

Identifikasi Penyakit Tanaman Berdasarkan Citra Daun Berbasis Web dengan Pendekatan Algoritma *Convolutional Neural Network*

Sri Mulyana^{1*}, Mansur AS², Angga Warjaya³, Inna Muthmainnah⁴, Said Iskandar Al Idrus⁵,
Zulfahmi Indra⁶

^{1,2,3,4,5,6}Fakultas Matematika dan Ilmu Pengetahuan Alam, Ilmu Komputer, Universitas Negeri Medan,
Indonesia

E-mail: ^{1*}srimulyana@mhs.unimed.ac.id, ²asmansur@unimed.ac.id, ³anggawarjaya@mhs.unimed.ac.id,
⁴innamuthmainnah@unimed.ac.id, ⁵saidiskandar@unimed.ac.id, ⁶zulfamhi.indra@mhs.unimed.ac.id
(* : corresponding author)

Abstrak

Penyakit tanaman sawi merupakan salah satu faktor utama yang dapat menurunkan kualitas dan kuantitas hasil panen, sehingga identifikasi dini sangat diperlukan untuk mendukung upaya pengendalian secara efektif. Penelitian ini bertujuan untuk mengembangkan sistem identifikasi penyakit tanaman sawi menggunakan metode *Convolutional Neural Network* (CNN) yang diintegrasikan ke dalam *platform* berbasis *web*. Identifikasi dilakukan terhadap tiga kelas, yaitu Daun Sawi Bercak, Daun Sawi Busuk, Daun Sawi Sehat, dengan penambahan kelas Bukan Daun Sawi sebagai kelas distraktor guna menguji ketahanan model terhadap citra yang tidak termasuk dalam kategori identifikasi utama. Dataset yang digunakan terdiri dari 800 citra, masing-masing 200 gambar per kelas. Model CNN dibangun dengan arsitektur *sequential* yang terdiri dari beberapa lapisan *konvolusi*, *pooling*, *dropout*, dan *dense*, serta menggunakan fungsi aktivasi ReLU dan *softmax* pada lapisan *output*. Proses pelatihan dilakukan hingga 100 *epoch*, namun dengan penggunaan *callback* berupa *EarlyStopping*, pelatihan berhenti pada *epoch* ke-60, dengan performa terbaik (*best epoch*) tercapai pada *epoch* ke-32. Evaluasi model pada data uji menunjukkan akurasi sebesar 93,75%. Model kemudian diimplementasikan ke dalam antarmuka web sehingga pengguna dapat mengunggah gambar daun dan memperoleh hasil identifikasi secara otomatis.

Kata kunci: CNN, daun sawi, pengolahan citra digital, penyakit tanaman, *website*.

Abstract

Mustard plant disease is one of the main factors that can reduce the quality and quantity of harvest yields, so early identification is essential to support effective control efforts. This study aims to develop a mustard plant disease identification system using the Convolutional Neural Network (CNN) method integrated into a web-based platform. Identification was carried out on three classes, namely Spotted Mustard Leaves, Rotten Mustard Leaves, Healthy Mustard Leaves, with the addition of the Non-Mustard Leaf class as a distractor class to test the model's resilience to images that are not included in the main identification category. The dataset used consisted of 800 images, each with 200 images per class. The CNN model was built with a sequential architecture consisting of several convolutional, pooling, dropout, and dense layers, and used ReLU and softmax activation functions in the output layer. The training process was carried out up to 100 epochs, but with the use of a callback in the form of EarlyStopping, training stopped at the 60th epoch, with the best performance (best epoch) achieved at the 32nd epoch. Model evaluation on test data showed an accuracy of 93.75%. The model is then implemented into a web interface so that users can upload leaf images and obtain identification results automatically.

Keywords: CNN, digital image processing, mustard leaves, plant disease, *website*

1. PENDAHULUAN

Tumbuhan memiliki peran penting dalam penyediaan pangan secara global. Namun, faktor lingkungan sering menjadi pemicu penyakit pada tanaman, yang berdampak signifikan pada penurunan hasil produksi [1]. Salah satu tantangan utama dalam pertanian adalah mengidentifikasi penyakit tanaman sejak dini. Identifikasi dini sangat krusial untuk meningkatkan produktivitas pertanian. Metode diagnosis tradisional umumnya melibatkan penilaian visual langsung oleh ahli patologi tanaman melalui inspeksi lapangan. Namun, pemeriksaan manual ini memiliki kelemahan, seperti tingkat akurasi yang rendah dan keterbatasan jumlah tenaga ahli [2].

Tanaman Sawi (*Brassica rapa*) merupakan salah satu komoditas sayuran yang banyak dibudidayakan di Indonesia, terutama di daerah yang memiliki iklim tropis [3]. Tanaman sawi hijau adalah salah satu sayuran yang memiliki nilai komersial dan prospek yang baik. Sayuran ini sangat digemari oleh berbagai kalangan masyarakat, sehingga permintaan terhadap sawi terus meningkat seiring dengan pertumbuhan jumlah penduduk dan kesadaran akan pentingnya kebutuhan gizi [4].

Berdasarkan data dari Badan Pusat Statistik [5], produksi tanaman sawi di Sumatera Utara menunjukkan fluktuasi yang cukup signifikan. Pada tahun 2019, produksi mencapai puncaknya dengan 78.728 ton. Namun, pada tahun 2020, 2021, dan 2022 terjadi penurunan yang cukup tajam, dengan total produksi hanya mencapai 74.370 ton. Kemudian, di tahun 2023, produksi kembali meningkat menjadi 77.970 ton. Data ini menunjukkan bahwa produksi sawi di Sumatera Utara cenderung tidak stabil dari tahun ke tahun.

Kota Medan sebagai salah satu pusat pertanian di Indonesia menghadapi berbagai tantangan dalam budidaya tanaman sawi, terutama terkait dengan penyakit dan hama. Beberapa penyakit yang sering menyerang tanaman sawi antara lain adalah: Penyakit Busuk daun *Phytophthora sp.*: Penyakit ini disebabkan oleh kondisi suhu dan kelembaban udara yang tinggi. Tanda dari penyakit ini ialah adanya bercak basah berwarna coklat kehitaman pada daun. Selanjutnya penyakit bercak daun, yang disebabkan oleh jamur *Botryodiplodia sp.* yang menyebabkan munculnya bercak berwarna kuning hingga kecoklatan pada bagian daun sehingga daun akan tampak layu dan mati [6].

Model *Convolutional Neural Network* (CNN) adalah jaringan saraf multilayer yang terdiri dari dua bagian utama, yaitu *feature extractor* dan *trainable classifier*. Bagian *feature extractor* mencakup lapisan *feature map* yang berfungsi untuk mengambil fitur dari data mentah, seperti gambar, melalui proses *convolutional filtering* dan *downsampling*. Filter konvolusi bertindak sebagai *local feature extractor* yang dapat mengidentifikasi hubungan antar elemen dalam data [7].

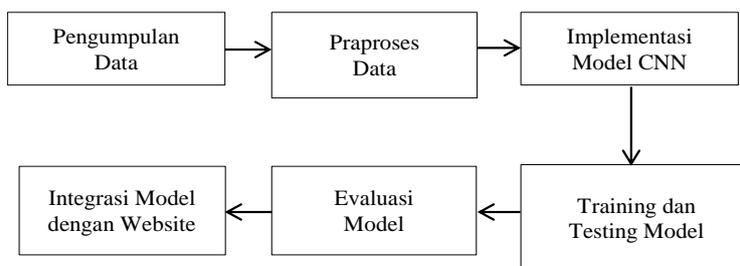
Beberapa studi sebelumnya telah menunjukkan efektivitas CNN dalam klasifikasi berbasis citra. Penelitian oleh [8] menggunakan CNN untuk klasifikasi tiga jenis penyakit kulit, yaitu jerawat, kurap, dan panu, menggunakan dataset sebanyak 800 citra digital yang terdiri dari 600 gambar untuk pelatihan dan 200 gambar untuk pengujian. Hasil akurasi yang didapat sebesar 87,14%. Penelitian yang dilakukan oleh [9] mengimplementasikan arsitektur *Convolutional Neural Network* (CNN) ResNet50 untuk mendeteksi kualitas buah dan sayuran, yang diklasifikasikan ke dalam dua kelas yaitu "Segar" dan "Rusak". Total data yang digunakan sebanyak 800 gambar, terdiri dari delapan jenis buah dan sayur, dengan pembagian 70% data latih, 15% validasi, dan 15% pengujian. Proses pelatihan dilakukan selama 50 *epoch* menggunakan optimizer Adam dan loss function *categorical cross-entropy*. Hasil pengujian mencapai akurasi sebesar 84,4%.

Namun, kedua penelitian tersebut memiliki keterbatasan, penelitian [8] belum mengintegrasikan model CNN ke dalam sistem berbasis web sehingga masih terbatas pada penggunaan oleh peneliti atau praktisi teknis. Penelitian [9] hanya menggunakan dua kelas tanaman dan tidak menyertakan kelas distraktor untuk menguji ketahanan model terhadap citra yang tidak relevan.

Oleh karena itu, penelitian ini bertujuan untuk merancang dan mengembangkan model CNN yang tidak hanya dapat mengidentifikasi penyakit pada daun sawi secara akurat, tetapi juga diintegrasikan ke dalam sistem berbasis *website* sehingga dapat diakses dan digunakan langsung oleh pengguna non-teknis seperti petani, pelajar, atau masyarakat umum. Kontribusi utama dari penelitian ini adalah pengembangan sistem identifikasi berbasis citra yang praktis, cepat, dan dapat digunakan untuk mengidentifikasi penyakit daun sawi dengan keakuratan tinggi secara langsung dari *web*. Dengan demikian, sistem ini diharapkan menjadi solusi awal yang efektif dalam membantu proses identifikasi dini dan pengambilan keputusan terkait perawatan tanaman.

2. METODE PENELITIAN

Penelitian ini akan dilaksanakan di Laboratorium Ilmu Komputer, Universitas Negeri Medan, yang berfungsi sebagai lokasi utama untuk pengembangan, implementasi, dan pengujian model-model penelitian yang dirancang. Proses pengumpulan data, sebagai bagian penting dari penelitian ini, akan dilakukan di Laboratorium Kultur Jaringan Yahdi Medan. Laboratorium tersebut berlokasi di Jalan Ambung, Tanah Enam Ratus, Kecamatan Medan Marelan, Kota Medan, Sumatera Utara 20245. Penelitian akan dilaksanakan selama 3 bulan. Adapun alur penelitian yang akan dilakukan sebagai berikut:



Gambar 1. Alur Penelitian

Alur Penelitian pada Gambar 1. dimulai dengan pengumpulan data citra daun sawi, yang kemudian melalui tahap praproses data untuk meningkatkan kualitas citra sebelum digunakan. Selanjutnya, data yang telah diproses digunakan dalam implementasi model CNN, lalu dilakukan training dan testing guna memperoleh model yang optimal. Setelah itu, dilakukan evaluasi model untuk mengukur performa. Model yang telah dievaluasi kemudian diintegrasikan ke dalam platform *website*, sehingga dapat digunakan untuk mengidentifikasi penyakit daun sawi secara cepat dan akurat.

2.1. Pengumpulan Data

Jenis data yang digunakan dalam penelitian ini adalah data primer, dengan mengumpulkan 800 citra daun sawi yang terbagi dalam empat kelas: Daun Sawi Bercak, Daun Sawi Busuk, Daun Sawi Sehat, dan Bukan Daun Sawi, masing-masing sebanyak 200 citra berformat JPG. Gambar diambil menggunakan kamera Canon i1000D dengan lebar pita Fx15000.

Tabel 1. Sumber dan Jenis Dataset yang digunakan

Label	Daun Sehat	Bercak Daun	Busuk Daun
Citra			
Deskripsi	Daun sawi yang sehat memiliki warna hijau segar merata, permukaan halus, dan bebas dari bercak atau kerusakan. Daunnya elastis, tidak layu, dan tidak menunjukkan tanda-tanda lubang atau gigitan hama	daun sawi dengan bercak daun memiliki bercak berwarna cokelat, kuning, atau kemerahan yang berbentuk bulat atau tidak beraturan. Area sekitar bercak menguning atau memudar	Daun sawi yang mengalami busuk daun akan berubah warna menjadi hitam, cokelat gelap, atau kehijauan pucat, dengan permukaan berlendir, basah, atau berair. Teksturnya menjadi lembek dan mudah robek

2.2. Praproses Data

Tahap praproses dalam pengolahan gambar bertujuan untuk mempersiapkan data agar siap digunakan dalam analisis atau pelatihan model. Langkah pertama adalah penghapusan latar

belakang (*background removal*), di mana latar belakang yang tidak relevan dihilangkan agar objek utama yang diinginkan tetap fokus. Selanjutnya, mengubah ukurannya (*resizing*) agar memiliki dimensi seragam menjadi 224x224 piksel. Langkah ini dilakukan untuk memastikan gambar dapat diproses dalam *batch*, mempercepat komputasi, dan menghindari kesalahan. Terakhir, dilakukan normalisasi data, yang mengatur nilai piksel gambar ke dalam rentang tertentu menjadi antara 0 hingga 1, hal ini dilakukan untuk meningkatkan efisiensi dan stabilitas model.

2.3. Implementasi Model CNN

Algoritma *deep learning* yang sering dipakai untuk pengenalan citra adalah model *Convolutional Neural Network* (CNN) [10]. *Convolutional Neural Network* (CNN) adalah pengembangan dari *multilayer perceptron* (MLP) yang dirancang untuk mengolah data berformat dua dimensi, seperti citra digital [11]. *Convolutional Neural Network* (CNN) umumnya terdiri dari dua komponen utama, yaitu proses ekstraksi fitur dan tahap klasifikasi. Proses ekstraksi fitur dilakukan melalui sejumlah lapisan konvolusi yang diikuti oleh operasi *max-pooling* dan penerapan fungsi aktivasi. Sementara itu, tahap klasifikasi biasanya menggunakan lapisan *fully connected* (terhubung penuh) [12]. CNN terdiri dari beberapa lapisan utama yang berfungsi untuk mengekstraksi fitur dan melakukan klasifikasi. Lapisan pertama adalah *Convolutional Layer*, yang berfungsi untuk mendeteksi fitur dari gambar, seperti tepi, tekstur, dan pola visual, dengan menggunakan filter atau kernel yang bergerak di sepanjang gambar untuk mengekstraksi fitur tersebut. Setelah itu, *Pooling Layer*, pada penelitian ini menggunakan *max pooling*, untuk mengurangi ukuran representasi gambar, mengurangi jumlah parameter dan komputasi, serta mencegah *overfitting*. Lapisan selanjutnya adalah *Fully Connected Layer*, yang berada di akhir jaringan dan menghubungkan semua neuron untuk melakukan klasifikasi akhir berdasarkan fitur yang telah diekstraksi. Terakhir, *Activation Function* digunakan untuk menambahkan non-linearitas ke dalam model; fungsi aktivasi yang digunakan adalah ReLU (*Rectified Linear Unit*) dan *Softmax* digunakan pada lapisan output untuk menghasilkan probabilitas prediksi kelas [13].

2.4. Training dan Testing Model

Proses pembagian data dilakukan menjadi dua bagian, yaitu data *training* dan data *testing*. Rincian jumlah dan proporsi pembagian data tersebut dapat dilihat pada tabel berikut:

Tabel 2. Pembagian Data

Pembagian Data	Jumlah
<i>Training</i>	60%
<i>Testing</i>	40%

Sebanyak 480 data (60% dari total) digunakan sebagai data latih (*training*) untuk melatih model dalam mengenali pola dan fitur pada gambar, sementara 320 data (40%) dialokasikan sebagai data uji (*testing*) sekaligus validasi untuk mengevaluasi kinerja model dan memantau performanya selama pelatihan.

2.5. Evaluasi Model

Evaluasi dilakukan dengan menggunakan berbagai metrik seperti: *Accuracy*, *Precision*, *Recall*, *f-1 score* dan *confusion Matrix*. Evaluasi ini dilakukan untuk memahami apakah model telah mempelajari pola dengan baik dan apakah model bisa diaplikasikan dengan baik pada data baru.

a. Confusion matrix

Confusion matrix merupakan salah satu metode dalam *data mining* yang umum digunakan untuk menilai kinerja suatu algoritma atau model [14]. Berikut merupakan tabel dari *confusion matri*.

Tabel 3. *Confusion Matrix*

		Actual Class	
		Positive	Negative
Predicted Class	Positive	TP (True Positive)	FP (False Positive)
	Negative	FN (False Negative)	TN (True Negative)

Keterangan:

TP (*True Positive*): Data yang diklasifikasikan dengan benar sebagai positif.

FP (*False Positive*): Data yang diklasifikasikan secara keliru sebagai positif, padahal sebenarnya negatif.

FN (*False Negative*): Data yang diklasifikasikan secara keliru sebagai negatif, padahal sebenarnya positif.

TN (*True Negative*): Data yang diklasifikasikan dengan tepat sebagai negatif.

b. *Accuracy*

Accuracy adalah perbandingan antara jumlah prediksi yang benar (baik positif maupun negatif) dengan total data yang ada [15]. Dengan kata lain, *accuracy* menggambarkan seberapa dekat hasil prediksi dengan nilai sebenarnya. Nilai akurasi dapat dihitung menggunakan rumus berikut:

$$Accuracy = \frac{TP + TN}{TP + FP + FN + TN} \tag{1}$$

c. *Precision*

Precision adalah rasio antara jumlah prediksi positif yang benar dengan total prediksi yang diberikan sebagai positif [15]. Dengan kata lain, dari seluruh hasil yang diprediksi positif, *precision* menunjukkan seberapa banyak yang memang benar-benar positif. Nilai *precision* dapat dihitung menggunakan rumus berikut:

$$Precision = \frac{TP}{TP + FP} \tag{2}$$

d. *Recall*

Recall merupakan rasio prediksi benar positif dibandingkan dengan keseluruhan data yang benar positif [15]. Nilai *recall* dapat dihitung dengan persamaan berikut:

$$Recall = \frac{TP}{TP + FN} \tag{3}$$

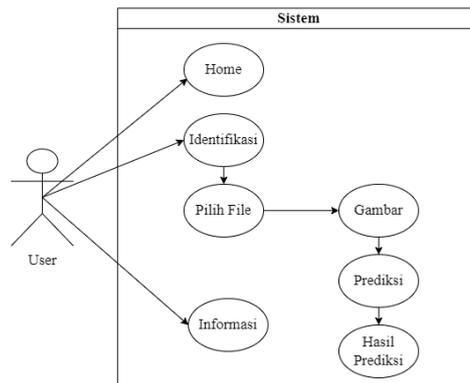
e. *F1-Score*

F1-score adalah rata-rata harmonis dari presisi dan recall [15]. Nilai *F1-score* dapat dihitung dengan persamaan berikut:

$$f1\ Score = \frac{2 \times Recall \times Precision}{Recall + Precision} \tag{4}$$

2.6. Integrasi Model dengan Website

Website adalah sebuah platform yang terdiri dari beberapa halaman yang saling terhubung melalui *hyperlink* [16]. Model CNN yang telah dilatih kemudian diintegrasikan ke dalam sistem berbasis *web* menggunakan bahasa pemrograman *Python* dengan *framework Flask*. *Website* ini terdiri dari *frontend* yang dibangun menggunakan HTML, CSS, dan *JavaScript*, yang memungkinkan pengguna untuk mengunggah gambar daun sawi melalui antarmuka *web*. Sementara itu, *backend flask* berperan dalam memuat model terlatih yang telah disimpan dalam format *.h5*, memproses gambar yang diunggah, dan menghasilkan hasil prediksi berupa jenis penyakit daun.



Gambar 1. Use Case Diagram

Pada Gambar 2. ditampilkan diagram *use case* sistem yang menunjukkan interaksi antara pengguna (*user*) dengan fitur-fitur yang tersedia pada *website* identifikasi penyakit daun sawi. Terdapat tiga menu utama, yaitu *Home*, *Identifikasi*, dan *Informasi*. Menu *Home* berisi tampilan awal yang memperkenalkan fungsi utama sistem. Menu *Identifikasi* memungkinkan pengguna untuk memilih dan mengunggah file gambar daun melalui fitur *Pilih File*, yang kemudian diproses oleh sistem melalui tahap *Gambar*, *Prediksi*, dan menghasilkan *Hasil Prediksi*. Sementara itu, menu *Informasi* memberikan penjelasan tambahan mengenai jenis penyakit daun sawi, cara penanganan serta tips merawat daun sawi.

3. HASIL DAN PEMBAHASAN

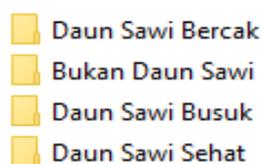
3.1. Perancangan Sistem

Perangkat keras yang digunakan meliputi komputer untuk pengembangan model dan aplikasi (Intel Core i5-2410M, RAM 8 GB, GPU NVIDIA GT 540M), kamera digital Canon i1000D untuk pengambilan data citra, serta *smartphone* Samsung Galaxy A33 5G untuk pengujian aplikasi dan pencarian literatur. Sementara itu, perangkat lunak yang digunakan mencakup sistem operasi *Windows 10 Pro 64-bit*, *browser Chrome*, IDE *Visual Studio Code* dan *Google Colab*, serta bahasa pemrograman *Python* versi 3.10.10.

3.2. Praproses Data

a. Pelabelan Data

Tahap awal dalam proses praproses data adalah melakukan pelabelan pada setiap citra sesuai dengan jenis penyakit daun sawi yang ditampilkan. Proses pelabelan ini dilakukan secara manual dengan mengklasifikasikan gambar ke dalam kelas yang telah ditentukan berdasarkan hasil pengumpulan data. Struktur pelabelan data ini dapat dilihat pada Gambar 3.



Gambar 3. Struktur Folder Pelabelan Data

b. Penghapusan Latar Belakang (*Removal Background*)

Setelah proses pelabelan data citra selesai dilakukan, langkah berikutnya adalah penghapusan latar belakang. Tahapan ini bertujuan untuk memisahkan objek utama, yaitu daun tanaman, dari elemen-elemen lain yang tidak relevan dalam gambar. Gambar 4. berikut menunjukkan contoh hasil dari proses penghapusan latar belakang (*background removal*).



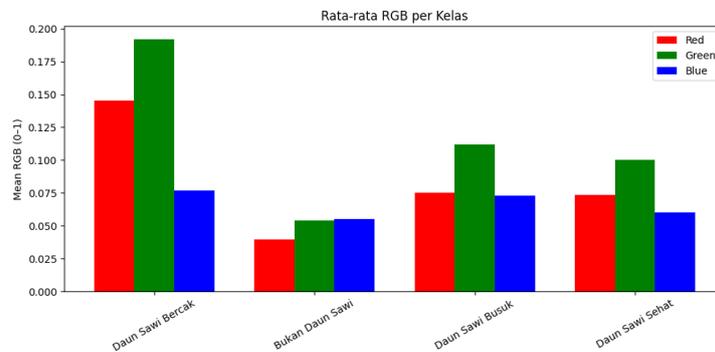
Gambar 4. Hasil *Remove Background*

c. *Resizing*

Pada tahap *resizing*, ukuran setiap gambar diubah menjadi 224x224 piksel. Penyeragaman ukuran ini bertujuan untuk meningkatkan efisiensi selama proses pelatihan serta memastikan hasil yang diperoleh lebih konsisten dan akurat.

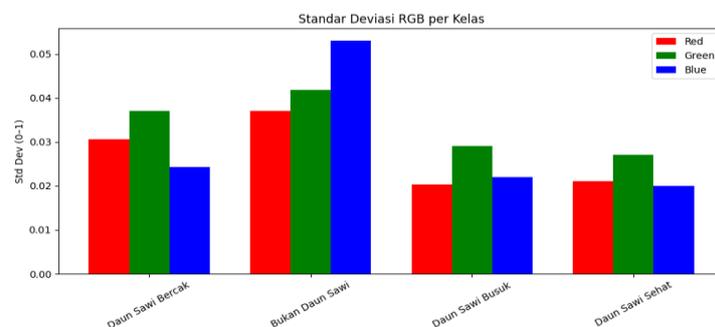
3.3. Analisis RGB

Analisis eksploratori terhadap warna dalam penelitian ini dilakukan sebagai langkah awal untuk memahami karakteristik warna pada masing-masing kelas citra. Hasil dari analisis ini ditampilkan pada Gambar 5.



Gambar 5. Hasil Analisis RGB Setiap Kelas

Pada Gambar 5. terlihat bahwa setiap kelas citra daun memiliki karakteristik warna yang berbeda dalam skala 0 hingga 1. Kelas "Daun Sawi Bercak" memiliki nilai Green tertinggi (± 0.19), diikuti Red (± 0.145), dan Blue (± 0.075), menunjukkan dominasi warna hijau dengan keunikan nilai merah yang relatif tinggi akibat bercak. Kelas "Bukan Daun Sawi" menunjukkan nilai RGB paling rendah (semua di bawah 0.06), menandakan gambar dengan warna lebih gelap atau berbeda dari daun sawi. Adapun kelas "Daun Sehat" dan "Daun Sawi Busuk" memiliki pola warna serupa, didominasi warna hijau, namun daun busuk menunjukkan sedikit peningkatan pada intensitas merah dan biru, mengindikasikan perubahan warna akibat pembusukan.



Gambar 6. Standar Deviasi untuk Setiap Kelas

Berdasarkan Gambar 6. grafik Standar Deviasi RGB per Kelas, terlihat bahwa kelas "Bukan Daun Sawi" memiliki variasi warna tertinggi, terutama pada channel biru, yang

mencerminkan keberagaman objek dan ketidakteraturan warna. Kelas "Daun Sawi Bercak" juga menunjukkan variasi cukup tinggi pada channel hijau dan merah, akibat adanya bercak yang mengubah distribusi warna. Sebaliknya, kelas "Daun Sawi Sehat" dan "Daun Sawi Busuk" menunjukkan standar deviasi yang lebih rendah, mengindikasikan warna yang lebih seragam. Hal ini menunjukkan bahwa standar deviasi RGB dapat menjadi indikator penting dalam membedakan jenis citra, di mana nilai yang tinggi menandakan gangguan atau ketidakteraturan warna pada daun.

3.4. Implementasi Model CNN

Model yang digunakan dalam penelitian ini dibangun menggunakan pendekatan CNN dengan jenis model *Sequential*, sebagaimana ditampilkan pada gambar berikut ini:

Layer (type)	Output Shape	Param #
conv2d (Conv2D)	(None, 224, 224, 16)	448
max_pooling2d (MaxPooling2D)	(None, 112, 112, 16)	0
conv2d_1 (Conv2D)	(None, 112, 112, 32)	4,640
max_pooling2d_1 (MaxPooling2D)	(None, 56, 56, 32)	0
conv2d_2 (Conv2D)	(None, 56, 56, 64)	18,496
max_pooling2d_2 (MaxPooling2D)	(None, 28, 28, 64)	0
dropout (Dropout)	(None, 28, 28, 64)	0
flatten (Flatten)	(None, 50176)	0
dense (Dense)	(None, 64)	3,211,328
dropout_1 (Dropout)	(None, 64)	0
dense_1 (Dense)	(None, 4)	260

Total params: 3,235,172 (12.34 MB)
Trainable params: 3,235,172 (12.34 MB)
Non-trainable params: 0 (0.00 B)

Gambar 7. Arsitektur Model CNN

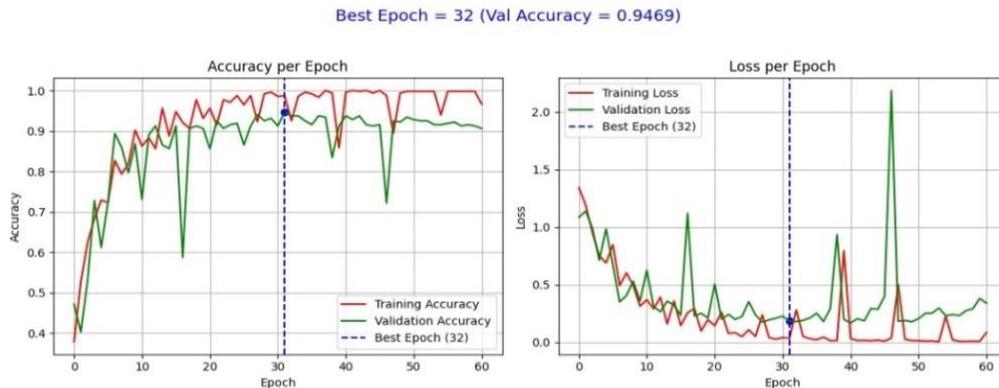
Pada Gambar 7 Model dirancang secara khusus (*custom*) tanpa menggunakan *pretrained* model, sehingga seluruh parameternya dilatih langsung berdasarkan karakteristik citra daun yang digunakan. Model menerima input berupa citra berukuran 224x224 piksel dengan tiga saluran warna (RGB), ditentukan melalui parameter input shape = (224, 224, 3). Ekstraksi fitur dimulai dengan lapisan *Conv2D* sebanyak 16 filter berukuran kernel 3x3 yang menghasilkan output berdimensi (224, 224, 16) dengan 448 parameter yang dapat dilatih. Dilanjutkan dengan *MaxPooling2D* untuk mereduksi dimensi spasial menjadi (112, 112, 16), lalu ditambahkan *Conv2D* kedua dengan 32 filter dan pooling kembali menjadi (56, 56, 32). Proses ini berlanjut dengan lapisan *Conv2D* ketiga sebanyak 64 filter yang diikuti oleh pooling hingga menghasilkan dimensi akhir (28, 28, 64). Penambahan lapisan-lapisan ini bertujuan untuk menangkap pola visual yang semakin kompleks dari citra.

Model menyisipkan lapisan *Dropout* sebesar 0,5 (50%) setelah proses konvolusi terakhir. Fitur yang telah diekstraksi kemudian diratakan melalui lapisan *Flatten* menjadi vektor berdimensi satu sepanjang 50.176, yang dilanjutkan ke lapisan *Dense* dengan 64 neuron. Lapisan ini memiliki bobot pelatihan terbesar, yaitu 3.211.328 parameter, karena semua output dari *flatten* terhubung ke tiap neuron. Selanjutnya, diterapkan kembali *Dropout* sebelum menuju ke lapisan *Dense* output yang terdiri dari 4 neuron, sesuai dengan jumlah kelas target. Fungsi aktivasi *softmax* digunakan pada lapisan output untuk menghasilkan probabilitas prediksi dari masing-masing kelas. Secara keseluruhan, model ini memiliki total 3.235.172 parameter trainable yang disesuaikan selama pelatihan, dengan harapan mampu mengidentifikasi citra daun secara akurat.

3.5. Training dan Testing Model

Proses *training* dilakukan untuk melatih model agar dapat mengenali pola dalam data dan membuat prediksi yang akurat. Model akan dilatih selama 100 *epoch* untuk memastikan proses pembelajaran yang cukup dalam menangkap fitur-fitur penting dari data. Dalam proses

pelatihan, juga digunakan *callback* berupa *EarlyStopping* untuk menghentikan pelatihan secara otomatis apabila performa pada data validasi tidak mengalami peningkatan dalam beberapa *epoch*. Penggunaan *EarlyStopping* ini bertujuan untuk mencegah *overfitting* serta memastikan bahwa model yang dihasilkan adalah model dengan kinerja terbaik berdasarkan akurasi validasi. Hasil akurasi dapat dilihat pada grafik berikut:



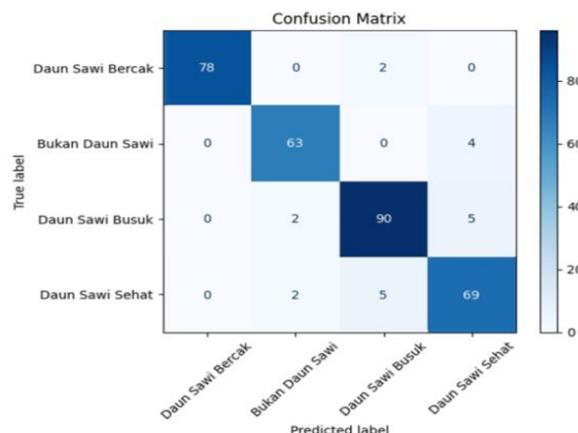
Gambar 8. Grafik *Accuracy* dan *Loss*

Pada Gambar 8. menunjukkan performa model CNN selama pelatihan sebanyak 60 *epoch*, dengan metrik akurasi dan *loss* pada data pelatihan dan validasi. Akurasi pelatihan meningkat secara konsisten hingga mendekati 100%, sedangkan akurasi validasi tetap stabil di atas 90%. Titik akurasi validasi tertinggi terjadi pada epoch ke-32 dengan nilai 94,69%, yang ditandai sebagai *epoch* terbaik (*best epoch*). Hal ini menunjukkan bahwa model mampu belajar dengan baik dan memiliki kemampuan generalisasi yang kuat terhadap data validasi.

Pada grafik *loss*, nilai *loss* pelatihan terus menurun secara stabil, sedangkan *loss* validasi menunjukkan beberapa lonjakan setelah *epoch* ke-32. Penggunaan teknik *early stopping* berdasarkan akurasi validasi terbaik terbukti efektif dalam memilih model dengan kinerja terbaik.

3.6. Evaluasi Model

Tahap ini merupakan bagian akhir sekaligus krusial untuk menentukan apakah model perlu dilatih ulang. Evaluasi model dilakukan menggunakan bahasa *Python* dengan bantuan *library scikit-learn*. Pada Gambar 9. ditampilkan *confusion matrix* serta nilai rata-rata *precision*, *recall*, *f1-score*, dan akurasi berdasarkan hasil pengujian model.



Gambar 9. *Confusion Matrix*

Gambar 9 menunjukkan bahwa model memiliki kinerja yang baik dalam mengklasifikasikan empat kelas: Daun Sawi Bercak, Bukan Daun Sawi, Daun Sawi Busuk, dan Daun Sawi Sehat. Kelas Daun Sawi Bercak dan Daun Sawi Busuk diklasifikasikan dengan

masing-masing 78 dan 90 prediksi benar. Beberapa kesalahan terjadi, seperti 4 sampel Bukan Daun Sawi yang diklasifikasikan sebagai Daun Sawi Sehat, serta 5 sampel Daun Sawi Sehat yang salah diprediksi sebagai Daun Sawi Busuk. Berdasarkan perhitungan, akurasi model mencapai 93.75%, yang mencerminkan kinerja model yang baik dan kemampuan generalisasi yang tinggi terhadap data uji.

Nilai keseluruhan dari *precision*, *recall*, dan *f1-score* untuk masing-masing kelas berdasarkan hasil pengujian model dapat dilihat pada tabel di bawah ini:

Tabel 4. Hasil Pengujian Model

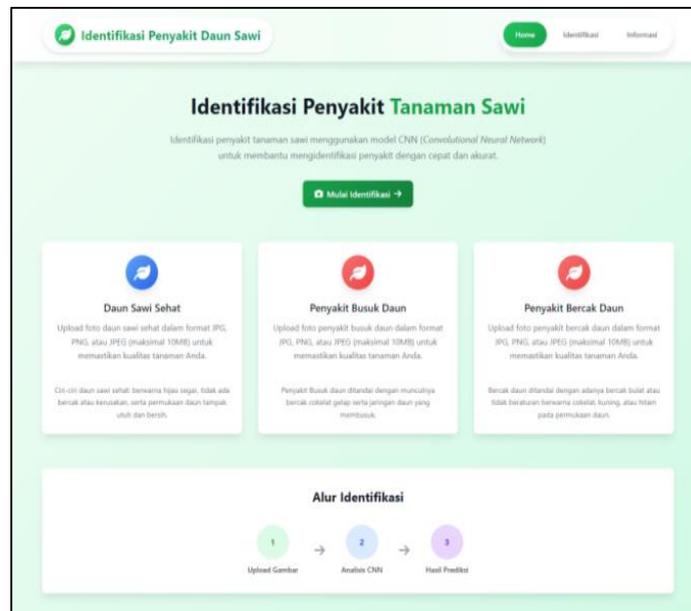
Label	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>
Daun Sawi Bercak	1.00	0.975	0.987
Bukan Daun Sawi	0.969	0.940	0.954
Daun Sawi Busuk	0.947	0.928	0.937
Daun Sawi Sehat	0.945	0.908	0.926
Rata-Rata	0.965	0.938	0.951
Akurasi	93.75%		

Akurasi model CNN sebesar 93% menunjukkan bahwa model sudah cukup baik dalam mengenali pola dari citra daun, namun masih terdapat 7% kesalahan prediksi yang perlu diperhatikan. Salah satu penyebabnya kemungkinan karena model belum cukup *robust* terhadap variasi data, mengingat pelatihan dilakukan tanpa proses augmentasi gambar. Tanpa augmentasi, model cenderung belajar dari pola terbatas sehingga kurang mampu menggeneralisasi terhadap data baru dengan kondisi pencahayaan, sudut pandang, atau bentuk daun yang berbeda.

3.7. Integrasi Model dengan Website

Berikut ini adalah halaman-halaman yang tersedia pada *website* yang dikembangkan.

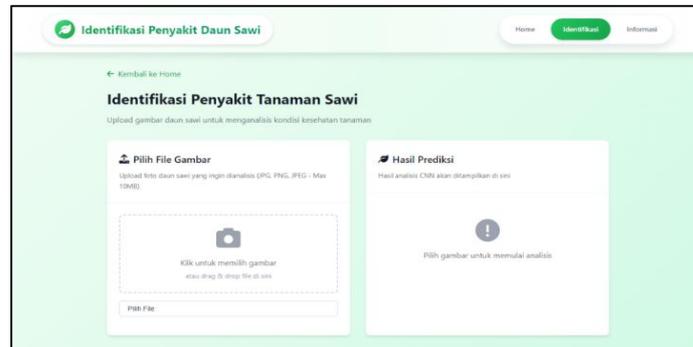
a. Menu Home



Gambar 10. Menu Home

Gambar 10. Menunjukkan tampilan halaman *home* pada yang menampilkan fitur utama berupa identifikasi penyakit daun sawi. Pengguna dapat mengunggah gambar daun untuk dianalisis, lalu mendapatkan hasil identifikasi dan rekomendasi penanganan. Alur Identifikasi ditampilkan secara sederhana: Upload Gambar → Analisis CNN → Hasil Prediksi.

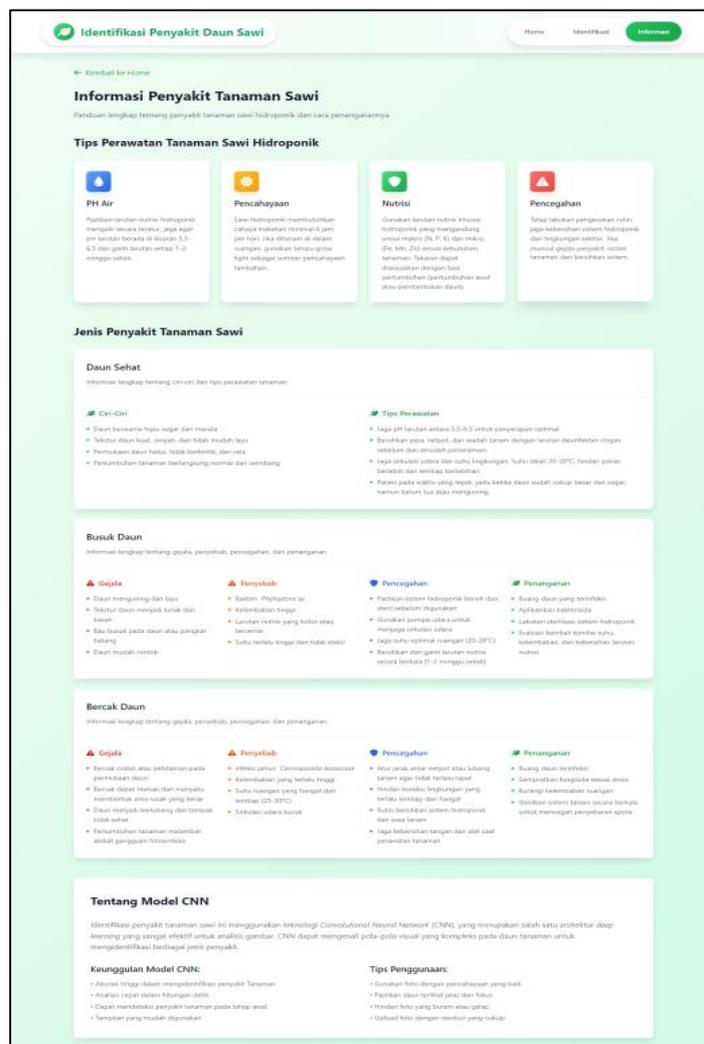
b. Menu Identifikasi



Gambar 11. Menu Identifikasi

Gambar 11 Menunjukkan halaman yang memungkinkan pengguna mengunggah gambar daun sawi dalam format JPG, PNG, atau JPEG (maksimal 10MB) untuk dianalisis oleh model CNN. Setelah gambar dipilih, hasil prediksi akan muncul di sisi kanan, menampilkan informasi terkait kondisi kesehatan daun. Tampilan ini dirancang sederhana agar pengguna dapat melakukan analisis secara praktis dan efisien.

c. Menu Informasi



Gambar 12. Menu Informasi

Pada Gambar 12 Menampilkan menu Informasi Penyakit Tanaman Sawi menyajikan panduan lengkap tentang perawatan tanaman sawi serta informasi gejala, penyebab, pencegahan, dan penanganan penyakit daun seperti busuk daun dan bercak daun. Selain itu, dijelaskan pula ciri-ciri daun sehat dan tips pemeliharaan yang optimal.

4. KESIMPULAN DAN SARAN

Berdasarkan hasil yang diperoleh, penelitian ini berhasil mengembangkan sistem identifikasi penyakit pada tanaman sawi menggunakan metode *Convolutional Neural Network* (CNN) yang diintegrasikan ke dalam *website*. Model CNN dirancang menggunakan arsitektur *sequential* yang terdiri dari beberapa lapisan konvolusi, *pooling*, *dropout*, dan *dense*, serta dioptimalkan dengan fungsi aktivasi ReLU dan *softmax*. Proses pelatihan dilakukan menggunakan 800 citra daun sawi yang terbagi dalam empat kelas, yaitu Daun Sehat, Daun Bercak, Daun Busuk, dan Bukan Daun Sawi sebagai kelas distraktor. Pelatihan model berhenti secara otomatis pada *epoch* ke-60 melalui penggunaan *EarlyStopping*, dengan performa terbaik tercapai pada *epoch* ke-32. Hasil evaluasi menunjukkan bahwa model mampu mengidentifikasi citra daun sawi dengan akurasi sebesar 93,75%, yang menunjukkan tingkat performa yang tinggi dalam pengenalan pola visual antar kelas. Model kemudian berhasil diimplementasikan ke dalam antarmuka *web* yang memungkinkan pengguna untuk mengunggah gambar daun dan memperoleh hasil identifikasi secara langsung, cepat, dan praktis.

Agar performa model dapat lebih ditingkatkan, disarankan untuk memperluas variasi data pelatihan melalui penerapan teknik augmentasi citra, seperti rotasi, *zoom*, *flipping*, dan perubahan tingkat kecerahan (*brightness*). Teknik ini akan membantu memperkaya representasi fitur dalam data dan meningkatkan generalisasi model terhadap citra baru. Selain itu, pada pengembangan selanjutnya, sistem dapat dilengkapi dengan fitur *feedback* pengguna, penyimpanan riwayat identifikasi, atau pengujian lapangan untuk menilai keakuratan sistem dalam kondisi nyata di lingkungan pertanian.

DAFTAR PUSTAKA

- [1] M. Sari, "Tantangan Global dalam Pertanian: Pangan, Iklim, dan Keamanan Pangan," Mertani. Accessed: Nov. 15, 2024. [Online]. Available: <https://www.mertani.co.id/id/post/tantangan-global-dalam-pertanian-pangan-iklim-dan-keamanan-pangan>
- [2] M. R. Alamadani and D. Indriyana, "Klasifikasi Kesehatan Tanaman Padi Menggunakan Algoritma Convolutional Neural Network," *J. Mhs. Tek. Inform.*, vol. 8, no. 5, pp. 10177–10182, 2024, doi: <https://doi.org/10.36040/jati.v8i5.10844>.
- [3] Y. P. Efendy, H. Suhardjono, and W. Widiwujani, "Pertumbuhan dan Produksi Tanaman Sawi Pakcoy (*Brassica rapa L.*) Akibat Dibudidayakan pada Berbagai Komposisi Media Tanam dan Konsentrasi Pupuk Organik Cair dengan Sistem Vertikultur," *J. Agrotropika*, vol. 23, no. 1, pp. 69-79, 2024, doi: <https://doi.org/10.23960/ja.v23i1.8226>.
- [4] R. Krisnawan, "Pertumbuhan dan Hasil Tanaman Sawi Hijau (*Brassica juncea L.*) Dengan Lantunan Murottal Al-Qur'an dan Pupuk NPK 16:16:16," *Jurnal Ilmiah Mahasiswa Pertanian*, vol. 2, no. 1, pp. 1–15, 2022.
- [5] B. P. Statistik, "Produksi Tanaman Sayuran, 2021-2023," Jakarta, 2023. [Online]. Available: <https://www.bps.go.id/id/statistics-table/2/NjEjMg==/production-of-vegetables.html>
- [6] S. Hanifah, N. Apriliani, E. T. Suciarto, and E. S. Purwati, "Identifikasi Jamur Penyebab Penyakit pada Tanaman Sawi Putih (*Brassica rapa L.*) dan Persentase Penyakitnya di Desa Serang Kecamatan Karangreja, Kabupaten Purbalingga," *Bio Eksakta J. Ilm. Biol. Unsoed*, vol. 2, no. 2020, pp. 487–501, 2020, <https://doi.org/10.20884/1.bioe.2020.2.3.3394>.
- [7] C. R. Rahman *et al.*, "Identification and recognition of rice diseases and pests using

- convolutional neural networks,” *Biosyst. Eng.*, vol. 194, pp. 112–120, 2020, doi: <https://doi.org/10.1016/j.biosystemseng.2020.03.020>.
- [8] I. Fathurrahman, *et al.*, “Pengembangan Model Convolutional Neural Network (CNN) untuk Klasifikasi Penyakit Kulit Berbasis Citra Digital,” *Infotek J. Inform. dan Teknol.*, vol. 8, no. 1, pp. 298–308, 2025, doi: <https://doi.org/10.1016/j.biosystemseng.2020.03.020>.
- [9] Q. S. A. Wasilah, M. Martanto, A. R. Dikananda, and D. Rohman, “Implementasi Cnn Resnet50 Untuk Mendeteksi Kualitas,” *J. Mhs. Tek. Inform.*, vol. 9, no. 3, pp. 3675–3682, 2025, doi: <https://doi.org/10.36040/jati.v9i3.13349>.
- [10] I. N. Suandana and W. Apriandari, “Pemanfaatan CNN (Convolutional Neural Network) dan Mobile V2 dalam Klasifikasi Rempah-Rempah Lokal Di Indonesia,” *J. Mhs. Tek. Inform.*, vol. 8, no. 5, 2024, doi: <https://doi.org/10.36040/jati.v8i5.10873>.
- [11] P. N. Candra and A. Prapanca, “Klasifikasi Gambar Asli dan Manipulasi Menggunakan Error Level Analysis (ELA) Sebagai Proses Komputasi Metode Convolutional Neural Network (CNN),” *J. Informatics Comput. Sci.*, vol. 2, no. 01, pp. 9–18, 2020, doi: <https://doi.org/10.26740/jinacs.v2n01.p9-18>.
- [12] M. Muslih and E. H. Rachmawanto, “Convolutional Neural Network (Cnn) Untuk Klasifikasi Citra Penyakit Diabetes Retinopathy,” *Skanika*, vol. 5, no. 2, pp. 167–176, 2022, doi: <https://doi.org/10.36080/skanika.v5i2.2945>.
- [13] S. Wahyuni and M. Sulaeman, “Penerapan Algoritma Deep Learning Untuk Sistem Absensi Kehadiran Deteksi Wajah Di PT Karya Komponen Presisi,” *J. Inform. SIMANTIK*, vol. 7, no. 1, pp. 5–6, 2022, [Online]. Available: <https://simantik.panca-sakti.ac.id/index.php/simantik/article/view/127>
- [14] N. F. Arminda, N. Sulistiyowati, and T. Nur Padilah, “Implementasi Algoritma Multinomial Naive Bayes Pada Analisis Sentimen Terhadap Ulasan Pengguna Aplikasi Brimo,” *JATI: Jurnal Mhs. Tek. Inform.*, vol. 7, no. 3, pp. 1817–1822, 2023, doi: <https://doi.org/10.36040/jati.v7i3.7012>.
- [15] R. Merdiansah, S. Siska, and A. A. Ridha, “Analisis Sentimen Pengguna X Indonesia Terkait Kendaraan Listrik Menggunakan IndoBERT,” *J. Ilmu Komput. dan Sist. Inf.*, vol. 7, no. 1, pp. 221–228, 2024, doi: <https://doi.org/10.55338/jikoms.v7i1.2895>.
- [16] A. Hidayat *et al.*, “Metode Convolutional Neural Network (CNN) Untuk Klasifikasi Tingkat Kesehatan Tanaman Lidah Buaya Berbasis Web,” *J. Tek. Inform. dan Sist. Inf.*, vol. 11, no. 4, pp. 392–406, 2024.