS 6814	MICS 6814

2.5. Data Keluaran Sensor

Tabel 2 menyajikan data keluaran sensor MQ yang digunakan untuk mendeteksi keberadaan gas pada tiga kondisi berbeda: keberadaan *Spodoptera*, thrips, dan tidak ada hama. Gas-gas yang terdeteksi oleh sensor mencakup Alkohol, Toluene, CO, Hidrogen, H₂S, Etanol, NH₃, dan NO₂. Keberadaan Hidrogen dan CO selalu mendominasi pada semua kondisi, dengan Hidrogen menunjukkan konsentrasi dan variabilitas tertinggi. Keberadaan Toluene relatif lebih tinggi pada kondisi thrips dibandingkan dengan kondisi lainnya. Deteksi gas-gas lain seperti Alkohol, Etanol, NH₃, dan NO₂ menunjukkan variasi yang lebih kecil antar kondisi.

Tabel 2. Data Keluaran Sensor MQ

Deteksi Gas	Spodoptera			thrips			tidak ada hama		
	Avg	n	Std Dev	Avg	n	Std Dev	Avg	n	Std Dev
Alkohol	0.092	1196	0.082	0.124	664	0.054	0.133	628	0.128
Thoulene	0.175	1196	0.278	0.675	664	0.216	0.390	628	0.312
CO	4.553	1196	1.897	4.236	664	1.387	4.984	628	1.872
Hidrogen	18.229	1196	16.578	21.043	664	17.821	23.143	628	18.482
H ₂ S	0.128	1196	0.101	0.139	664	0.163	0.177	628	0.115
Etanol	0.051	1196	0.052	0.049	664	0.026	0.059	628	0.049
NH ₃	0.787	1196	0.464	0.667	664	0.323	1.116	628	0.898
NO ₂	0.183	1196	0.131	0.170	664	0.105	0.170	628	0.153

Tabel 3 menyajikan data keluaran sensor TGS yang digunakan untuk mendeteksi keberadaan gas pada tiga kondisi berbeda: keberadaan *Spodoptera*, thrips, dan tidak ada hama. Gas-gas yang terdeteksi oleh sensor mencakup Alkohol, Toluene, CO, Hidrogen, H₂S, Etanol, NH₃, dan NO₂. Sama halnya dengan sensor MQ, keberadaan Hidrogen dan CO selalu mendominasi pada semua kondisi, dengan Hidrogen menunjukkan konsentrasi dan variabilitas tertinggi. Keberadaan Toluene relatif lebih tinggi pada kondisi thrips dibandingkan dengan kondisi lainnya. Deteksi gas-gas lain seperti Alkohol, Etanol, NH₃, dan NO₂ menunjukkan variasi yang lebih kecil antar kondisi.

Tabel 3. Data Keluaran Sensor TGS

Deteksi Gas	Spodoptera			thrips			tidak ada hama		
	Avg	n	Std Dev	Avg	n	Std Dev	Avg	n	Std Dev
Alkohol	0.089	1317	0.079	0.125	773	0.052	0.113	698	0.074
Thoulene	0.199	1317	0.324	0.632	773	0.202	0.439	698	0.300
CO	4.385	1317	1.826	4.299	773	1.394	4.867	698	1.886
Hidrogen	16.841	1317	15.313	18.787	773	17.775	26.308	698	17.400
H ₂ S	0.116	1317	0.092	0.128	773	0.175	0.154	698	0.093
Etanol	0.050	1317	0.054	0.053	773	0.060	0.058	698	0.033
NH ₃	0.737	1317	0.433	0.675	773	0.332	1.136	698	0.944
NO ₂	0.184	1317	0.132	0.174	773	0.115	0.159	698	0.159

2.6. Pelatihan dan Evaluasi Model

Pelatihan model BPPN telah dilakukan dengan mendefinisikan arsitektur jaringan saraf, termasuk jumlah lapisan, neuron per lapisan, fungsi aktivasi, dan hiperparameter lainnya. *GridSearchCV* telah disiapkan untuk penyetelan hiperparameter dengan mendefinisikan kisi parameter, yang mencakup rentang nilai untuk hiperparameter seperti laju pembelajaran, ukuran batch, dan jumlah epoch. Latih model BPPN menggunakan *GridSearchCV*, disesuaikan dengan model pada data pelatihan secara random. Sementara *GridSearchCV* mencari kombinasi hiperparameter yang optimal melalui validasi silang. Evaluasi kinerja model BPPN yang diatur pada set validasi menggunakan metrik seperti akurasi, presisi, recall, dan skor F1 untuk menilai kemampuan model dalam membedakan antara spodoptera dan thrips. Terakhir, hasil model BPPN dengan penyetelan *GridSearchCV* divisualisasikan dengan memplot kurva pembelajaran dan matriks konfusi untuk menginterpretasikan kinerja model. Pemodelan diimplementasikan dalam bahasa Python (versi 3.9.7, Python Software


Foundation, Del-aware, USA) dengan paket ML dari Scikit-learn (Versi 1.1.3). Delapan puluh persen dari sampel eksperimental, atau 80 sampel, diterapkan untuk set pelatihan, sedangkan sampel yang tersisa, atau 20 sampel, digunakan untuk set pengujian (**Lapcharoensuk & Moul, 2024**).

3. HASIL DAN PEMBAHASAN

Hidung elektronik (E-nose) adalah instrumen yang terdiri dari serangkaian sensor kimia elektronik dengan spesifisitas parsial dan sistem pengenalan pola yang dapat mendeteksi bau sederhana atau kompleks. Prinsipnya berbeda dengan metode analisis kimia seperti kromatografi gas dan kromatografi cair, spektrometri massa, resonansi magnetik nuklir, dan spektrofotometri (**Wilson, 2020**). E-nose tidak memecah zat-zat yang mudah menguap dalam suatu sampel menjadi komponen-komponen tersendiri, melainkan merespons seluruh zat-zat yang mudah menguap berdasarkan model digital tunggal. Teknologi E-Nose telah berhasil digunakan dalam berbagai aplikasi termasuk pemantauan tanaman. Baru-baru ini, penelitian difokuskan pada deteksi dini hama (**Fuentes et al., 2021**). E-nose juga telah digunakan untuk mengkarakterisasi zat mudah menguap yang dipancarkan tanaman kayu pada berbagai umur tanaman dan tingkat kerusakan akibat hama. Teknologi E-nose cepat, sensitif, spesifik, tidak merusak, dan mudah digunakan (**Wesoly et al., 2023; Wilson et al., 2019**).


Tanaman merespons kerusakan hama dengan melepaskan berbagai zat yang mudah menguap. Zat-zat volatil yang dikeluarkan oleh tumbuhan sehat sangat berbeda dengan zat-zat yang mudah menguap yang dikeluarkan oleh tumbuhan yang dirusak oleh hama (**Ali et al., 2023**). Senyawa volatil yang diinduksi sangat bervariasi dalam kuantitas dan kualitas tergantung pada spesies atau varietas tanaman. Kerusakan tanaman yang disebabkan oleh hama, melepaskan zat-zat yang mudah menguap dalam jumlah yang lebih besar dan berbeda dibandingkan kerusakan mekanis saja. Volatil tanaman yang dihasilkan sebagai respons terhadap kerusakan hama dapat memberikan informasi tentang identitas hama tersebut (**MacDougall et al., 2022**).

Hasil penelitian pada gambar 2 menggambarkan kinerja Jaringan Syaraf Tiruan *Backpropagation* (BPPN) menggunakan data a) sensor MQ dan b) sensor TGS selama 300 iterasi. Awalnya, loss dimulai pada nilai tinggi mendekati 1,0, yang menunjukkan rasio kesalahan awal model. Saat iterasi meningkat, loss menurun tajam, yang menunjukkan bahwa model sedang belajar dan meningkatkan akurasi. Kurva mulai mendatar saat mendekati 300 iterasi, yang menunjukkan bahwa model sedang konvergen dan peningkatan lebih lanjut minimal. Namun, pada sensor TGS ada beberapa fluktuasi, termasuk lonjakan penting di sekitar tanda 250 iterasi, yang dapat menunjukkan *overfitting* atau *noise* dalam data. Secara keseluruhan, tren penurunan dalam kurva kerugian menunjukkan bahwa model BPPN secara efektif belajar membedakan antara hama thrips dan *Spodoptera* menggunakan data sensor MQ maupun TGS. Stabilisasi kurva loss menjelang akhir iterasi menunjukkan bahwa model telah mencapai titik di mana pelatihan tambahan tidak secara signifikan meningkatkan kinerja. Penurunan tajam dalam kerugian selama iterasi awal menyoroti pentingnya periode pelatihan yang cukup untuk memungkinkan model mempelajari pola yang mendasarinya dalam data (**Rahman et al., 2024**). Sensor TGS tampaknya memberikan data yang andal untuk dipelajari oleh model BPPN, sebagaimana dibuktikan oleh pengurangan *loss* yang signifikan dari waktu ke waktu.



Gambar 2. Hasil Kinerja BPNN Berupa Grafik *Loss* pada (A) Sensor MQ dan (B) Sensor TGS

Matriks konfusi untuk sensor MQ dan sensor TGS memberikan rincian terperinci tentang kinerja model dalam mengklasifikasikan *Spodoptera*, Thrips, dan tidak ada hama. Matriks konfusi sensor MQ yang ditampilkan pada Gambar 3. a) menunjukkan bahwa model mengidentifikasi hama *Spodoptera* dengan benar sebesar 90%, hama thrips sebesar 89% dan tidak ada hama sebesar 82%. Berbeda dengan matriks konfusi sensor TGS yang ditampilkan pada Gambar 3. b) menunjukkan bahwa model mengidentifikasi hama *Spodoptera* dengan benar sebanyak 92%, hama thrips sebanyak 92% dan tidak ada hama sebanyak 92%. Banyaknya prediksi yang benar untuk *Spodoptera* dan thrips menunjukkan bahwa sensor TGS, dikombinasikan dengan model BPPN, efektif dalam membedakan antara kedua hama ini.




Gambar 3. Matriks Konfusi BPNN untuk (A) Sensor MQ dan (B) Sensor TGS

Penggunaan Sensor TGS menunjukkan kemampuan yang wajar untuk mengidentifikasi contoh-contoh yang tidak terdapat hama, meskipun masih ada ruang untuk perbaikan. Kesalahan klasifikasi, khususnya 20 sampel *Spodoptera* yang diprediksi tidak memiliki hama dan sebaliknya, menunjukkan bahwa sensor TGS mungkin mengalami kesulitan dengan kasus-kasus tertentu atau fitur-fitur yang tumpang tindih antara kategori-kategori ini. Jumlah kesalahan klasifikasi yang relatif rendah untuk thrips menunjukkan bahwa sensor TGS lebih layak untuk mengidentifikasi hama *Spodoptera* dan thrips di tanaman stroberi. Sensor TGS

tampaknya menyediakan data yang dapat diandalkan untuk model BPPN, sebagaimana dibuktikan oleh tingginya jumlah klasifikasi yang benar. Namun, kesalahan klasifikasi menyoroti perlunya penyempurnaan lebih lanjut, mungkin melalui pra-proses data tambahan, pemilihan fitur, atau penyetelan model (**Feltes et al., 2024**).

Hasil model BPPN dengan penyetelan *GridSearchCV* yang diterapkan pada sensor MQ dan TGS divisualisasikan dalam Gambar 4 dan Gambar 5. Grafik sebelah kiri, Akurasi Model menunjukkan akurasi pelatihan dan validasi selama beberapa periode. Akurasi pelatihan (garis biru) dimulai lebih tinggi dan berakhir sedikit di atas akurasi validasi (garis oranye), yang menunjukkan peningkatan yang konsisten dalam kinerja model seiring dengan peningkatan jumlah periode. Grafik sebelah kanan, *Loss* Model menampilkan kesalahan pelatihan dan validasi selama beberapa periode. Baik kerugian pelatihan (garis biru) maupun kerugian validasi (garis oranye) menurun tajam pada awalnya dan kemudian mendatar, mendekati nol, dengan *loss* pelatihan menurun sedikit lebih cepat daripada *loss* validasi.




Gambar 4. Akurasi Model dan *Loss* Model pada BPNN yang Telah Dilakukan Penyetelan Gridsearchcv pada Sensor MQ

Model BPPN yang telah dioptimalkan menggunakan teknik *GridSearchCV* menunjukkan keunggulan dalam analisis data sensor MQ dan TGS untuk membedakan hama thrips dan Spodoptera pada tanaman stroberi. Penerapan *GridSearchCV* untuk menyetel hyperparameter seperti jumlah neuron, fungsi aktivasi, dan tingkat pembelajaran memungkinkan optimalisasi kinerja model secara efektif. Dengan ini, model mampu memanfaatkan pola-pola kompleks dalam data sensor untuk menghasilkan prediksi yang akurat dan konsisten.

Dalam pengujian yang dilakukan, tren peningkatan akurasi pada pelatihan dan validasi mencerminkan kemampuan model untuk mempelajari fitur-fitur utama yang relevan dalam membedakan kedua jenis hama tersebut. Hal ini sangat penting mengingat akurasi model adalah salah satu indikator utama keberhasilannya dalam aplikasi praktis. Selain itu, penurunan kerugian pada pelatihan dan validasi semakin mendukung temuan bahwa model ini tidak hanya cocok dengan data pelatihan, tetapi juga mampu memberikan generalisasi yang baik terhadap data baru, memastikan keandalannya di lapangan.


Selain manfaat teknis, penerapan model BPPN yang canggih ini membuka peluang besar dalam bidang pertanian pintar. Dengan kemampuan mendeteksi hama secara otomatis, petani dapat mengurangi ketergantungan pada inspeksi manual yang sering kali membutuhkan waktu dan tenaga lebih banyak. Lebih jauh lagi, solusi ini dapat membantu

mengurangi penggunaan pestisida secara berlebihan, karena identifikasi hama yang lebih akurat memungkinkan pengendalian hama yang lebih terarah dan ramah lingkungan.



Gambar 5. Akurasi Model dan *Loss* Model pada BPNN yang telah Dilakukan Penyetelan Gridsearchcv pada Sensor TGS

Sedikit perbedaan antara akurasi dan *loss* pelatihan dan validasi menunjukkan bahwa model tersebut disetel dengan baik dan tidak *overfitting*, yang sangat penting untuk deteksi hama yang andal dalam skenario dunia nyata. Penggunaan *GridSearchCV* untuk penyetelan hiperparameter kemungkinan berkontribusi pada hasil positif ini dengan mengoptimalkan parameter model untuk kinerja yang lebih baik.



Gambar 6. Matriks Konfusi BPPN yang Telah Dilakukan Penyetelan Gridsearchcv untuk (A) Sensor MQ dan (B) Sensor TGS

Matriks konfusi BPPN yang telah dilakukan penyetelan *GridSearchCV* untuk sensor MQ dan sensor TGS ditampilkan gambar 5. Matriks konfusi sensor MQ yang ditampilkan pada Gambar 6. a) menunjukkan bahwa model mengidentifikasi hama *Spodoptera* dengan benar sebesar 94%, hama thrips sebesar 84% dan tidak ada hama sebesar 82%. Berbeda dengan matriks konfusi sensor TGS yang ditampilkan pada Gambar 6. b) menunjukkan bahwa model mengidentifikasi hama *Spodoptera* dengan benar sebanyak 92%, hama thrips sebanyak 89%

dan tidak ada hama sebanyak 89%. Banyaknya prediksi yang benar untuk *Spodoptera* dan thrips menunjukkan bahwa sensor TGS, dikombinasikan dengan model BPNN yang telah dilakukan penyetelan *GridSearchCV*, efektif dalam membedakan antara kedua hama ini (**Lapcharoensuk & Moul, 2024**).

Hasil penelitian terkait tingkat akurasi sensor dan model untuk deteksi hama *Spodoptera* dan thrips tercantum pada tabel 4. Sensor TGS mencapai akurasi tertinggi sebesar 90,50% saat menggunakan model BPNN dengan penyetelan *GridSearchCV*, yang menunjukkan bahwa proses penyetelan secara signifikan meningkatkan kemampuan model untuk membedakan antara hama thrips dan *Spodoptera*. Tanpa penyetelan, sensor TGS masih berkinerja baik, dengan akurasi 89,96%, yang menunjukkan bahwa meskipun proses penyetelan meningkatkan kinerja, sensor TGS secara inheren efektif dalam membedakan hama.

Di sisi lain, sensor MQ mencapai akurasi 87,55% dengan model BPNN dengan penyetelan *GridSearchCV*, yang lebih rendah dari kinerja sensor TGS, yang menunjukkan bahwa sensor MQ mungkin kurang sensitif atau kurang efektif dalam membedakan antara dua jenis hama. Tanpa penyetelan, akurasi sensor MQ adalah 87,35%, menunjukkan penurunan minimal, yang menunjukkan bahwa proses penyetelan memiliki efek yang kurang jelas pada kinerja sensor MQ dibandingkan dengan sensor TGS.

Tabel 4. Tingkat Akurasi Sensor dan Model untuk Deteksi Hama *Spodoptera* dan Thrips

Sensor	Model	Akurasi (%)
TGS	BPNN dengan penyetelan <i>GridSearchCV</i>	90.50
TGS	BPNN tanpa penyetelan <i>GridSearchCV</i>	89.96
MQ	BPNN dengan penyetelan <i>GridSearchCV</i>	87.55
MQ	BPNN tanpa penyetelan <i>GridSearchCV</i>	87.35

Secara keseluruhan, sensor TGS lebih unggul daripada sensor MQ dalam model yang disetel dan tidak disetel, yang menunjukkan bahwa sensor TGS lebih cocok untuk membedakan antara hama thrips dan *Spodoptera* pada tanaman stroberi. Proses penyetelan (*GridSearchCV*) meningkatkan akurasi kedua sensor, tetapi peningkatannya lebih signifikan untuk sensor TGS. Hasil ini menunjukkan bahwa penggunaan sensor TGS dengan penyetelan *GridSearchCV* memberikan akurasi terbaik untuk membedakan antara hama, dan kombinasi ini harus dipertimbangkan untuk penelitian lebih lanjut dan aplikasi praktis dalam deteksi hama pada tanaman stroberi. Penelitian di masa depan dapat mengeksplorasi metode penyetelan tambahan atau jenis sensor untuk lebih meningkatkan akurasi dan keandalan (**Rao et al., 2020**).

4. KESIMPULAN

Implementasi hidung elektronik, khususnya sensor TGS dan MQ, menunjukkan efektivitas dalam mendeteksi serta membedakan hama thrips dan *Spodoptera litura* pada tanaman stroberi. Model jaringan syaraf tiruan dengan penyetelan *GridSearchCV* meningkatkan akurasi deteksi, di mana sensor TGS menunjukkan performa yang lebih unggul dibandingkan sensor MQ. Teknologi ini menawarkan metode deteksi hama yang cepat, sensitif, dan ramah lingkungan, yang berpotensi mengurangi ketergantungan pada pestisida dan mendukung pengelolaan hama yang berkelanjutan dalam budidaya stroberi. Penelitian lebih lanjut diperlukan untuk meningkatkan selektivitas sensor dan kinerja model dalam berbagai kondisi lingkungan.

UCAPAN TERIMA KASIH

Peneliti mengucapkan terima kasih kepada Kementerian Pendidikan, Kebudayaan, Riset, dan Teknologi. Berkat dukungan yang diberikan kepada peneliti berupa bantuan dana penelitian melalui keputusan nomor 0459/E5/PG.02.00/2024 dan Perjanjian/ Kontrak Nomor 106/E5/PG.02.00.PL/2024; 048/SP2H/RT-MONO/LL4/2024; 07/LPPM/KONT/H-PDP/II.3.AU/F/2024 yang menunjang berlangsungnya penelitian ini dengan baik

DAFTAR RUJUKAN

- Abdelmaksoud, E. M., El-Refai, S. A., Mahmoud, K. W., & Ragab, M. E. (2020). Susceptibility of some new strawberry genotypes to infestation by western flower thrips, *Frankliniella occidentalis* (Pergande)(Thysanoptera: Thripidae) in the nursery. *Annals of Agricultural Sciences*, 65(2), 144–148.
- Ali, M. Y., Naseem, T., Holopainen, J. K., Liu, T., Zhang, J., & Zhang, F. (2023). Tritrophic interactions among arthropod natural enemies, herbivores and plants considering volatile blends at different scale levels. *Cells*, 12(2), 251.
- Amarathunga, D. C., Parry, H., Grundy, J., & Dorin, A. (2024). A predator–prey population dynamics simulation for biological control of *Frankliniella occidentalis* (Western Flower Thrips) by *Orius laevigatus* in strawberry plants. *Biological Control*, 188, 105409.
- Conzemius, S. R., Reay-Jones, F. P. F., Greene, J. K., Campbell, B. T., Reisig, D. D., Wang, H., & Bridges, W. C. (2023). Field screening of wild cotton, *Gossypium hirsutum*, landraces for resistance to thrips (Thysanoptera: Thripidae). *Crop Protection*, 163, 106113.
- Dong, C.-W., Yang, Y. E., Zhang, J.-Q., Zhu, H.-K., & Fei, L. I. U. (2014). Detection of thrips defect on green-peel citrus using hyperspectral imaging technology combining PCA and B-spline lighting correction method. *Journal of Integrative Agriculture*, 13(10), 2229–2235.
- Feltes, G., Ballen, S. C., Soares, A. C., Soares, J. C., Paroul, N., Steffens, J., & Steffens, C. (2024). Discrimination of artificial strawberry aroma by electronic nose based on nanocomposites. *Journal of Food Process Engineering*, 47(1), e14501.
- Fuentes, S., Tongson, E., Unnithan, R. R., & Gonzalez Viejo, C. (2021). Early detection of aphid infestation and insect-plant interaction assessment in wheat using a low-cost electronic nose (E-nose), near-infrared spectroscopy and machine learning modeling. *Sensors*, 21(17), 5948.
- Kessek, L. I. M., Tulung, M., & Salaki, C. L. (2015). Jenis dan Populasi Hama Pada Tanaman Stroberi (*Fragaria X Ananassa* Duscene). *Eugenia*, 21(1).

- Kim, C.-Y., Ahmed, S., Stanley, D., & Kim, Y. (2023). HMG-like DSP1 is a damage signal to mediate the western flower thrips, *Frankliniella occidentalis*, immune responses to tomato spotted wilt virus infection. *Developmental & Comparative Immunology*, *144*, 104706.
- Lapcharoensuk, R., & Moul, C. (2024). Geographical origin identification of Khao Dawk Mali 105 rice using combination of FT-NIR spectroscopy and machine learning algorithms. *Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy*, *318*, 124480.
- MacDougall, S., Bayansal, F., & Ahmadi, A. (2022). Emerging methods of monitoring volatile organic compounds for detection of plant pests and disease. *Biosensors*, *12*(4), 239.
- Majid, A., Speed, L., Croijmans, I., & Arshamian, A. (2017). What makes a better smeller? *Perception*, *46*(3–4), 406–430.
- Mulyatni, A. S., Kresnawaty, I., Eris, D. D., Panji, T., Kimberly, W., Widiastuti, H., PRIYONO, P., CHOTIMAH, C., & TRIYANA, K. (2022). Potensi electronic nose 118 untuk mendeteksi penyakit busuk pangkal batang pada kelapa sawit. *Menara Perkebunan*, *90*(1).
- Olatinwo, R., & Hoogenboom, G. (2014). Weather-based pest forecasting for efficient crop protection. In *Integrated pest management* (pp. 59–78). Elsevier.
- Rahman, K. S., Salehin, M. M., Roy, R., Swarna, J. B., Rakib, M. R. I., Saha, C. K., & Rahman, A. (2024). Prediction of mango quality during ripening stage using MQ-based electronic nose and multiple linear regression. *Smart Agricultural Technology*, *9*, 100558.
- Rao, J., Zhang, Y., Yang, Z., Li, S., Wu, D., Sun, C., & Chen, K. (2020). Application of electronic nose and GC–MS for detection of strawberries with vibrational damage. *Food Quality and Safety*, *4*(4), 181–192.
- Shih, H.-J., Kao, Y.-H., Chang, T.-W., Shen, W.-H., Lin, Y.-H., Lin, Y.-C., Liao, T.-S., Hsiao, W.-T., & Lin, H.-N. (2022). *Smart Phone Operated Portable Nitrogen Dioxide Gas Sensor*. *203*, 10–20.
- Tay, A., Lafont, F., Balmat, J.-F., Pessel, N., & Lhoste-Drouineau, A. (2021). Decision support system for Western Flower Thrips management in roses production. *Agricultural Systems*, *187*, 103019.
- Wesoły, M., Przewodowski, W., & Ciosek-Skibińska, P. (2023). Electronic noses and electronic tongues for the agricultural purposes. *TrAC Trends in Analytical Chemistry*, *164*, 117082.
- Wilson, A. D. (2020). Noninvasive early disease diagnosis by electronic-nose and related

- VOC-detection devices. In *Biosensors* (Vol. 10, Issue 7, p. 73). MDPI.
- Wilson, A. D., Forse, L. B., Babst, B. A., & Bataineh, M. M. (2019). Detection of emerald ash borer infestations in living green ash by noninvasive electronic-nose analysis of wood volatiles. *Biosensors*, 9(4), 123.
- Xu, S., Zhou, Z., Tian, L., Lu, H., Luo, X., & Lan, Y. (2018). Study of the similarity and recognition between volatiles of brown rice plant hoppers and rice stem based on the electronic nose. *Computers and Electronics in Agriculture*, 152, 19–25.
- Yusup, C. A., & Sartiami, D. (2015). Catatan baru hama penting, *Frankliniella intonsa* (Trybom)(Thysanoptera: Thripidae) pada tanaman stroberi di Desa Alamendah, Kecamatan Rancabali Kabupaten Bandung, Jawa Barat. *Jurnal Entomologi Indonesia*, 12(1), 1.
- Zhou, B., & Wang, J. (2011). Use of electronic nose technology for identifying rice infestation by *Nilaparvata lugens*. *Sensors and Actuators B: Chemical*, 160(1), 15–21.