

**PENERAPAN FITUR EKSTRAKSI FUZZY LOCAL BINARY PATTERN (FLBP)
DAN ALGORITMA CONVOLUTIONAL NEURAL NETWORK (CNN)
UNTUK DETEKSI PENYAKIT PADA TANAMAN
(STUDI KASUS TANAMAN SELADA HIDROPONIK PADA
LABORATORIUM KULTUR JARINGAN YAHDI MEDAN)**

Inna Muthmainnah, Yulita Molliq Rangkuti, Zulfahmi Indra, Sri Mulyana, Angga Warjaya, Mansur AS
Ilmu Komputer, Universitas Negeri Medan
Jl. William Iskandar, Ps. V, Kenangan Baru, Kec. Percut Sei Tuan, Kab. Deli Serdang
innamuthmainnah411@gmail.com

ABSTRAK

Tanaman selada merupakan salah satu komoditas hortikultura yang rentan terhadap serangan penyakit daun yang dapat menurunkan kualitas dan hasil panen. Deteksi penyakit secara manual memerlukan keahlian khusus dan waktu yang tidak efisien, sehingga dibutuhkan sistem otomatis berbasis citra digital. Penelitian ini bertujuan mengembangkan sistem informasi deteksi penyakit daun selada menggunakan metode *Fuzzy Local Binary Pattern* (FLBP) sebagai ekstraksi fitur tekstur dan *Convolutional Neural Network* (CNN) untuk klasifikasi citra. Dataset terdiri dari 330 gambar daun selada yang terbagi dalam tiga kelas: daun sehat, daun bercak, dan daun busuk. Proses ekstraksi menghasilkan vektor histogram berdimensi sepuluh untuk setiap citra, yang digunakan dalam pelatihan model CNN dengan arsitektur *Functional*, lapisan *Concatenate*, *Dropout*, dan *Dense*, serta fungsi aktivasi *ReLU* dan *Softmax*. Pelatihan dilakukan selama 60 *epoch* dengan *EarlyStopping* untuk mencegah *overfitting*. Hasil evaluasi menunjukkan akurasi mencapai 93,94% dengan nilai *precision*, *recall*, dan *F1-score* tinggi di setiap kelas. Model kemudian diintegrasikan ke dalam antarmuka web yang memungkinkan pengguna mengunggah citra daun dan memperoleh hasil klasifikasi secara otomatis.

Kata kunci : Deteksi citra, FLBP, CNN, Penyakit tanaman, Daun selada, Website

1. PENDAHULUAN

Pemanfaatan teknologi dalam bidang pertanian telah mendorong terjadinya transformasi besar dalam sistem budidaya modern. Inovasi seperti sistem pertanian presisi, *Internet of Things* (IoT), serta analisis berbasis citra digital menjadi faktor kunci dalam meningkatkan produktivitas dan efisiensi pertanian [1]. Penerapan teknologi ini tidak hanya berpengaruh terhadap peningkatan hasil panen, tetapi juga dalam hal efisiensi penggunaan sumber daya air, lahan, serta pengendalian lingkungan tumbuh tanaman.

Salah satu inovasi yang saat ini berkembang pesat adalah sistem hidroponik, yang memungkinkan tanaman tumbuh tanpa tanah dengan media air yang diperkaya nutrisi. Sistem ini memberikan keuntungan signifikan terutama di wilayah urban dan daerah dengan keterbatasan lahan, karena efisiensi penggunaan air dan ruang lebih tinggi dibandingkan sistem konvensional. Namun, seiring dengan meningkatnya penggunaan sistem hidroponik, tantangan baru juga muncul, terutama dalam pengendalian penyakit tanaman yang dapat menyebabkan penurunan hasil panen secara drastis.

Salah satu komoditas yang banyak dibudidayakan secara hidroponik adalah selada (*Lactuca sativa* L.), yang memiliki nilai ekonomi tinggi dan permintaan pasar yang stabil [2]. Meskipun demikian, tingkat produksi selada di Indonesia masih tergolong rendah. Berdasarkan data Badan Pusat Statistik (2021), produksi selada nasional baru

mencapai 727.467 ton dan belum mampu memenuhi kebutuhan pasar. Salah satu penyebab utamanya adalah tingginya tingkat serangan penyakit daun yang sering sulit dideteksi pada tahap awal [3].

Menurut penelitian [4], dua penyakit utama yang sering menyerang selada hidroponik adalah busuk basah (*Phytophthora infestans*) dan bercak daun (*Cercospora capsici*). Keduanya berdampak pada terganggunya proses fotosintesis dan penyerapan nutrisi, yang berujung pada penurunan kualitas maupun kuantitas hasil panen. Dalam wawancara dengan Prof. Dr. Fauziyah Harahap, M.Si., dijelaskan bahwa gejala penyakit seperti bercak daun ditandai dengan adanya lapisan abu-abu pada permukaan bawah daun dan lubang-lubang kecil, sementara busuk basah menyebabkan perubahan warna daun menjadi coklat serta pembusukan di pangkal daun.

Selama ini, deteksi penyakit tanaman umumnya dilakukan melalui observasi visual dan analisis laboratorium. Meskipun metode ini akurat, prosesnya membutuhkan waktu lama dan memerlukan keahlian khusus di bidang patologi tanaman [5]. Selain itu, pada tahap awal infeksi, gejala sering kali bersifat samar dan sulit dibedakan secara manual. Hal ini membuka peluang untuk pemanfaatan teknologi kecerdasan buatan, terutama pengolahan citra digital dan machine learning, dalam membantu proses diagnosis penyakit tanaman secara cepat dan objektif.

Berbagai penelitian telah dilakukan untuk mengembangkan sistem deteksi otomatis berbasis

citra daun tanaman. Salah satu pendekatan yang terbukti efektif adalah kombinasi antara ekstraksi fitur tekstur dan algoritma klasifikasi berbasis *deep learning*. *Fuzzy Local Binary Pattern* (FLBP) merupakan salah satu metode ekstraksi fitur yang banyak digunakan untuk mengatasi keterbatasan LBP konvensional dalam kondisi pencahayaan tidak seragam atau citra yang terdegradasi oleh noise [6]. FLBP menghasilkan deskripsi tekstur yang lebih adaptif dan mampu menangkap variasi halus pada pola piksel daun yang menjadi indikator gejala penyakit.

Dalam hal klasifikasi, *Convolutional Neural Network* (CNN) telah menjadi pendekatan yang dominan karena kemampuannya mengenali pola visual kompleks secara otomatis melalui proses pembelajaran berlapis. Penelitian oleh [7] menunjukkan bahwa CNN dapat mencapai akurasi hingga 97,5% dalam identifikasi penyakit daun tomat, melampaui performa metode tradisional seperti SVM. Keunggulan CNN terletak pada kemampuannya dalam melakukan *feature learning* langsung dari data citra tanpa memerlukan perancangan fitur manual, sehingga sangat cocok diterapkan dalam kasus citra tanaman yang memiliki variasi tekstur dan warna tinggi.

Berdasarkan studi-studi tersebut, penelitian ini berfokus pada penerapan kombinasi *Fuzzy Local Binary Pattern* (FLBP) sebagai metode ekstraksi fitur dan *Convolutional Neural Network* (CNN) sebagai algoritma klasifikasi utama untuk mendeteksi penyakit daun selada hidroponik. Selain itu, penelitian ini juga mengintegrasikan sistem deteksi tersebut ke dalam platform berbasis web agar dapat diakses secara luas oleh petani, peneliti, maupun masyarakat umum. Platform ini diharapkan dapat menjadi solusi praktis dan edukatif dalam membantu proses diagnosis penyakit tanaman secara cepat, efisien, dan akurat.

2. TINJAUAN PUSTAKA

2.1. Penelitian Terdahulu

Penelitian yang dilakukan oleh Sari dan Haryatmi (2021) menerapkan metode *Convolutional Neural Network* (CNN) untuk mendeteksi citra biji jagung kering sebagai upaya otomatisasi proses seleksi di industri pertanian. Penelitian ini melalui tiga tahap utama, yaitu *preprocessing* citra, pelatihan model CNN dengan tujuh lapisan konvolusi, dan pengujian menggunakan 20 citra uji dari total 100 data. Hasil penelitian menunjukkan bahwa model CNN mampu mendeteksi biji jagung dengan akurasi rata-rata 90,29%, dengan nilai tertinggi mencapai 100% pada beberapa sampel. Studi ini membuktikan bahwa CNN efektif dalam mengenali pola visual kompleks pada citra hasil pertanian dan dapat menjadi dasar pengembangan sistem deteksi penyakit tanaman secara otomatis [8].

2.2. Laboratorium Kultur Jaringan Yahdi Medan

Laboratorium Kultur Jaringan Yahdi Medan merupakan salah satu pusat penelitian dan pengembangan bioteknologi pertanian di Kota Medan, Sumatera Utara. Laboratorium ini berperan penting dalam pengembangan teknik kultur jaringan yang digunakan untuk memperbanyak tanaman secara aseptik, memproduksi bibit unggul, serta melakukan pemuliaan tanaman dengan karakteristik unggul. Selain kegiatan penelitian, laboratorium ini juga menjadi wadah kolaborasi dengan berbagai institusi akademik dan lembaga penelitian. Fokus utamanya meliputi pengembangan varietas tanaman yang tahan terhadap hama dan penyakit serta memiliki daya adaptasi tinggi terhadap perubahan iklim. Keberadaan fasilitas laboratorium yang lengkap menjadikan Yahdi Medan sebagai mitra potensial dalam penelitian berbasis teknologi pertanian modern, termasuk penelitian terkait sistem deteksi penyakit tanaman berbasis citra digital yang menjadi fokus penelitian ini.

2.3. Sistem Pertanian Hidroponik

Sistem hidroponik merupakan inovasi budidaya tanaman tanpa menggunakan tanah sebagai media tumbuh, melainkan air yang diperkaya dengan larutan nutrisi. Metode ini menjadi solusi efektif terhadap keterbatasan lahan dan efisiensi penggunaan air, sehingga cocok diterapkan di wilayah urban maupun lahan sempit. Menurut Wulansari, hidroponik mampu menghasilkan produktivitas tinggi dengan risiko kontaminasi tanah yang rendah. Namun demikian, sistem ini juga memiliki tantangan dalam hal pengendalian penyakit, karena lingkungan air dan kelembapan tinggi dapat mempercepat penyebaran patogen [9]. Beberapa tipe sistem hidroponik yang sering diterapkan antara lain *Nutrient Film Technique* (NFT), *Deep Flow Technique* (DFT), dan *Drip System* [10]. Masing-masing memiliki keunggulan tersendiri dalam sirkulasi nutrisi dan efisiensi energi. Dalam konteks penelitian ini, sistem hidroponik dipilih karena sifatnya yang terukur dan seragam, sehingga mempermudah proses pengambilan data citra daun tanaman untuk analisis penyakit.

2.4. Tanaman Selada

Selada merupakan salah satu komoditas hortikultura bernilai ekonomi tinggi yang banyak dibudidayakan di Indonesia. Tanaman ini memiliki kandungan gizi seperti serat, vitamin, dan mineral yang tinggi, sehingga digemari masyarakat. Namun, produktivitas selada nasional masih belum optimal. Berdasarkan data Badan Pusat Statistik (2021), produksi selada di Indonesia baru mencapai 727.467 ton, jumlah yang belum mampu memenuhi permintaan pasar. Salah satu penyebabnya adalah tingginya tingkat serangan penyakit daun pada sistem budidaya hidroponik, seperti busuk basah (*Phytophthora infestans*) dan bercak daun (*Cercospora capsici*). Kedua penyakit ini menyerang

bagian daun, menghambat proses fotosintesis, dan menurunkan kualitas hasil panen. Oleh karena itu, deteksi dini penyakit daun selada menjadi langkah penting dalam menjaga kualitas dan produktivitas pertanian hidroponik.

2.5. Pengolahan Citra (Image Processing)

Pengolahan citra atau *image processing* adalah suatu sistem yang melibatkan proses dengan masukan berupa citra dan menghasilkan keluaran juga dalam bentuk citra. Pengolahan citra dapat dibagi menjadi dua kategori yaitu: memperbaiki citra sesuai kebutuhan dan mengolah informasi yang terkandung di dalam citra. Beberapa jenis citra yang umum digunakan meliputi Citra Biner (*monokrom*), Citra Skala Keabuan (*gray scale*), Citra Warna, dan Citra Warna Berindeks.

2.6. Ekstraksi Fitur Warna RGB

Ekstraksi fitur warna RGB adalah proses pengambilan informasi warna dari citra berdasarkan tiga saluran warna utama: merah (*Red*), hijau (*Green*), dan biru (*Blue*). Dalam sistem RGB, setiap warna memiliki nilai yang berkisar antara 0 hingga 255, sehingga setiap komponen memiliki 256 tingkat intensitas. Pemilihan skala 256 ini didasarkan pada penggunaan 8 digit bilangan biner oleh mesin komputer.

2.7. Ekstraksi Fitur Bentuk

Ekstraksi ciri adalah proses untuk memperoleh karakteristik pembeda yang digunakan untuk membedakan satu objek dari objek lainnya.

2.8. Ekstraksi Fitur Fuzzy Local Binary Pattern (FLBP)

Fuzzy Local Binary Pattern (FLBP) adalah pengembangan dari metode *Local Binary Pattern* (LBP) untuk ekstraksi fitur tekstur yang memperkenalkan logika fuzzy guna meningkatkan daya diskriminasi pada gambar yang berisik atau mengalami perubahan intensitas.

2.9. Convolutional Neural Network

Algoritma *deep learning* yang sering dipakai untuk pengenalan citra adalah model *Convolutional Neural Network* (CNN). Model ini ditandai oleh arsitektur yang sederhana, jumlah parameter pelatihan yang lebih sedikit, dan tingkat fleksibilitas yang lebih tinggi. *Convolutional Neural Network* (CNN) adalah pengembangan dari *multilayer perceptron* (MLP) yang dirancang untuk mengolah data berformat dua dimensi, seperti citra digital.

2.10. Convolutional Layer

Lapisan konvolusi adalah komponen penting dalam arsitektur CNN. Pada tahap ini, konvolusi diterapkan pada *output* dari lapisan sebelumnya. Proses ini merupakan elemen utama yang membentuk dasar arsitektur jaringan CNN. Konvolusi merupakan

istilah matematika yang merujuk pada penerapan berulang satu fungsi terhadap *output* dari fungsi lainnya.

2.11. Pooling Layer

Pooling adalah operasi gabungan yang digunakan untuk mengurangi ukuran *array*. Pada dasarnya, tahap *pooling* terdiri dari filter dengan ukuran dan langkah tertentu yang bergerak secara bergantian di seluruh area objek grafik (*feature map*).

2.12. Fully-Connected Layer

Fully Connected Layer adalah lapisan di mana semua neuron yang diaktifkan di lapisan sebelumnya terhubung ke neuron di lapisan berikutnya, mirip dengan jaringan saraf biasa. Lapisan ini terutama digunakan dalam MLP (*Multilayer Perceptron*) dengan tujuan mengubah ukuran data agar dapat diklasifikasikan secara linier.

2.13. Confusion Matrix

Confusion matrix adalah teknik yang sering digunakan untuk mengevaluasi metode klasifikasi, baik untuk klasifikasi gambar maupun data numerik. Metode ini berguna untuk mengukur seberapa baik classifier dalam membuat prediksi pada kategori yang berbeda.

2.14. Accuracy

Accuracy merupakan rasio prediksi benar (positif dan negatif) dengan keseluruhan data. Dengan kata lain, *accuracy* merupakan tingkat kedekatan nilai prediksi dengan nilai aktual (sebenarnya). Nilai akurasi dapat dihitung dengan persamaan berikut:

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

2.15. Precision

precision merupakan rasio prediksi benar positif dibandingkan dengan keseluruhan hasil yang diprediksi positif. Dari semua kelas positif yang telah di prediksi dengan benar, berapa banyak data yang benar-benar positif. Nilai presisi dapat dihitung dengan persamaan berikut:

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

2.16. Recall

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

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

2.17. F-1 Score


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

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

2.18. Implementasi Sistem Berbasis Website

Untuk meningkatkan kemudahan akses dan pemanfaatan hasil penelitian, sistem deteksi penyakit selada diimplementasikan dalam bentuk platform berbasis web. Platform ini berfungsi sebagai media interaktif yang memungkinkan pengguna mengunggah citra daun dan memperoleh hasil deteksi secara otomatis. Selain itu, website juga berperan sebagai sarana edukasi dan informasi bagi petani, peneliti, maupun masyarakat umum mengenai penyakit tanaman hidroponik. Dengan pendekatan berbasis web, sistem ini dapat diakses secara luas tanpa memerlukan perangkat khusus, menjadikannya solusi praktis bagi sektor pertanian digital.

3. METODE PENELITIAN




Gambar 1. Alur Penelitian

Penelitian ini menggunakan metode kuantitatif, karena data yang digunakan mencakup citra daun tanaman selada yang akan dikonversi menjadi angka dalam bentuk matriks. Penelitian ini akan dilaksanakan di Laboratorium Ilmu Komputer, Universitas Negeri Medan. Pengumpulan data, dari penelitian ini, akan dilakukan di Laboratorium Kultur Jaringan Yahdi Medan. Laboratorium ini terletak di Jalan Ambung, Tanah Enam Ratus, Kecamatan Medan Marelán, Kota Medan, Sumatera Utara 20245. Tahap alur penelitian yang akan dilakukan adalah Pengumpulan Data, data yang akan digunakan pada penelitian ini adalah daun selada yang diambil dari Laboratorium Kultur Jaringan Yahdi Medan. Data citra daun selada dikumpulkan sebanyak 330 data dimana 110 data daun selada sehat, 110 data daun selada dengan penyakit bercak daun, dan 110 data daun selada dengan penyakit bercak daun. Selanjutnya *Pre-Processing* Data, Ekstraksi Fitur FLBP, Implementasi CNN, *Training Model* CNN, *Testing Model* CNN, Evaluasi Model CNN dan Integrasi Model dengan *Website*.

4. HASIL DAN PEMBAHASAN

4.1. Pelebelan Data


pertama dalam proses preprocessing data adalah memberikan label pada setiap citra sesuai dengan kategori penyakit daun selada. Setiap citra diamati lalu dipilah sesuai cirinya, sehingga diperoleh total 330 gambar dengan distribusi seimbang, yaitu 110 citra pada masing-masing folder.



Gambar 2. Struktur Pelebelan Data

4.2. Segmentasi Data

Pada penelitian ini, segmentasi digunakan untuk memisahkan bagian daun dari *background* gambar sehingga model hanya mengolah informasi penting dari objek daun. Contoh hasil segmentasi data dapat dilihat pada Gambar 3.



Gambar 3. Hasil Segmentasi

4.3. Penghapusan Latar Belakang (*Removal Background*)

Proses ini bertujuan untuk memisahkan objek utama, yakni daun selada, dari elemen-elemen lain yang tidak diperlukan pada gambar. Contoh hasil penghapusan latar belakang (*removal background*) dapat dilihat pada Gambar 4.




Gambar 4. Hasil Remove Background

4.4. Resizing

Pada tahap *resizing*, seluruh citra diubah ukurannya menjadi 224x224 piksel. Penyeragaman ukuran ini dilakukan untuk meningkatkan efisiensi proses pelatihan sekaligus memastikan hasil yang dihasilkan lebih konsisten dan akurat.

4.5. Analisis RGB

Hasil dari analisis RGB dapat dilihat pada Gambar 5.



Gambar 5. Hasil Analisis RGB Setiap Kelas

Gambar di atas menunjukkan hasil analisis rata-rata dan standar deviasi nilai RGB pada setiap kelas daun selada, yaitu daun selada sehat, daun selada bercak, dan daun selada busuk. Pada grafik rata-rata, terlihat bahwa daun selada sehat memiliki nilai hijau (G) yang paling tinggi dibandingkan kelas lainnya, menandakan dominasi warna hijau segar pada daun normal. Sementara itu, daun selada busuk memiliki nilai rata-rata RGB yang lebih rendah, terutama pada kanal biru (B), yang mengindikasikan warna daun lebih kusam dan cenderung gelap. Adapun pada daun selada bercak, nilai hijau (G) tetap dominan, tetapi lebih rendah dibanding daun sehat, sedangkan nilai merah (R) dan biru (B) relatif sedang. Pada grafik standar deviasi, terlihat bahwa daun sehat dan bercak memiliki variasi warna yang cukup tinggi, terutama pada kanal hijau, yang menggambarkan adanya perbedaan tingkat kecerahan dan ketidakteraturan warna pada permukaan daun. Sebaliknya, daun busuk menunjukkan standar deviasi yang rendah pada semua kanal RGB, menandakan warna yang relatif seragam dan cenderung gelap.

4.6. Pembagian Data

Rincian jumlah dan proporsi pembagian data tersebut dapat dilihat pada Tabel 1.

Tabel 1. Pembagian Data


Pembagian Data	Jumlah
Training	80%
Validation	20%

Dari total 330 data citra, sebanyak 80% atau 264 data citra digunakan sebagai data latih (*training*) untuk membantu model mengenali pola dan fitur pada gambar. Sementara itu, 20% sisanya yaitu 66 data citra, dialokasikan sebagai data uji (*testing*) guna mengevaluasi kinerja model setelah proses pelatihan selesai. Data uji ini juga berperan sebagai data validasi (*validation*) yang dipakai untuk memantau performa model selama pelatihan serta menyesuaikan parameter agar terhindar dari *overfitting*.


4.7. Ekstraksi Fitur *Fuzzy Local Binary Pattern* (FLBP)

Gambar 7 menampilkan rata-rata histogram hasil ekstraksi fitur menggunakan metode *Fuzzy Local Binary Pattern* (FLBP) pada citra daun selada sehat, busuk, dan bercak dengan data pelatihan dan validasi yang digabungkan. Berdasarkan histogram, terlihat bahwa setiap kelas daun memiliki pola distribusi yang berbeda pada beberapa bin. Daun selada busuk menunjukkan frekuensi yang relatif lebih tinggi pada bin awal (sekitar bin ke-1 hingga bin ke-2), sedangkan daun selada bercak dan sehat cenderung memiliki distribusi yang lebih rendah pada area tersebut. Perbedaan paling mencolok terjadi pada bin ke-8, di mana seluruh kelas menunjukkan peningkatan frekuensi, namun dengan nilai yang bervariasi; daun selada sehat memiliki peningkatan

tertinggi dibandingkan kelas lainnya. Hasil dari proses ekstraksi fitur FLBP dapat dilihat pada Gambar 6.



Gambar 6. Hasil Fitur Ekstraksi FLBP



Gambar 7. Rata-rata Histogram FLBP per Kelas

4.8. Implementasi Model CNN

Model arsitektur yang digunakan pada penelitian ini dibangun dengan pendekatan Functional API. Model ini menerima masukan berupa citra berukuran 224×224 piksel dengan tiga saluran warna (RGB), yang didefinisikan melalui lapisan masukan. Proses ekstraksi fitur dimulai dengan lapisan Conv2D pertama yang terdiri atas 32 filter berukuran kernel 3×3 , menghasilkan output berdimensi $(224, 224, 32)$ dengan total 896 parameter. Hasil ekstraksi fitur kemudian direduksi menggunakan MaxPooling2D sehingga dimensi spasial berkurang menjadi $(112, 112, 32)$. Ekstraksi dilanjutkan dengan lapisan Conv2D kedua yang menggunakan 64 filter dan menghasilkan output berdimensi $(112, 112, 64)$, kemudian kembali diperkecil menggunakan pooling menjadi $(56, 56, 64)$. Selanjutnya, tambahkan lapisan Conv2D ketiga dengan 128 filter yang menghasilkan dimensi $(56, 56, 128)$, sebelum kembali direduksi menjadi $(28, 28, 128)$ oleh MaxPooling2D. Untuk memperkaya fitur representasi, digunakan pula lapisan GlobalAveragePooling yang meratakan peta fitur menjadi vektor satu dimensi berdimensi 128.

Selain input utama berupa citra, model ini juga menerima input tambahan berupa fitur numerik hasil ekstraksi FLBP dengan dimensi (9,). Input ini kemudian digabungkan (*concatenate*) dengan hasil ekstraksi fitur dari citra untuk diproses lebih lanjut. Tahap berikutnya adalah lapisan Dense tersembunyi dengan jumlah neuron berturut-turut 128, 64, dan 32. Bagian akhir arsitektur ditutup dengan lapisan output Dense yang memiliki 3 neuron, sesuai dengan jumlah

kelas target pada proses klasifikasi. Lapisan ini menggunakan fungsi aktivasi softmax untuk menghasilkan probabilitas distribusi dari setiap kelas. Secara keseluruhan, model memiliki 122.979 parameter, seluruhnya bersifat dapat dilatih, sehingga bobot jaringan dapat disesuaikan sepenuhnya dengan data pelatihan.

4.9. Training dan Testing Model


Training merupakan proses melatih model agar dapat mengenali pola dalam data dan membuat prediksi yang akurat. Hasil akurasi dapat dilihat pada grafik berikut:



Gambar 8. Grafik Training & Validation Accuracy

Grafik diatas memperlihatkan kinerja model CNN selama proses pelatihan sebanyak 25 epoch dengan menggunakan metrik akurasi pada data pelatihan maupun validasi. Akurasi pada data pelatihan menunjukkan peningkatan yang cukup stabil hingga mencapai nilai mendekati 95%, sedangkan akurasi pada data validasi juga mengalami peningkatan signifikan sejak awal pelatihan dan cenderung stabil di kisaran 90% ke atas setelah epoch ke-10.

Pencapaian akurasi validasi tertinggi diperoleh pada epoch ke-20 dengan nilai sebesar 93.94%, yang ditetapkan sebagai epoch terbaik (best epoch). Kondisi ini menunjukkan bahwa model mampu melakukan pembelajaran dengan baik dan memiliki kemampuan generalisasi yang cukup baik terhadap data validasi.




Gambar 9. Grafik Training & Validation Loss

Selanjutnya, grafik *loss* diatas memperlihatkan bahwa nilai *training loss* dan *validation loss* mengalami penurunan signifikan sejak awal pelatihan dan terus menurun hingga mendekati 0,2 pada akhir

epoch. Pola penurunan *loss* pada data pelatihan dan validasi relatif serupa, dengan selisih yang kecil serta beberapa kali *validation loss* lebih rendah dibandingkan *training loss*. Hal ini menunjukkan bahwa model tidak mengalami *overfitting* dan memiliki performa yang stabil, sehingga dapat disimpulkan bahwa model CNN yang dibangun mampu menghasilkan akurasi yang tinggi serta generalisasi yang baik terhadap data validasi.

4.10. Evaluasi Model

confusion matrix serta nilai rata-rata *precision*, *recall*, *f1-Score*, dan akurasi dapat dilihat berdasarkan hasil pengujian model pada Gambar 10.



Gambar 10. Confusion Matrix

Confusion matrix menunjukkan bahwa model memiliki kinerja yang baik dalam mengklasifikasikan tiga kelas yaitu Daun Selada Bercak, Daun Selada Busuk, dan Daun Selada Sehat. Kelas Daun Selada Sehat dan Daun Selada Busuk diklasifikasikan dengan masing-masing 21 dan 22 prediksi benar serta Daun Selada Sehat dengan 21 prediksi benar. Beberapa kesalahan terjadi, seperti 1 sampel Daun Selada Sehat diklasifikasikan sebagai Daun Selada Bercak serta 3 sampel Daun Selada Bercak diklasifikasikan sebagai Daun Selada Sehat. Berdasarkan hasil perhitungan, akurasi model mencapai 93.94% menunjukkan kinerja model yang baik dan memiliki kemampuan generalisasi yang tinggi terhadap data uji.

Nilai *precision*, *recall*, dan *f1-score* keseluruhan kelas berdasarkan hasil pengujian model dari dapat dilihat pada table berikut:

Tabel 2. Hasil Pengujian Model

Label	Precision	Recall	F1-score
Daun Selada Bercak	0.95	0.86	0.90
Daun Selada Busuk	1.00	1.00	1.00
Daun Selada Sehat	0.88	0.95	0.91
Rata-Rata	0.94	0.94	0.94
Akurasi	93.94%		


Akurasi model FLBP+CNN sebesar 93.94%, hasil akurasi ini menunjukkan bahwa model sudah

cukup baik dalam mengenali pola dari citra daun selada, namun terdapat 6.06% kesalahan prediksi yang masih perlu diperhatikan. Salah satu faktor penyebab yang mungkin adalah model belum memiliki tingkat *robustness* yang memadai terhadap variasi data, karena proses pelatihan dilakukan tanpa penerapan augmentasi citra. Oleh sebab itu, penerapan teknik augmentasi citra seperti rotasi, *zoom*, *flipping*, serta penyesuaian *brightness* direkomendasikan agar model memperoleh data pelatihan yang lebih bervariasi. Dengan demikian, performa model diharapkan meningkat sekaligus meminimalkan potensi kesalahan dalam prediksi.

4.11. Integrasi Model dengan Website

Berikut ini merupakan halaman-halaman yang terdapat pada *website* yang dikembangkan.

4.12. Menu Home




Gambar 1. Menu Home

Halaman Home pada system “Deteksi Penyakit Tanaman Selada” menampilkan fitur utama berupa deteksi penyakit daun menggunakan model CNN yang didalamnya sudah tersedia fitur ekstraksi FLBP yang menghasilkan deteksi secara cepat dan akurat. Alur identifikasi ditampilkan secara sederhana: Mulai Deteksi → Upload Gambar → Proses Analisis → Hasil Deteksi.

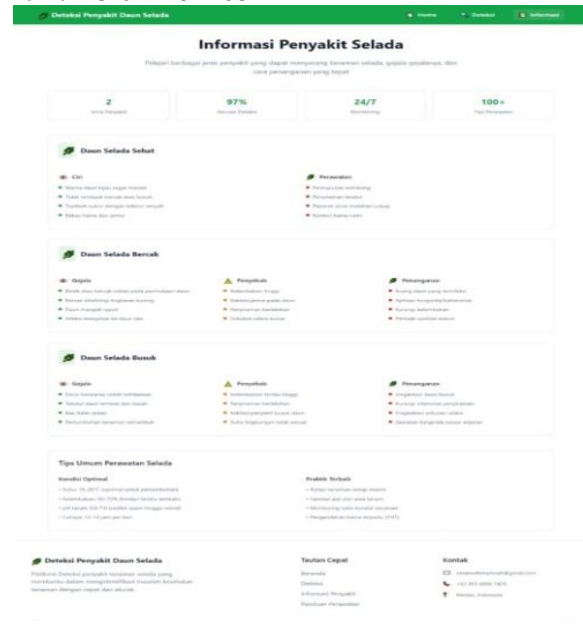
4.13. Menu Deteksi

Halaman Deteksi pada sistem “Deteksi Penyakit Daun Selada”, pengguna dapat mengunggah gambar daun selada dengan format JPG, PNG, atau JPEG (maksimal 10MB) atau pengguna juga dapat mengunggah gambar dengan melakukan *Drag and Drop* pada gambar. Setelah berhasil mengunggah gambar, kemudian klik mulai analisis lali hasil deteksi akan muncul di sisi kanan dengan menampilkan informasi terkait kondisi kesehatan daun.



Gambar 2. Menu Deteksi

4.14. Menu Informasi



Gambar 3. Menu Informasi

Halaman Informasi pada sistem “Deteksi Penyakit Daun Selada” menampilkan panduan lengkap mengenai perawatan tanaman selada hidroponik serta informasi gejala, penyebab, dan penanganan penyakit daun selada seperti daun selada bercak dan daun selada busuk. Selain itu, terdapat informasi ciri-ciri dan tips perawatan daun selada yang optimal.

5. KESIMPULAN DAN SARAN

Model CNN dengan fitur FLBP berhasil mendeteksi kondisi daun selada berdasarkan citra RGB dengan akurasi 93,94%, precision, recall, dan f1-score rata-rata 0,94. Model menunjukkan kemampuan generalisasi yang baik tanpa overfitting, meskipun masih terdapat kesalahan kecil pada kelas

daun bercak. Untuk penelitian selanjutnya, disarankan memperluas dataset, menerapkan *image augmentation*, serta mengeksplorasi *hyperparameter* dan arsitektur pretrained seperti VGG, ResNet, atau EfficientNet guna meningkatkan akurasi dan ketahanan model terhadap variasi kondisi citra.

DAFTAR PUSTAKA

- [1] V. P. Febrianti *et al.*, “Analisis Pengaruh Perkembangan Teknologi Pertanian Di Era Revolusi Industri 4.0 Terhadap Hasil Produksi Padi,” *J. Pengolah. Pangan*, vol. 6, no. 2, pp. 54–60, 2021.
- [2] A. Romalasari and E. Sobari, “Produksi Selada (*Lactuca sativa* L.) Menggunakan Sistem Hidroponik Dengan Perbedaan Sumber Nutrisi,” *Agriprima J. Appl. Agric. Sci.*, vol. 3, no. 1, pp. 36–41, 2019, doi: 10.25047/agriprima.v3i1.158.
- [3] A. S. Setyo, H. Fitriyah, and R. Pramananda, “Sistem Deteksi Tip Burn pada Selada Hidroponik menggunakan Metode Thresholding pada Warna Hue Saturation Value,” *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 7, no. 3, pp. 1511–1517, 2023.
- [4] K. Huda, D. Putra, and F. Yulianto, “Analisis penyakit pada tumbuhan hidroponik selada menggunakan metode forward chaining,” vol. 18, no. 2, pp. 85–99, 2024.
- [5] M. F. A. Maulana, “Identifikasi Penyakit Tanaman Tomat Menggunakan Algoritma Convolutional Neural Network Dan Pendekatan Transfer Learning,” pp. 1–82, 2020.
- [6] M. D. Ansari, S. P. Ghrera, and A. R. Mishra, “Texture Feature Extraction Using Intuitionistic Fuzzy Local Binary Pattern,” *J. Intell. Syst.*, vol. 29, no. 1, pp. 19–34, 2020, doi: 10.1515/jisys-2016-0155.
- [7] F. Felix, S. Faisal, T. F. M. Butarbutar, and P. Sirait, “Implementasi CNN dan SVM untuk Identifikasi Penyakit Tomat via Daun,” *J. SIFO Mikroskil*, vol. 20, no. 2, pp. 117–134, 2019, doi: 10.55601/jsm.v20i2.670.
- [8] A. T. Sari and E. Haryatmi, “Penerapan Convolutional Neural Network Deep Learning dalam Pendeteksian Citra Biji Jagung Kering,” *J. Resti*, vol. 1, no. 10, pp. 265–271, 2021.
- [9] A. Wulansari, B. Medha, and S. Agus, “Pengaruh Tingkat EC dan Populasi Terhadap Produksi Tanaman Kale (*Brassica oleracea* var . *Acephala*) Pada Sistem Hidroponik Rakit Apung,” *Produksi Tanam.*, vol. 7, no. 2, pp. 330–338, 2019.
- [10] M. Safeyah, Z. A. Achmad, and Juwito, “Modul Pelatihan Teknik Hidroponik dan Vertikultur,” *Modul Pengabd. Kpd. Masy. Univ. Pembang. Nas. “Veteran” Jawa Timur*, 2021.