

**KLASIFIKASI PENYAKIT TANAMAN PANGAN BERDASARKAN
CITRA DAUN MENGGUNAKAN *CONVOLUTIONAL*
*NEURAL NETWORK***

SKRIPSI

**Oleh:
DENIS AJI PANGESTU
NIM. 200605110003**



**PROGRAM STUDI TEKNIK INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2024**

**KLASIFIKASI PENYAKIT TANAMAN PANGAN BERDASARKAN
CITRA DAUN MENGGUNAKAN *CONVOLUTIONAL*
*NEURAL NETWORK***

SKRIPSI

Diajukan kepada:
Universitas Islam Negeri Maulana Malik Ibrahim Malang
untuk Memenuhi Salah Satu Persyaratan dalam Memperoleh
Gelar Sarjana Komputer (S.Kom)

Oleh:
DENIS AJI PANGESTU
NIM. 200605110003

**PROGRAM STUDI TEKNIK INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2024**

HALAMAN PERSETUJUAN

**KLASIFIKASI PENYAKIT TANAMAN PANGAN BERDASARKAN
CITRA DAUN MENGGUNAKAN *CONVOLUTIONAL*
*NEURAL NETWORK***

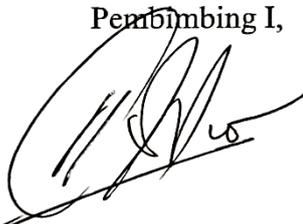
SKRIPSI

Oleh:

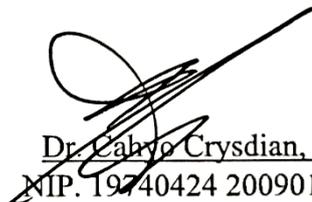
DENIS AJI PANGESTU
NIM. 200605110003

Telah Diperiksa dan Disetujui untuk Diuji:
Tanggal: 5 Juni 2024

Pembimbing I,


Okta Qomaruddin Aziz, M.Kom
NIP. 19911019 201903 1 013

Pembimbing II,


Dr. Cahyo Crysdiyan, MCS
NIP. 19740424 200901 1 008

Mengetahui,
Ketua Program Studi Teknik Informatika
Fakultas Sains dan Teknologi
Universitas Islam Negeri Maulana Malik Ibrahim Malang




Dr. Fachrul Kurniawan, M.MT, IPM
NIP. 19771020 200912 1 001

HALAMAN PENGESAHAN

**KLASIFIKASI PENYAKIT TANAMAN PANGAN BERDASARKAN
CITRA DAUN MENGGUNAKAN *CONVOLUTIONAL*
*NEURAL NETWORK***

SKRIPSI

Oleh:
DENIS AJI PANGESTU
NIM. 200605110003

Telah Dipertahankan di Depan Dewan Penguji Skripsi
dan Dinyatakan Diterima Sebagai Salah Satu Persyaratan
Untuk Memperoleh Gelar Sarjana Komputer (S.Kom)
Tanggal: 13 Juni 2024

Susunan Dewan Penguji

Ketua Penguji : Dr. M. Amin Hariyadi, M.T
NIP. 19670118 200501 1 001

Anggota Penguji I : Ajib Hanani, M.T
NIP. 19840731 202321 1 013

Anggota Penguji II : Okta Qomaruddin Aziz, M.Kom
NIP. 19911019 201903 1 013

Anggota Penguji III : Dr. Cahyo Crysdian, MCS
NIP. 19740424 200901 1 008

()
()
()
()

Mengetahui dan Mengesahkan,
Ketua Program Studi Teknik Informatika
Fakultas Sains dan Teknologi
Universitas Islam Negeri Maulana Malik Ibrahim Malang



Dr. Bachrul Kurniawan, M.MT, IPM
NIP. 19771020 200912 1 001

PERNYATAAN KEASLIAN TULISAN

Saya yang bertanda tangan di bawah ini:

Nama : Denis Aji Pangestu
NIM : 200605110003
Fakultas / Program Studi : Sains dan Teknologi / Teknik Informatika
Judul Skripsi : Klasifikasi Penyakit Tanaman Pangan Berdasarkan Citra Daun Menggunakan *Convolutional Neural Network*

Menyatakan dengan sebenarnya bahwa Skripsi yang saya tulis ini benar-benar merupakan hasil karya saya sendiri, bukan merupakan pengambil alihan data, tulisan, atau pikiran orang lain yang saya akui sebagai hasil tulisan atau pikiran saya sendiri, kecuali dengan mencantumkan sumber cuplikan pada daftar pustaka.

Apabila dikemudian hari terbukti atau dapat dibuktikan skripsi ini merupakan hasil jiplakan, maka saya bersedia menerima sanksi atas perbuatan tersebut.

Malang, 10 Juni 2024
Yang membuat pernyataan,



Denis Aji Pangestu
NIM. 200605110003

MOTTO

“Alhamdulillah for everything I have”

“Remember why you started”

HALAMAN PERSEMBAHAN

Alhamdulillah, segala puji dan syukur saya panjatkan ke hadirat Allah SWT. Shalawat serta salam semoga senantiasa tercurah kepada junjungan kita, Nabi Muhammad SAW. Berkat rahmat dan hidayah-Nya, saya berhasil menyelesaikan skripsi ini.

Skripsi ini saya persembahkan dengan penuh cinta dan rasa hormat kepada kedua orang tua saya, Wajib dan Suratini, yang selalu memberikan dukungan tanpa henti, doa yang tulus, restu, serta bimbingan yang tiada henti. Mereka adalah sumber semangat dan motivasi terbesar saya dalam menyelesaikan tugas akhir ini.

Saya juga ingin mengucapkan terima kasih yang sebesar-besarnya kepada kakak dan adik saya, Levi Rahayu Ning Tyas, Fitria Khofifa Warawansha, dan Ciciliya Sofiana Putri. Dukungan dan semangat yang kalian berikan telah menjadi pendorong utama bagi saya untuk mencapai titik ini.

Tidak lupa, terima kasih saya sampaikan kepada sahabat-sahabat saya yang setia mendampingi dan saling membantu selama masa perkuliahan. Kebersamaan dan kerjasama kita adalah anugerah yang luar biasa, dan saya bersyukur memiliki kalian sebagai teman seperjuangan.

KATA PENGANTAR

Assalamualaikum, Wr. Wb.

Alhamdulillah, Puji syukur kehadiran Allah SWT yang tak terhingga atas petunjuk-Nya yang tiada henti, karunia-Nya yang melimpah, serta pertolongan-Nya yang senantiasa menyertai setiap langkah penelitian ini. Saya menyampaikan segala puji bagi-Nya atas rahmat yang telah menggerakkan hati dan pikiran saya untuk meniti jalan keilmuan dalam konteks penelitian ini. Sholawat dan salam semoga selalu tetap tercurahkan kepada baginda Nabi Muhammad SAW yang menjadi suri tauladan yang agung bagi umat manusia. Penulis mengucapkan terima kasih kepada pihak-pihak yang membantu proses penulisan Skripsi ini. Ucapan terima kasih ini, penulis sampaikan kepada:

1. Prof. Dr. M. Zainuddin, M.A, selaku rektor UIN Maulana Malik Ibrahim Malang, yang telah banyak memberikan pengetahuan dan pengalaman yang berharga.
2. Prof. Dr. Sri Harini, M.Si selaku Dekan Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang
3. Dr. Fachrul Kurniawan, M.MT, IPM, selaku Ketua Program Studi Teknik Informatika Universitas Islam Negeri Maulana Malik Ibrahim Malang.
4. Okta Qomaruddin Aziz, M.Kom, selaku dosen pembimbing I yang sabar untuk memberikan bimbingan, memberikan nasehat, saran dan memberikan pengarahan sehingga penulis dapat menyelesaikan skripsi ini.

5. Dr. Cahyo Crysdiyan, MCS, selaku pembimbing II yang sabar memberikan bimbingan, pengarahan dan nasehat sehingga penulis dapat menyelesaikan skripsi ini.
6. Dr. M. Amin Hariyadi, M.T dan Ajib Hanani, M.T selaku penguji I dan II yang telah memberikan saran dan kritik yang telah berikan selama proses pengujian skripsi ini.
7. Seluruh dosen Program Studi Teknik Informatika Fakultas Sains dan Teknologi UIN Maulana Malik Ibrahim Malang yang telah memberikan ilmu, pengetahuan, pengalaman dan wawasan yang banyak bagi penulis.
8. Orang tua tercinta yaitu Ayahanda saya Wajib, Ibunda saya Suratini, kakak tersayang, Levi Rahayu Ning Tyas dan adikku tersayang, Fitria Khofifa Warawansha dan Cicilya Sofiana Putri yang tiada hentinya memberikan doa, motivasi, semangat dan selalu memberikan dukungan sehingga bisa terselesaikan penelitian skripsi ini.
9. Sahabat seperjuangan saya dari awal perkuliahan hingga saat ini, yaitu Akmal, Candra, Enggar, Ridho, Rizal dan Taufiq yang senantiasa selalu menemani dan memberikan semangat hingga dapat menempuh gelar sarjana bersama.
10. Teman dekat sekaligus mentor saya dalam menempuh masa Sarjana yaitu Galan dan Teman-teman angkatan 2020 “INTEGER” yang sudah menemani dalam menempuh masa perkuliahan.
11. Semua pihak yang telah memberikan bantuan baik dukungan nyata ataupun semangat serta pihak-pihak yang tidak dapat penulis sebutkan satu persatu.

12. Terimakasih untuk diri saya sendiri yang selalu sabar, selalu bertahan dan semangat dengan penuh perjuangan ketika hampir berada pada posisi terendah, sehingga dapat menyelesaikan skripsi ini dengan baik.

Dengan penuh kesadaran, penulis menyadari bahwa dalam penyusunan skripsi ini masih terdapat banyak kekurangan. Oleh sebab itu, penulis berharap kritik serta saran untuk penelitian kedepannya. Penulis berharap semoga skripsi ini dapat memberikan manfaat kepada pembaca khususnya bagi diri penulis. Semoga Allah SWT melimpahkan keberkahan atas skripsi penulis dan senantiasa selalu diberikan petunjuk dan rahmat-Nya serta segala bentuk kebaikan dalam menarungi kehidupan kita di dunia.

Wassalamualaikum Warahmatullahi Wabarakatuh

Malang, 10 Juni 2024

Penulis

DAFTAR ISI

HALAMAN JUDUL	i
HALAMAN PENGAJUAN	ii
HALAMAN PERSETUJUAN	iii
HALAMAN PENGESAHAN	iv
PERNYATAAN KEASLIAN TULISAN	v
MOTTO	vi
HALAMAN PERSEMBAHAN	vii
KATA PENGANTAR.....	viii
DAFTAR ISI.....	xi
DAFTAR GAMBAR.....	xiii
DAFTAR TABEL	xv
ABSTRAK	xiii
ABSTRACT.....	xiv
مستخلص البحث.....	xv
BAB I PENDAHULUAN.....	1
1.1 Latar Belakang	1
1.2 Identifikasi Masalah	5
1.3 Tujuan Penelitian	6
1.4 Batasan Masalah.....	6
1.5 Manfaat Penelitian	6
BAB II STUDI PUSTAKA	7
2.1 Permasalahan Sektor Industri Pertanian.....	7
2.2 Klasifikasi Penyakit Tanaman.....	9
2.3 <i>Convolutional Neural Network</i>	13
BAB III DESAIN DAN IMPLEMENTASI	17
3.1 Desain Penelitian.....	17
3.2 Pengumpulan Data	18
3.3 Desain Sistem.....	20
3.3.1 <i>Input Image</i>	21
3.3.2 <i>Image Preprocessing</i>	21
3.4 Implementasi Metode.....	23
3.4.1 <i>Input Layer</i>	24
3.4.2 <i>Convolution Layer</i>	25
3.4.3 <i>Max Pooling Layer</i>	26
3.4.4 <i>Fully Connected Layer</i>	26
3.5 Proses <i>Training</i>	30
BAB IV HASIL DAN PEMBAHASAN	34
4.1 Langkah-Langkah Uji Coba	34
4.1.1 Data Pengujian	34
4.1.2 Skenario Pengujian.....	35
4.2 Hasil Uji Coba.....	38
4.2.1 Skenario Uji 1	38
4.2.2 Skenario Uji 2	40

4.2.3 Skenario Uji 3	43
4.2.4 Skenario Uji 4	45
4.2.5 Skenario Uji 5	54
4.2.6 Skenario Uji 6	63
4.3 Pembahasan.....	72
BAB V KESIMPULAN DAN SARAN	85
5.1 Kesimpulan	85
5.2 Saran.....	86
DAFTAR PUSTAKA	

DAFTAR GAMBAR

Gambar 2.1 Segitiga Penyakit Tanaman	8
Gambar 2.2 Gambaran Bentuk Arsitektur CNN	14
Gambar 2.3 Fungsi aktivasi ReLu	16
Gambar 2.4 Fungsi Aktivasi <i>Softmax</i>	16
Gambar 3.1 Tahapan Penelitian.	17
Gambar 3.2 Desain Sistem	20
Gambar 3.3 Proses Pengolahan Data	20
Gambar 3.4 Rotation	22
Gambar 3.5 Zoom	22
Gambar 3.6 Vertical Flip	23
Gambar 3.7 <i>Horizontal Flip</i>	23
Gambar 3.8 Arsitektur CNN LeNet-5	24
Gambar 4.1 Contoh Single dan Multi Stage Classification	36
Gambar 4.2 Grafik Cost Proses Training Model 1	38
Gambar 4.3 Hasil Prediksi Data dengan Rasio 70:30 pada 12 Kelas	39
Gambar 4.4 Visual Performa Skenario Uji Coba 1 Pembagian Data 70:30	40
Gambar 4.5 Grafik Cost Proses Training Model 2	41
Gambar 4. 6 Hasil Prediksi Data dengan Rasio 80:20 pada 12 Kelas	41
Gambar 4. 7 Visual Performa Skenario Uji Coba 2 Pembagian Data 80:20	42
Gambar 4.8 Grafik Cost Proses Training Model 3	43
Gambar 4.9 Hasil Prediksi Data dengan Rasio 90:10 pada 12 Kelas	43
Gambar 4.10 Visual Performa Skenario Uji Coba 3 Pembagian Data 90:10	45
Gambar 4.11 Grafik Cost Proses Training Model 4 Stage 1	45
Gambar 4.12 Hasil Prediksi Data dengan Rasio 70:30 pada 4 Kelas	46
Gambar 4.13 Grafik Cost Proses Training Model 4 Stage 2 Penyakit Tanaman Jagung	47
Gambar 4.14 Hasil Prediksi Data dengan Rasio 70:30 pada 3 Kelas Penyakit Tanaman Jagung	47
Gambar 4.15 Grafik Cost Proses Training Model 4 Stage 2 Penyakit Tanaman Kentang	48
Gambar 4.16 Hasil Prediksi Data dengan Rasio 70:30 pada 3 Kelas Penyakit Tanaman Kentang	49
Gambar 4.17 Grafik Cost Proses Training Model 4 Stage 2 Penyakit Tanaman Padi	50
Gambar 4.18 Hasil Prediksi Data dengan Rasio 70:30 pada 3 Kelas Penyakit Tanaman Padi	50
Gambar 4.19 Grafik Cost Proses Training Model 4 Stage 2 Penyakit Tanaman Tomat	51
Gambar 4.20 Hasil Prediksi Data dengan Rasio 70:30 pada 3 Kelas Penyakit Tanaman Tomat	52

Gambar 4.21 Visual Performa Skenario Uji Coba 4 Pembagian Data 70:30	54
Gambar 4.22 Grafik Cost Proses Training Model 5 Stage 1	54
Gambar 4.23 Hasil Prediksi Data dengan Rasio 80:20 pada 4 Kelas	55
Gambar 4.24 Grafik Cost Proses Training Model 5 Stage 2 Penyakit Tanaman Jagung	56
Gambar 4.25 Hasil Prediksi Data dengan Rasio 80:20 pada 3 Kelas Penyakit Tanaman Jagung	56
Gambar 4.26 Grafik Cost Proses Training Model 5 Stage 2 Penyakit Tanaman Kentang	57
Gambar 4.27 Hasil Prediksi Data dengan Rasio 80:20 pada 3 Kelas Penyakit Tanaman Kentang	58
Gambar 4.28 Grafik Cost Proses Training Model 5 Stage 2 Penyakit Tanaman Padi	59
Gambar 4.29 Hasil Prediksi Data dengan Rasio 80:20 pada 3 Kelas Penyakit Tanaman Padi	59
Gambar 4.30 Grafik Cost Proses Training Model 5 Stage 2 Penyakit Tanaman Tomat	60
Gambar 4.31 Hasil Prediksi Data dengan Rasio 80:20 pada 3 Kelas Penyakit Tanaman Tomat	61
Gambar 4.32 Visual Performa <i>Skenario</i> Uji Coba 5 Pembagian Data 80:20	63
Gambar 4.33 Grafik Cost Proses Training Model 6 Stage 1	63
Gambar 4.34 Hasil Prediksi Data dengan Rasio 90:10 pada 4 Kelas	64
Gambar 4.35 Grafik Cost Proses Training Model 6 Stage 2 Penyakit Tanaman Jagung	65
Gambar 4.36 Hasil Prediksi Data dengan Rasio 90:0 pada 3 Kelas Penyakit Tanaman Jagung	65
Gambar 4.37 Grafik Cost Proses Training Model 6 Stage 2 Penyakit Tanaman Kentang	66
Gambar 4.38 Hasil Prediksi Data dengan Rasio 90:10 pada 3 Kelas Penyakit Tanaman Kentang	67
Gambar 4.39 Grafik Cost Proses Training Model 6 Stage 2 Penyakit Tanaman Padi	68
Gambar 4.40 Hasil Prediksi Data dengan Rasio 90:10 pada 3 Kelas Penyakit Tanaman Padi	68
Gambar 4.41 Grafik Cost Proses Training Model 6 Stage 2 Penyakit Tanaman Tomat	69
Gambar 4.42 Hasil Prediksi Data dengan Rasio 90:10 pada 3 Kelas Penyakit Tanaman Tomat	70
Gambar 4.43 Visual Performa <i>Skenario</i> Uji Coba 6 Pembagian Data 90:10	72
Gambar 4.44 Perbandingan Skenario Uji Per Rasio Data	78
Gambar 4.45 Perbandingan Skenario Uji Per Stage	79

DAFTAR TABEL

Tabel 3.1 Beberapa contoh data penyakit tanaman.....	18
Tabel 4.1 Dataset Penelitian.....	34
Tabel 4.2 Skenario Pengujian	36
Tabel 4.3 Score Precision, Recall, F1-Score pada 12 Kelas Skenario Uji 1.....	39
Tabel 4.4 Score Precision, Recall, F1-Score pada 12 Kelas Skenario Uji 2.....	42
Tabel 4.5 Score Precision, Recall, F1-Score pada 12 Kelas Skenario Uji 3.....	44
Tabel 4.6 Score Precision, Recall, F1-Score pada 4 Kelas Jenis Tanaman	46
Tabel 4.7 Score Precision, Recall, F1-Score pada 3 Kelas Penyakit Tanaman Jagung	48
Tabel 4.8 Score Precision, Recall, F1-Score pada 3 Kelas Penyakit Tanaman Kentang.....	49
Tabel 4.9 Score Precision, Recall, F1-Score pada 3 Kelas Penyakit Tanaman Padi	51
Tabel 4.10 Score Precision, Recall, F1-Score pada 3 Kelas Penyakit Tanaman Tomat	52
Tabel 4.11 Performa Hasil Uji dengan Metode Multi stage classification rasio data 70:30	53
Tabel 4.12 Score Precision, Recall, F1-Score pada 4 Kelas Jenis Tanaman	55
Tabel 4.13 Score Precision, Recall, F1-Score pada 3 Kelas Penyakit Tanaman Jagung.....	57
Tabel 4.14 Score Precision, Recall, F1-Score pada 3 Kelas Penyakit Tanaman Kentang	58
Tabel 4.15 Score Precision, Recall, F1-Score pada 3 Kelas Penyakit Tanaman Padi.....	60
Tabel 4.16 Score Precision, Recall, F1-Score pada 3 Kelas Penyakit Tanaman Tomat	61
Tabel 4.17 Performa Hasil Uji dengan Metode Multi stage classification rasio data 80:20	62
Tabel 4.18 Score Precision, Recall, F1-Score pada 4 Kelas Jenis Tanaman	64
Tabel 4.19 Score Precision, Recall, F1-Score pada 3 Kelas Penyakit Tanaman Jagung.....	66
Tabel 4.20 Score Precision, Recall, F1-Score pada 3 Kelas Penyakit Tanaman Kentang	67
Tabel 4.21 Score Precision, Recall, F1-Score pada 3 Kelas Penyakit Tanaman Padi.....	69
Tabel 4.22 Score Precision, Recall, F1-Score pada 3 Kelas Penyakit Tanaman Tomat	70
Tabel 4.23 Performa Hasil Uji dengan Metode Multi stage classification rasio data 90:10	71

Tabel 4.24 Performa kelas a) Jagung, b) Kentang, c) Padi, dan d) Tomat skenario uji pertama	73
Tabel 4.25 Performa kelas a) Jagung, b) Kentang, c) Padi, dan d) Tomat skenario uji kedua.....	73
Tabel 4.26 Performa kelas a) Jagung, b) Kentang, c) Padi, dan d) Tomat skenario uji ketiga	74
Tabel 4.27 Performa kelas a) Jagung, b) Kentang, c) Padi, dan d) Tomat skenario uji keempat.....	75
Tabel 4.28 Performa kelas a) Jagung, b) Kentang, c) Padi, dan d) Tomat skenario uji kelima	76
Tabel 4.29 Performa kelas a) Jagung, b) Kentang, c) Padi, dan d) Tomat skenario uji keenam.....	77

ABSTRAK

Pangestu, Denis Aji. 2024. **Klasifikasi Penyakit Tanaman Pangan Berdasarkan Citra Daun Menggunakan Convolutional Neural Network**. Skripsi. Program Studi Teknik Informatika Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang. Pembimbing: (I) Okta Qomaruddin Aziz, M.Kom. (II) Dr. Cahyo Crys dian, M.Cs

Kata kunci: *Convolutional Neural Network, Klasifikasi, Penyakit Tanaman*

Pertanian merupakan sektor vital dalam perekonomian yang menyediakan pangan, bahan mentah, dan lapangan pekerjaan. Namun, di Indonesia, sektor ini mengalami tantangan besar, termasuk rendahnya minat generasi muda untuk terjun langsung serta masalah penyakit tanaman. Untuk melakukan identifikasi terhadap penyakit tanaman, dibutuhkan ahli yang paham dalam bidang tersebut, akan tetapi membutuhkan waktu dan biaya yang cukup banyak dalam prosesnya. Penelitian ini bertujuan mengembangkan model klasifikasi penyakit tanaman menggunakan metode *Convolutional Neural Network* (CNN) untuk membantu petani dalam mengidentifikasi penyakit tanaman padi, jagung, tomat, dan kentang berdasarkan citra daun. Skenario uji pada penelitian ini dilakukan dengan rasio pembagian data 70:30, 80:20, dan 90:10 serta menggunakan metode *single stage classification* dan *multi stage classification*. Hasil terbaik diperoleh dari skenario pembagian data 80:20 dengan *single stage classification* yang mencapai rata-rata *accuracy* 80%, *precision* 80%, *recall* 81%, dan *F1-Score* 79%. Studi ini menunjukkan bahwa metode CNN efektif dalam klasifikasi penyakit tanaman, dengan performa terbaik diperoleh pada rasio data 80:20 dan *single stage classification*. Penelitian ini diharapkan dapat menjadi alat bantu bagi petani baru untuk mengenali dan menangani penyakit tanaman dengan lebih cepat dan tepat, serta mendorong inovasi dalam industri pertanian. Implementasi CNN dalam klasifikasi penyakit tanaman menunjukkan potensi besar dalam meningkatkan efisiensi dan akurasi deteksi penyakit, yang pada akhirnya dapat mendukung keberlanjutan dan perkembangan sektor pertanian.

ABSTRACT

Pangestu, Denis Aji. 2024. **Classification of Crop Disease Based on Leaf Images Using Convolutional Neural Network**. Undergraduate Thesis. Informatics Engineering Study Program, Faculty of Science and Technology, Universitas Islam Negeri Maulana Malik Ibrahim Malang. Advisors: (I) Okta Qomaruddin Aziz, M.Kom. (II) Dr. Cahyo Crysdiyan, M.Cs

Agriculture is a vital sector in the economy, providing food, raw materials, and employment. However, in Indonesia, this sector faces significant challenges, including the low interest of the younger generation in direct involvement and plant disease issues. Identifying plant diseases requires experts in the field, but this process is time-consuming and *costly*. This study aims to develop a plant disease classification model using the Convolutional Neural Network (CNN) method to assist farmers in identifying diseases in rice, corn, tomato, and potato plants based on leaf images. The experimental scenario in this research was conducted with data split ratios ratios of 70:30, 80:20, and 90:10, and utilizes single stage classification and multi stage classification methods. The best results were obtained from the 80:20 data split scenario with single stage classification, achieving average accuracy, *precision*, *recall*, and *F1-Score* of 80%, 80%, 81%, and 79%, respectively. This study demonstrates that the CNN method is effective in plant disease classification, with the best performance achieved with an 80:20 data split and single stage classification. This research is expected to serve as a tool for new farmers to recognize and address plant diseases more quickly and accurately, and to encourage innovation in the agricultural industry. The implementation of CNN in plant disease classification shows great potential in increasing the efficiency and accuracy of disease detection, ultimately supporting the sustainability and development of the agricultural sector.

Keywords: *Classification, Convolutional Neural Network, Plant Disease*

مستخلص البحث

بانجستو، دينيس آجي. 2024. تصنيف أمراض النباتات الغذائية بناء على صور الأوراق باستخدام الشبكة العصبية التلافيفية. البحث الجامعي. قسم الهندسة المعلوماتية، كلية العلوم والتكنولوجيا بجامعة مولانا مالك إبراهيم الإسلامية الحكومية مالانج. المشرف الأول: أوكنا قمر الدين عزيز، الماجستير. المشرف الثاني: د. جهيو كريسديان، الماجستير.

الكلمات الرئيسية: أمراض النبات، الشبكة العصبية التلافيفية، التصنيف.

الزراعة قطاع حيوي في الاقتصاد يوفر الغذاء والمواد الخام والوظائف. ومع ذلك، في إندونيسيا، يواجه هذا القطاع تحديات كبيرة، بما في ذلك انخفاض اهتمام جيل الشباب بالقفز مباشرة إلى الصناعة ومشكلة الأمراض النباتية. لتحديد الأمراض النباتية، هناك حاجة إلى خبراء يفهمون هذا المجال، لكن الأمر يستغرق الكثير من الوقت والمال في هذه العملية. هدف هذا البحث إلى تطوير نموذج لتصنيف أمراض النبات باستخدام طريقة الشبكة العصبية التلافيفية (CNN) لمساعدة المزارعين في تحديد أمراض محاصيل الأرز والذرة والبطاطس والبطاطس بناء على صور الأوراق. تم تنفيذ سيناريو الاختبار في هذا البحث بنسب مشاركة بيانات 20:80 و 30:70 و 10:90 وباستخدام تصنيف أحادي المرحلة وطريقة تصنيف متعدد المراحل. تم الحصول على أفضل النتائج من سيناريو مشاركة البيانات 20:80 مع تصنيف المرحلة الواحدة الذي حقق متوسط دقة وثبات واستدعاء ودرجة ف1 بنسبة 80% و 81% و 79% على التوالي. أظهر هذا البحث أن طريقة CNN فعالة في تصنيف أمراض النبات، مع أفضل أداء تم الحصول عليه عند نسبة البيانات 20:80 وتصنيف مرحلة واحدة. من المتوقع أن يكون هذا البحث أداة للمزارعين للتعرف على أمراض النبات وإدارتها بسرعة ودقة أكبر، فضلا عن تشجيع عدم الالتزام في الصناعة الزراعية. أظهر تنفيذ CNN في تصنيف الأمراض النباتية إمكانات كبيرة في تحسين كفاءة ودقة الكشف عن الأمراض، والتي يمكن أن تدعم في نهاية المطاف استدامة وتطوير القطاع الزراعي.

BAB I

PENDAHULUAN

1.1 Latar Belakang

Pertanian merupakan salah satu industri yang menyediakan berbagai macam jenis makanan, obat, bahan mentah dan lain sebagainya. Pertanian sebagai sektor industri, menjadi tulang punggung ekonomi bagi kehidupan manusia untuk memenuhi kebutuhan pangan serta dapat membuka peluang pekerjaan. (Chellapandi et al., 2021). Di Indonesia, saat ini pertanian dikatakan sebagai pekerjaan kerah biru yang memperburuk kesenjangan yang lebih jauh antara kebutuhan dan sumber daya. Iklim sosial politik telah membuat pekerjaan kerah putih lebih menarik dan ekonomis bagi sebagian besar orang, karena memiliki peluang yang lebih baik dan gaji yang lebih tinggi. Sehingga banyak orang yang memilih untuk tidak memasuki bidang pertanian (Sholihati et al., 2020). Menurut data yang ditunjukkan DPR RI yang membahas tentang Anggaran Pendapatan dan Belanja Negara (APBN) Indonesia, menunjukkan penurunan jumlah usia produktif sektor pertanian dikarenakan kurangnya dukungan pemerintah yang dapat menyebabkan sektor pertanian indonesia semakin terpuruk pada 10 tahun yang akan datang.

Selain berkurangnya minat kerja pada bidang pertanian, tingkat produktivitas tanaman pangan juga dipengaruhi faktor penghambat lain, salah satunya yaitu penyakit tanaman. Menurut Badan Pusat Statistik (BPS) pada tahun 2020 produksi beras mengalami penurunan sebanyak 39.000 ton, hal ini disebabkan baik karena faktor cuaca, sumber daya, hama dan penyakit tanaman. Usaha pertanian sejak

terimplementasikannya revolusi industri selalu tidak terlepas dari gangguan organisme yang tidak diharapkan yang menyebabkan tanaman terjangkit penyakit. Serangan penyakit tanaman disebabkan oleh patogen seperti virus, bakteri, jamur, atau nematoda yang menyerang tanaman dan mengganggu pertumbuhan serta produktivitasnya (Suganda et al., 2018).

Mencari cara untuk mengenali dan mencari cara untuk mengatasi sebuah penyakit yang menjangkit tanaman ini merupakan salah satu cara usaha untuk bertanggung jawab atas apa yang telah Allah *Subhanahu wa ta'ala* berikan kepada manusia, hal ini tercantum dalam Surat An-Nahl ayat 11:

يُثْبِتُ لَكُمْ بِهِ الزَّرْعَ وَالزَّيْتُونَ وَالتَّخَيْلَ وَالْأَعْنَابَ وَمِنْ كُلِّ الثَّمَرَاتِ إِنَّ فِي ذَلِكَ لَآيَةً لِّقَوْمٍ يَتَفَكَّرُونَ

"Dengan (air hujan) itu Dia menumbuhkan untukmu tumbuh-tumbuhan, zaitun, kurma, anggur, dan segala macam buah-buahan. Sesungguhnya pada yang demikian itu benar-benar terdapat tanda (kebesaran Allah) bagi orang yang berpikir." (QS. An-Nahl : 11).

Dalam penjelasan tafsir Ibnu Katsir, dijelaskan jika segala sesuatu atas kebutuhan manusia telah dicukupkan mulai dari disuburkannya tumbuhan melalui air hujan dari langit dan sebagian digunakan sebagai air minum, serta tempat bagi kalian menggembalakan ternak. Hal tersebut sebagai tanda atas kekuasaan Allah SWT terutama bagi kaum yang memikirkan petunjuk yang ada bahwa Allah SWT adalah Tuhan Yang Maha Esa. Dengan landasan tersebut, sebagai manusia yang telah dipenuhi kebutuhannya oleh Allah *Subhanahu wa Ta'ala* diperlukan sebuah tanggung jawab untuk terus belajar serta bertanggung jawab atas dirinya sendiri serta lingkungan sebagai bentuk rasa syukur atas segala nikmat yang telah diberikan-Nya (Abdul Ghoffar E.M, 2003).

Identifikasi penyakit tanaman merupakan salah satu tindakan tanggung jawab yang dapat dilakukan manusia untuk mencari informasi terkait penyakit yang menyerang tanaman. Selain itu cara untuk mengatasinya juga perlu diperhatikan, karena jika melakukan penanganan yang salah maka dapat menyebabkan kerusakan pada lingkungan atau alam yang ditempati. Selain itu, dengan banyaknya jenis penyakit tanaman serta penanganan yang berbeda pada setiap penyakitnya, maka diperlukan adanya seorang ahli dalam mengidentifikasi penyakit tanaman (Ulfah Nur Oktaviana et al., 2021). Identifikasi yang dilakukan oleh para ahli atau petani berpengalaman masih menjadi pendekatan utama dalam mendeteksi penyakit tanaman di berbagai tempat. Namun identifikasi secara manual dalam pertanian akan memakan waktu serta biaya yang tinggi untuk konsultasi kepada para ahli. Secara realistis identifikasi otomatis penyakit tanaman sangatlah penting untuk dapat mendeteksi gejala penyakit tanaman segera setelah muncul pada daun dan dapat dilakukan dengan menggunakan suatu teknik, yaitu teknik klasifikasi citra (Singh & Misra, 2017). Klasifikasi citra merupakan suatu teknik yang digunakan untuk mengatur citra ke dalam berbagai kategori kedalam satu atau lebih kategori yang telah ditentukan sebelumnya (Ambarwari et al., 2023). Oleh karena itu, penerapan ekstraksi fitur dan *machine learning* sangat berguna untuk mengklasifikasikan penyakit tanaman secara otomatis walaupun tanpa adanya ahli secara langsung.

Dalam upaya untuk membantu proses identifikasi penyakit tanaman ini, terdapat banyak metode yang dapat digunakan untuk melakukan klasifikasi citra, salah satunya *Convolutional Neural Network* (CNN). Penggunaan metode

Convolutional Neural Network (CNN) sebagai pengolah citra digital untuk mengklasifikasi penyakit tanaman merupakan sebuah solusi yang menjanjikan. Dengan memanfaatkan *image processing* dari *dataset* yang digunakan untuk pengenalan fitur dan klasifikasi objek digital, *Convolutional Neural Network* (CNN) memiliki potensi untuk klasifikasi dengan banyak data secara cepat serta akurat. (Anggiratih et al., 2021). Karena dasar implementasinya menggunakan *cortex* manusia dan mampu untuk mempelajari objek secara kompleks, *Convolutional Neural Network* (CNN) menjadi salah satu metode yang sering digunakan dalam pengolahan citra objek secara kompleks. *Convolutional Neural Network* (CNN) terdiri dari 3 jenis *layer* yaitu *convolution layer*, *pooling layer*, dan *fully-connected layer* (Guo & Wang, 2022).

Penelitian ini akan menggunakan metode *Convolutional Neural Network* (CNN) untuk proses klasifikasi. Beberapa penelitian telah menerapkan metode ini untuk menyelesaikan masalah klasifikasi berbasis citra, seperti penelitian yang dilakukan oleh Pujiati & Rochmawati, (2022) terkait penerapan metode *convolutional Neural Network* (CNN) pada sumber bahan obat tradisional dan obat alam yang didapat dari tanaman herbal, yang bertujuan untuk melakukan identifikasi citra daun tanaman herbal. Sebagai data *input*, penelitian ini memiliki 33 kelas dengan total data keseluruhan yang digunakan yaitu 21.450 citra tumbuhan herbal, dimana data tersebut dibagi menjadi 16.500 untuk *training*, 3300 untuk validasi, dan 1650 untuk *testing*. Pada proses *training* dan validasi dilakukan sebanyak 150 *epoch* yang mendapatkan nilai akurasi pada proses *testing* sebesar 84% dengan mengidentifikasi 1382 citra daun tanaman herbal secara benar dari

total 1650 citra yang ada. Penelitian menunjukkan bahwa metode *Convolutional Neural Network* yang diusulkan memiliki nilai akurasi yang baik.

Wijaya et al., (2020) juga melakukan penelitian dengan menggunakan metode *Convolutional Neural Network* (CNN) untuk klasifikasi jenis tanaman. Pada penelitian ini digunakan “*Supervised Learning*” untuk membantu mengenali jenis tanaman berdasarkan daunnya. *Dataset* yang digunakan terdiri dari 5 kelas daun dan berjumlah 375 gambar daun. Pengujian yang dilakukan pada penelitian menggunakan 375 daun, 250 citra sebagai data *training*, dan 125 citra sebagai data *test*. Hasil dari pengujian penelitian ini menunjukkan tingkat akurasi sebesar 76%.

Dengan dasar masalah yang telah diuraikan, penelitian ini memiliki tujuan dalam mengembangkan model *machine learning* dalam klasifikasi penyakit tanaman pangan berdasarkan citra daun yang dapat mendorong inovasi serta membuka peluang baru dalam industri pertanian untuk terus berkembang dan berubah secara dinamis (Kaya et al., 2019). Hal ini diharapkan dapat membantu petani dalam mengidentifikasi sekaligus mengenali jenis penyakit tanaman dengan lebih efektif, sehingga dapat membantu sektor industri pertanian untuk lebih berkembang.

1.2 Identifikasi Masalah

Bagaimana performa metode *Convolutional Neural Network* (CNN) dalam mengklasifikasikan jenis penyakit tanaman berdasarkan citra daun padi, tomat, kentang dan jagung?

1.3 Tujuan Penelitian

Tujuan dari penelitian ini adalah mengukur performa dari metode *Convolutional Neural Network* (CNN) dalam klasifikasi penyakit tanaman padi, jagung, tomat dan kentang berdasarkan citra daun.

1.4 Batasan Masalah

Adapun batasan-batasan yang ditetapkan pada penelitian ini digunakan untuk memfokuskan proses eksperimen, batasan-batasan tersebut diantaranya adalah:

1. *Dataset* yang akan digunakan berformat JPG yang didapat dari Kaggle dengan judul “*New Plant Disease Dataset*” dan “*Rice Leaf Disease Image Sample*” yang telah dipublikasikan pada repositori terbuka dan dapat diakses pada website mendeley data.
2. Pada penelitian ini hanya akan fokus pada pengklasifikasian penyakit tanaman berdasarkan citra daun pada tanaman padi, jagung, tomat dan kentang dengan total 12 jumlah kelas.

Performa pada penelitian ini akan diukur berdasarkan *confusion matrix* dengan perhitungan nilai *accuracy*, *precision*, *recall*, dan *F1-Score*.

1.5 Manfaat Penelitian

Penelitian ini diharapkan dapat digunakan sebagai alat bantu untuk klasifikasi penyakit tanaman pangan sebagai sarana informasi yang dapat membantu petani baru dalam mengidentifikasi jenis penyakit tanaman untuk mengurangi kesalahan dalam mengenali penyakit tanaman sehingga dapat memberikan penanganan lebih cepat dan tepat.

BAB II

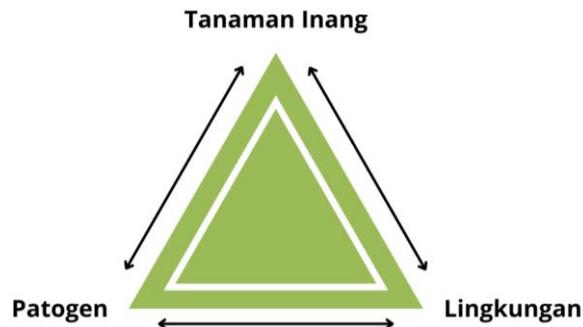
STUDI PUSTAKA

2.1 Permasalahan Sektor Industri Pertanian

Sektor industri pertanian menjadi salah satu penyedia bahan makanan pokok bagi masyarakat. Meningkatnya jumlah penduduk mengartikan konsumsi akan kebutuhan pangan juga semakin meningkat. Peningkatan kebutuhan pangan ini dinyatakan oleh Badan Pusat Statistik Indonesia (BPS) bahwa nilai konsumsi pangan pada tahun 2022 penduduk Indonesia meningkat 2,29% yaitu sebesar 32,07 juta ton dibandingkan tahun 2021 (Sheila et al., 2020). Dengan meningkatnya tingkat konsumsi masyarakat terhadap kebutuhan pangan, hal ini tidak dapat diimbangi oleh tingkat produksi dari petani. Banyak kendala yang dialami oleh petani salah satunya dengan adanya penyakit tanaman (Nuryanto, 2018).

Penyakit tanaman merupakan salah satu masalah penyebab menurunnya tingkat produksi hasil panen. Keterbatasan dalam penyuluhan pertanian mengenai hama dan penyakit tanaman dinilai berdampak pada kurangnya informasi yang diperoleh oleh para petani mengenai penyakit tanaman. Kurangnya informasi tersebut berakibat juga pada penanganan maupun pengendalian yang kurang tepat pada saat tanaman terkena penyakit (Ulfah Nur Oktaviana et al., 2021). Saat ini hanya terdapat 73 ribu petugas penyuluh pertanian yang turun ke lapangan dari 82 ribu desa yang berpotensi dapat dikembangkan wilayah pertaniannya. Hal ini mengakibatkan petani kita kehilangannya hasil panen diperkirakan mencapai

200.000 – 300.000 ton per tahun akibat serangan hama dan penyakit tanaman (Sahro Winanto et al., 2023).



Gambar 2.1 Segitiga Penyakit Tanaman

Gambar 2.1 menunjukkan bahwa penyakit tanaman dapat disebabkan oleh aktivitas atau serangan organisme di dalam, di luar, atau di sekitar tubuh tanaman. Di dalam tubuh tanaman, organisme menginfeksi bagian-bagian seperti daun, batang, dan akar. Organisme yang menyebabkan kerusakan ini termasuk jamur, bakteri, virus, dan serangga dalam fase larva maupun dewasa. Di luar tubuh tanaman, berbagai jenis organisme seperti yang telah disebutkan juga dapat menyebabkan kerusakan. Selain itu, gangguan di sekitar tubuh tanaman, seperti persaingan dengan gulma untuk mendapatkan air, nutrisi, sinar matahari, dan kebutuhan hidup lainnya, juga dapat mengakibatkan penyakit tanaman (Sutarman, n.d.). Identifikasi penyakit tanaman ini penting dilakukan untuk menanggulangi penurunan hasil produksi atau bahkan gagal panen, sehingga dapat meminimalisir kerugian yang dialami petani. Selain itu juga diharapkan dapat menyeimbangkan antara tingkat produksi dan konsumsi masyarakat serta menjamin ketersediaan pasokan pangan (Akther et al., 2021).

2.2 Klasifikasi Penyakit Tanaman

Pada sektor industri pertanian, salah satu aspek penting yang melibatkan teknologi otomatis menggunakan *machine learning* diperlukan dalam meningkatkan keefektifan identifikasi jenis penyakit tanaman dengan cara melakukan klasifikasi jenis penyakit secara otomatis sesuai dengan label yang telah ditetapkan (Sahro Winanto et al., 2023). Klasifikasi penyakit tanaman memiliki peranan penting untuk mengidentifikasi jenis penyakit tanaman yang memiliki banyak jenis, hal ini tentunya memberikan fasilitas kepada petani baru dalam mengidentifikasi penyakit tanaman secara otomatis.

Baranwal et al., (2019) melakukan penelitian tentang deteksi penyakit daun apel menggunakan *Deep Learning* menggunakan model *Convolutional Neural Network* arsitektur LeNet-5. Dalam studi ini, input yang digunakan berukuran 60x60x3 dengan 3 proses konvolusi, 2 proses pooling, 1 *hidden layer*, dan *output layer*. Total data yang digunakan pada penelitian ini sebanyak 500 citra dengan sekitar 20% adalah *original dataset*. Pada penelitian ini sebelum *training* dilakukan *preprocessing data* yang tujuannya untuk memperbanyak data latih menggunakan transformasi sederhana seperti *rotation*, *width shifts*, *height shifts*, *horizontal flip* dan *vertical flip*. Dalam penelitian ini, model yang dilatih mencapai akurasi rata-rata 98,54%.

Hasan et al., (2021) melakukan penelitian tentang klasifikasi penyakit anggur berdasarkan citra daun menggunakan model *Convolutional Neural Network* (CNN) arsitektur VGG16. Pada penelitian ini proses pengolahan citra berupa segmentasi menggunakan algoritma *k-means clustering* dan proses ekstraksi fitur

menggunakan teknik *transfer learning* VGG16 serta klasifikasi menggunakan CNN. *Dataset* diambil dari situ website *kaggle.com* dengan total jumlah data sebanyak 4000 citra daun anggur yang dibagi menjadi 4 kelas, yaitu daun dengan campak hitam, bercak daun, daun sehat, dan hawar daun. Diambil juga citra dari Google sejumlah 100 gambar yang digunakan sebagai data uji di luar *dataset*. Hasil dari penelitian ini memperoleh akurasi pelatihan model CNN sebesar 99,50%, pengujian menggunakan data uji menghasilkan 97,25%. Sedangkan dengan menggunakan data citra uji dari luar *dataset* memperoleh hasil akurasi sebesar 95%.

Penelitian yang dilakukan oleh Wijaya et al., (2020) klasifikasi jenis tanaman untuk identifikasi jenis tanaman berdasarkan daun. Pada penelitian ini menggunakan “*Supervised Learning*” untuk membantu dalam mengenali jenis tanaman. Dengan melakukan *preprocessing* data yang akan digunakan yang ada dalam *dataset*, selanjutnya dilakukan proses konversi citra menjadi sebuah matriks, dimana matriks akan diproses pada algoritma *Convolutional Neural Network* (CNN). Peneliti menggunakan *dataset* yang berupa citra daun dengan total 375 citra daun, 250 citra digunakan sebagai data *training* dan 125 citra digunakan untuk *testing*. Hasil dari pengujian pada penelitian ini menghasilkan tingkat akurasi sebesar 76%.

Sabrina & Maki W.F, (2022) melakukan penelitian mengenai klasifikasi penyakit tanaman pada tanaman kopi dengan menggunakan metode *Convolutional Neural Network* (CNN) dengan arsitektur *EfficientNet-B0* dan menggunakan *Adam* serta *Root Mean Square Propagation* (RMSprop) pada evaluasi performa. *Dataset* yang digunakan pada penelitian ini merupakan *dataset* sekunder bernama *RoCoLe*

yang diperoleh dari situs Mendeley dengan jumlah citra daun kopi sebanyak 1560 data yang terdiri dari 6 kelas berbeda diantaranya daun sehat, daun dengan tungau laba-laba merah, karat daun tingkat 1, karat daun tingkat 2, karat daun tingkat 3, dan karat daun tingkat 4. Dengan hasil nilai akurasi sebesar 91% dan *F1-Score* secara keseluruhan sebesar 90%.

Asrafil dkk., (2018) mengerjakan penelitian terkait klasifikasi penyakit tanaman apel dari citra daun menggunakan algoritma *Convolutional Neural Network* (CNN). Pada penelitian ini menggunakan *dataset* daun apel, data diambil dari *datasets* website *kaggle.com*, data disusun peneliti ke dalam direktori *train* dan *valid* dengan jumlah data sebanyak 9643 data daun apel. Sebanyak 7700 daun apel terletak pada direktori *train* dan 1943 terletak pada *valid*, yang dibagi menjadi 4 kelas diantaranya *apple scab*, *black rot*, *rust*, dan *healthy*. Input yang digunakan berukuran 256x256 dan menggunakan tipe gambar RGB. Program pada penelitian ini telah dapat dijalankan pada *smartphone* dengan minimum versi Android Lollipop. Hasil dari *final test accuracy* yang diperoleh dari keseluruhan proses pelatihan sebesar 97,1%.

Irfansyah et al., (2021) melakukan penelitian klasifikasi penyakit yang disebabkan hama pada tanaman kopi. Pada penelitian ini mengimplementasikan arsitektur *Convolutional Neural Network* (CNN) *Alexnet* dengan platform pemrograman MATLAB untuk identifikasi penyakit tanaman kopi menggunakan citra daun. *Dataset* yang digunakan pada penelitian ini diambil dari *mendeley ReCoLe: a robusta coffe leaf images dataset* dengan data sebanyak 300 data yang terbagi menjadi 3 kelas diantaranya yaitu *health*, *rust* dan *red spider mite*. Penelitian

ini akan menganggap hasil akurasi baik jika nilai akurasinya $> 70\%$ dengan pembagian data 80:20, 80 untuk data *training* dan 20 untuk data *testing*. Proses *training* yang melibatkan 260 data latih menghasilkan akurasi dengan nilai 69,44 – 80,56%. Proses pengujian jaringan menggunakan 40 data uji menghasilkan akurasi sebesar 81.6%, berdasarkan hasil penelitian tersebut dapat dikatakan bahwa arsitektur *AlexNet* akurat untuk klasifikasi penyakit tanaman kopi berdaun daun.

Anggraeni et al., (2022) melakukan penelitian terkait klasifikasi penyakit tanaman cabai. Penelitian ini menggunakan metode *Convolutional Neural Network* (CNN) dengan struktur model terdiri dari 3 lapisan konvolusi, 3 *fully connected layer* dan lapisan *output*. *Dataset* yang diambil dari situ *kaggle.com* dengan pembagian data 3 kelas dari beberapa penyakit tanaman cabai diantaranya *health*, *leaf curl*, *yellowish*. Pembagian data dari *dataset* tersebut terbagi menjadi 3 bagian diantaranya 80% untuk data *training*, 10% untuk data *validation* dan 10% sisanya untuk data *testing*. Hasil akurasi dari *training* yang dilakukan dengan total 300 data citra menghasilkan 80%, dan untuk akurasi dari validasi dengan total 100 data menghasilkan 60%.

Terakhir Zalvadila et al., (2023) melakukan sebuah penelitian terkait klasifikasi penyakit pada bawang merah menggunakan algoritma *Convolutional Neural Network* dan *Support Vector Machine* dengan berbagai kernel seperti *RBF*, *linear*, *sigmoid*, dan *polynomial*. Pada penelitian ini menggunakan *Gray Level Co-occurrence Matrix* (GLCM) sebagai model ekstraksi fitur. *Dataset* yang digunakan pada penelitian ini terdiri dari 320 citra yang dibagi menjadi dua kelas, penyakit bercak ungu dan penyakit moler, dengan masing-masing kelas berisi 160 gambar.

Hasil pengujian menunjukkan bahwa metode *Convolutional Neural Network* dan *Support Vector Machine* dengan menggunakan *kernel linear*, *RBF* dan *polynomial* mencapai *output* akurasi, presisi, *recall*, serta *F1-Score* masing-masing sebesar 100%. Sementara itu, SVM dengan kernel *sigmoid* menggunakan ekstraksi fitur GLCM mencapai nilai akurasi 75%, presisi 75%, *recall* 73%, dan *F1-Score* 74%.

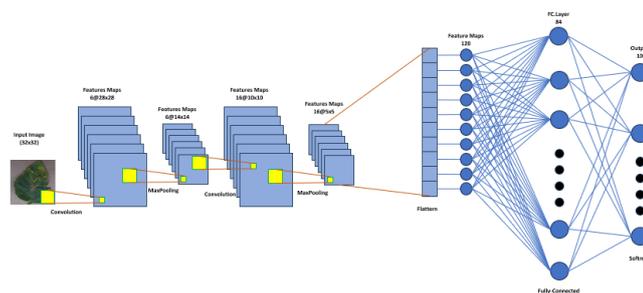
2.3 *Convolutional Neural Network*

Algoritma *deep learning* yang umum digunakan untuk pengenalan citra adalah model *Convolutional Neural Network* (CNN). Model tersebut dicirikan oleh arsitekturnya yang sederhana, lebih sedikit parameter pelatihan, dan lebih fleksibel. Selain pengenalan gambar, CNN juga banyak digunakan dalam tugas analisis ucapan dan pengenalan pola (Irfansyah et al., 2021).

CNN sering digunakan untuk mendeteksi translasi, zoom, dan berbagai bentuk invarian distorsi untuk grafik 2D. Dalam CNN, lapisan ekstraksi fitur dilatih menggunakan data, oleh karena itu tidak diperlukan ekstraksi fitur secara gamblang atau tersirat saat digunakan. Selain itu, karena neuron dalam peta fitur yang sama memiliki bobot yang sama, pembelajaran secara serentak dapat dilakukan di seluruh jaringan. Karakteristik ini memberikan keunggulan signifikan bagi CNN dibandingkan dengan *neural network* yang sepenuhnya terhubung. Rangka dari CNN menyediakan keuntungan khusus dalam deteksi suara dan analisis gambar, karena distribusi bobot yang tepat dapat membantu menyederhanakan kompleksitas jaringan. (Felix et al., 2020).

Secara garis besar, arsitektur *Convolutional Neural Network* (CNN) terdiri berdasarkan dua tahap utama. Tahap pertama disebut sebagai ekstraksi fitur, di

mana setiap neuron pada lapisan tersebut terhubung dengan area kecil pada lapisan sebelumnya untuk mengekstrak fitur-fitur lokal. Selain mengekstrak fitur-fitur ini, hubungan posisional antara fitur-fitur juga diidentifikasi. Tahap kedua dikenal sebagai tahap peta fitur, di mana setiap lapisan komputasi mencakup beberapa peta fitur. Dalam peta fitur, semua neuron berbagi bobot yang sama. Untuk mencapai invariansi pergeseran, CNN mengaplikasikan fungsi aktivasi *ReLU* pada *feature maps*-nya. Selain itu, karena neuron-neuron dalam *feature maps* yang sama memiliki bobot yang sama, jumlah parameter yang dibutuhkan dalam CNN menjadi lebih sedikit (Guo & Wang, 2022). Berikut contoh arsitektur *Convolutional Neural Network* ada pada Gambar 2.3.



Gambar 2.2 Gambaran Bentuk Arsitektur CNN

Dari Gambar 2.2 dapat diketahui struktur dari arsitektur *Convolutional Neural Network* adalah sebagai berikut.

1. *Input layer*: Menerima data input berupa gambar 2 dimensi.
2. *Convolution layer*:
 - a. Fungsi: Mendeteksi fitur dari gambar atau mendapatkan nilai dari *extraction feature (feature maps)*.

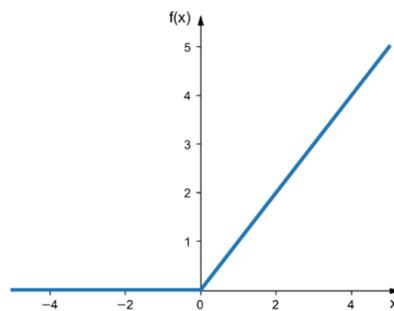
- b. Proses: Menggunakan filter (kernel) untuk melakukan operasi kovolusi pada gambar input.
- c. Parameter: *Stride* dan *Padding*, *stride* berfungsi untuk melakukan pergeseran filter, sementara *padding* berfungsi untuk menambah nilai *pixel* di sekitar gambar untuk mempertahankan dimensi *output* setelah dilakukan konvolusi.

3. *Max pooling layer*:

Fungsi: Mengurangi dimensi dari *output convolution layer* dengan mengambil nilai maksimum dari area filter.

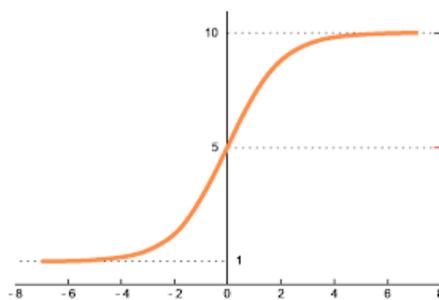
4. *Fully-Connected (FC) layer*:

- a. Fungsi: Mengklasifikasikan data berdasarkan *output* dari *convolution* dan *max pooling layer*.
- b. Proses: Menerima input berupa *array* 1D, menggunakan fungsi regresi dan fungsi aktivasi untuk menentukan *output* neuron.
- c. Fungsi aktivasi:
 - *ReLU*: Berfungsi untuk membatasi *output* negatif menjadi bernilai 0, sehingga *output* yang akan dikeluarkan *ReLU* hanya bernilai positif. Berikut adalah grafik visual dari fungsi aktivasi *ReLU* dapat dilihat pada Gambar 2.3.



Gambar 2.3 Fungsi aktivasi ReLu

- *Softmax*: Mengubah logits menjadi probabilitas, cocok untuk klasifikasi dengan lebih dari dua kategori. Berikut adalah grafik visual dari fungsi aktivasi *softmax* dapat dilihat pada Gambar 2.4.

Gambar 2.4 Fungsi Aktivasi *Softmax*.

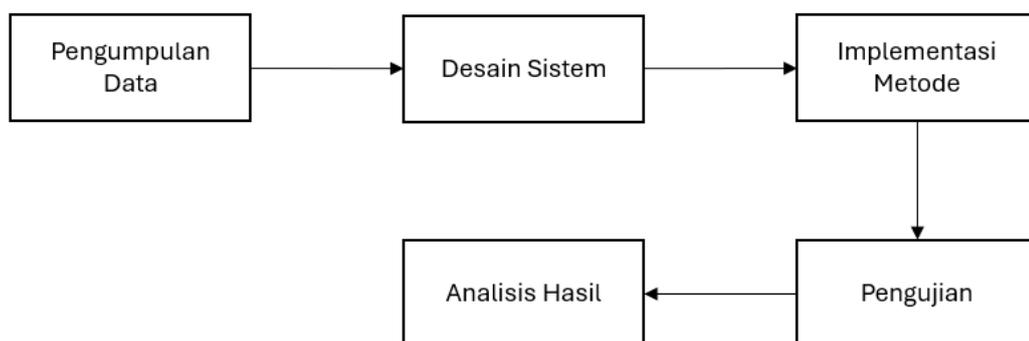
BAB III

DESAIN DAN IMPLEMENTASI

3.1 Desain Penelitian

Tahap desain penelitian ini merupakan proses dalam penelitian yang dikerjakan oleh peneliti. Beberapa tahapan tersebut dilakukan secara urut mulai dari hal mendasar hingga mendapatkan hasil yang optimal dimulai dari proses desain sampai implementasi. Tahapan awal yang perlu dilakukan dimulai dari pengumpulan data, kemudian akan dilanjutkan dengan membuat desain sistem dari proses yang akan terjadi pada sistem (*input, process, dan ouput*). Selanjutnya adalah implementasi metode atau sistem yang telah didesain akan diimplementasikan kedalam sistem, untuk mendapatkan hasil yang optimal dibutuhkan skenario uji maka dari itu diperlukan eksperimen percobaan terhadap skenario dan langkah terakhir merupakan evaluasi dan analisis hasil yang didapatkan dari skenario uji.

Alur proses desain penelitian dapat dilihat pada Gambar 3.1:



Gambar 3.1 Tahapan Penelitian.

3.2 Pengumpulan Data

Pada penelitian ini, untuk melakukan klasifikasi penyakit tanaman berdasarkan citra daun dibutuhkan *dataset* citra daun dari 4 jenis tanaman diantaranya tanaman padi, jagung, tomat dan kentang. *Dataset* yang digunakan adalah adalah *dataset* penyakit tanaman berdasarkan citra daun “*New Plant Disease Dataset*” dan “*Rice Leaf Disease Disease Image Sample*” yang didapatkan dari situs *website data.mendeley.com* dan *kaggle.com*. *Dataset* terdiri dari 4 spesies tanaman dengan 12 kelas yang berbeda dengan total banyaknya citra *dataset* adalah 1200, pada setiap kelas memiliki 100 citra daun dengan format .jpg untuk klasifikasi penyakit tanaman. Contoh sampel citra daun yang terkena penyakit dapat dilihat pada Tabel 3.1.

Tabel 3.1 Beberapa contoh data penyakit tanaman

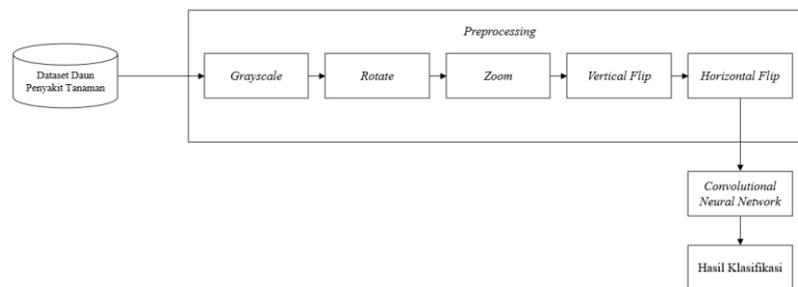
No	Nama tumbuhan dan Penyakit Tanaman	Citra Daun
1	<i>Corn Common Rust</i>	
2	<i>Corn Healthy</i>	
3	<i>Corn Northern Leaf Blight</i>	
4	<i>Potato Early Blight</i>	
5	<i>Potato Healthy</i>	
6	<i>Potato Late Blight</i>	

No	Nama tumbuhan dan Penyakit Tanaman	Citra Daun
7	<i>Rice Brown Spot</i>	
8	<i>Rice Healthy</i>	
9	<i>Rice Scald</i>	
10	<i>Tomato Bacterial Spot</i>	
11	<i>Tomato Healthy</i>	
12	<i>Tomato Mosaic Virus</i>	

Contoh data penyakit yang digunakan seperti yang terdapat pada Tabel 3.1 diambil dari tanaman yang terjangkit penyakit akibat jamur, virus, dan bakteri. Data pertama adalah *corn common rust* atau karat daun pada jagung, yang disebabkan oleh jamur *Puccinia sorghi*. Selanjutnya, *corn northern leaf blight* atau hawar utara daun jagung disebabkan oleh jamur *Exserohilum turcicum*. Kemudian, penyakit *potato early blight* atau pembusukan awal daun kentang dan *potato late blight* atau pembusukan daun kentang disebabkan oleh jamur *Alternaria solani*. Berikutnya, *rice brown spot* atau bercak coklat pada padi disebabkan oleh jamur *Cercospora oryzae*. Sementara itu, *rice scald* atau luka bakar daun padi disebabkan oleh jamur *Microdochium oryzae*. Terakhir, *tomato bacterial spot* atau bintik bakteri pada tomat disebabkan oleh bakteri *Pseudomonas syringae pv* (Wiyono, 2007).

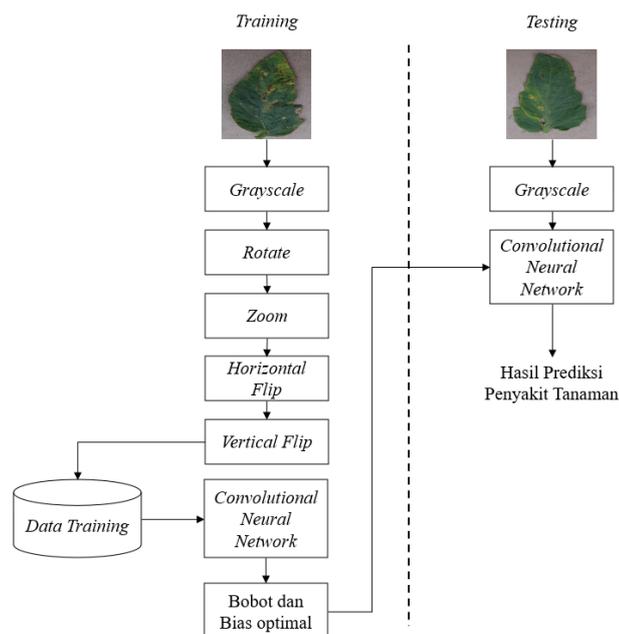
3.3 Desain Sistem

Struktur untuk desain sistem dalam penelitian ini menggambarkan alur yang akan dikerjakan oleh sistem terkait klasifikasi penyakit tanaman secara keseluruhan mulai dari input hingga *output*. Desain sistem pada penelitian ini dapat dilihat pada Gambar 3.2.



Gambar 3.2 Desain Sistem

Dapat dilihat pada Gambar 3.2 untuk proses sistem klasifikasi penyakit tanaman pada penelitian ini dimulai dengan *input* yang datanya berasal dari data citra daun penyakit tanaman jagung, padi, tomat dan kentang.



Gambar 3.3 Proses Pengolahan Data

Gambar 3.3 menunjukkan alur proses klasifikasi penyakit tanaman pangan. Proses ini dimulai dengan input yang datanya dibagi menjadi data latih dan data uji, dengan pembagian data yang akan dilakukan saat pengujian dalam penelitian ini. Setiap kelas memiliki 100 data citra sebagai *input*. Selanjutnya, data tersebut dimasukkan ke tahap *preprocessing* untuk dilakukan pengolahan seperti *rotate*, *zoom*, *vertical flip*, dan *horizontal flip*. Setelah tahap *preprocessing*, data akan diproses pada metode *Convolutional Neural Network*. Penelitian ini menghasilkan 12 kelas dari proses klasifikasi, yaitu *corn common rust*, *corn healthy*, *corn northern leaf blight*, *potato early blight*, *potato healthy*, *potato late blight*, *rice brown spot*, *rice healthy*, *rice scald*, *tomato bacterial spot*, *tomato healthy*, dan *tomato mosaic virus*. Hasil klasifikasi tersebut kemudian ditampilkan sebagai *output* untuk memberikan informasi tentang penyakit tanaman pangan.

3.3.1 Input Image

Citra daun yang sebelumnya telah didapatkan akan digunakan sebagai *inputan* pada sistem yang akan dibuat. Data citra daun tanaman jagung, padi, tomat dan kentang memiliki format .JPG dengan ukuran data 128x128 sejumlah total 1200 citra daun yang dibagi menjadi 12 kelas dan setiap kelas memiliki 100 data citra.

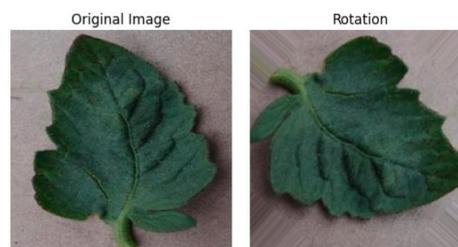
3.3.2 Image Preprocessing

Metode *Convolutional Neural Network* (CNN) memerlukan sejumlah besar data untuk mencapai performa yang optimal. Penggunaan metode augmentasi data merupakan salah satu cara untuk meningkatkan jumlah data dataset tanpa

merusaknya. Dalam penelitian ini, berbagai teknik augmentasi data akan digunakan, termasuk *rotate*, *zoom*, *vertical flip*, dan *horizontal flip*. Berikut adalah penjelasan untuk setiap teknik yang digunakan:

1. *Rotate*

Rotate digunakan untuk merotasi citra dengan menentukan derajat perputaran secara acak sesuai *range* derajat yang ditentukan. Gambar 3.4 merupakan contoh *output* dari teknik *rotate*.



Gambar 3.4 *Rotation*

2. *Zoom*

Zoom merupakan teknik yang digunakan untuk memperbesar gambar secara acak sesuai dengan nilai yang ditentukan. Gambar 3.5 merupakan contoh *output* dari teknik *zoom*.

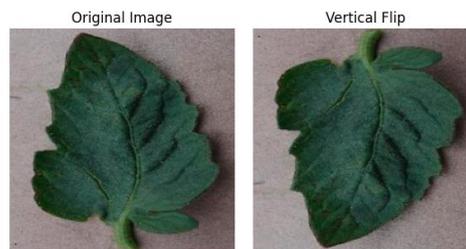


Gambar 3.5 *Zoom*

3. *Vertical Flip*

Teknik *vertical flip* berfungsi untuk membalikkan citra secara *vertical*.

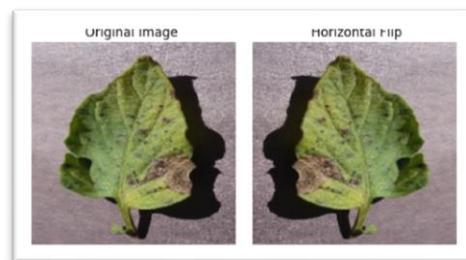
Pada Gambar 3.6 merupakan contoh *output* dari teknik *vertical flip*.



Gambar 3.6 *Vertical Flip*

4. *Horizontal Flip*

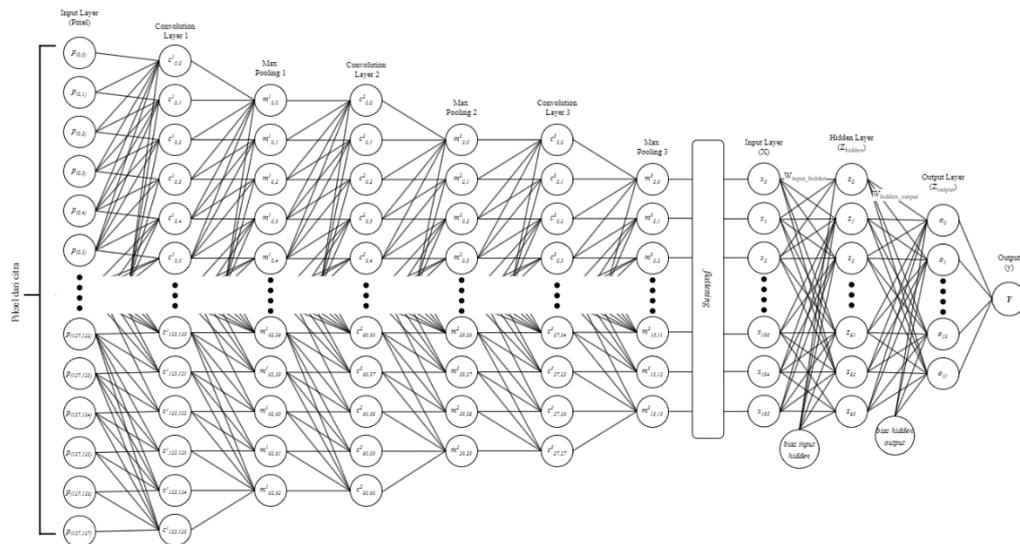
Teknik *horizontal flip* berfungsi untuk membalikkan citra secara *horizontal*. Pada Gambar 3.7 merupakan contoh *output* dari *horizontal flip*.



Gambar 3.7 *Horizontal Flip*

3.4 Implementasi Metode

Pada tahapan implementasi metode ini, data yang telah dipra-proses akan diproses dalam metode yang digunakan pada penelitian ini yaitu, *Convolutional Neural Network* (CNN). Dalam penelitian ini arsitektur CNN yang akan digunakan adalah arsitektur LeNet-5.



Gambar 3.8 Arsitektur CNN LeNet-5

Struktur CNN yang digunakan dalam penelitian ini digambarkan dalam Gambar 3.8. Berikut adalah berbagai lapisan dari arsitektur CNN LeNet-5 yang dimodifikasi yang digunakan dalam penelitian ini, diantaranya *input layer*, 3 *convolutional layers*, 3 *max-pooling layers*, *flatten layer*, *dense layer*, *output layer*, dan *output*. Arsitektur CNN dibagi menjadi *feature learning layer*, yang bertanggung jawab untuk ekstraksi fitur yang dilakukan dalam lapisan *convolutional* dan *max-pooling*. Di sisi lain, dalam lapisan klasifikasi, proses klasifikasi dilakukan melalui *flatten layer*, *dense layer*, dan *output layer*. Lapisan-lapisan tersebut juga dikenal sebagai *fully connected layers*.

3.4.1 Input Layer

Lapisan pertama berfungsi sebagai input layer yang menerima nilai piksel dari gambar berukuran 128×128 . Input ini merupakan citra hasil dari *preprocessing* data yang dilakukan sebelumnya dan berbentuk array dua dimensi.

3.4.2 Convolution Layer

Layer kedua, keempat dan keenam sebagai *convolution layer* dimana pada *convolution layer* ini dilakukan proses operasi konvolusi pada gambar grayscale. *Convolution* atau konvolusi berfungsi untuk menggabungkan dua baris angka yang berfungsi untuk menghasilkan baris angka ketiga. Baris angka yang dimaksud dalam penelitian ini adalah *input* dan filter (*kernel*), sedangkan baris ketiga dari kombinasi dua baris angka disebut *output*. Deret bilangan matriks terdiri dari ketiga baris tersebut, tahap augmentasi data menghasilkan *input* saat ini, dan *kernel* berfungsi sebagai filter untuk data yang di-*input* kan dan menghasilkan outptu yang dikenal sebagai *feature-maps*. Berikut adalah Persamaan 3.1 yang digunakan dalam perhitungan pada proses kovolusi:

$$c_{(a,b)} = \sum_{i=0}^{k_h-1} \sum_{j=0}^{k_w-1} X_{(a+i,b+j)} W_{(i,j)} \quad (3.1)$$

Keterangan:

- $c_{(a,b)}$ = Hasil konvolusi dengan indeks ke-(a,b)
- $X_{(a,b)}$ = Nilai piksel pada posisi (a,b) dalam gambar *input*.
- $W_{(i,j)}$ = Nilai kernel dengan indeks ke-(i,j)
- k_h = tinggi *kernel*
- k_w = lebar *kernel*
- a, b = tinggi dan lebar pada *feature map*
- i, j = baris dan kolom pada *kernel*

Dalam penelitian ini, *kernel* yang digunakan adalah *kernel* Sobel 3×3, *kernel* tersebut yang digunakan untuk memfasilitasi proses klasifikasi gambar, khususnya untuk ekstraksi tepi (Adistya & Muslim, 2016). Kernel Sobel Y yang digunakan dalam penelitian ini disajikan dalam Persamaan 3.2.

$$\text{kernel } k_{3 \times 3} = \begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix} \quad (3.2)$$

3.4.3 Max Pooling Layer

Layer ketiga, keempat dan kelima sebagai pooling layer dimana pada penelitian ini menggunakan *max pooling* yang berfungsi untuk mereduksi atau mengurangi dimensi dari *feature-maps* yang digunakan pada layer selanjutnya sehingga bisa hanya berfokus terhadap pola yang paling penting. Pada lapisan ini, *input* untuk *max pooling* berasal dari hasil konvolusi menggunakan ukuran jendela 2×2 dan *stride* (2, 2). Persamaan 3.3 di bawah ini digunakan dalam perhitungan ini..

$$m_{(p,q)} = \max (c_{a \times s_x + P, b \times s_y + Q}) \quad (3.3)$$

Keterangan:

$m_{(p,q)}$ = *feature maps* hasil *max-pooling* dari $c_{a \times b}$ pada indeks ke-(p,q)

$c_{(a,b)}$ = *feature maps* hasil konvolusi

p, q = tinggi dan lebar *feature map*

P, Q = indeks yang digunakan untuk iterasi dalam jendela pooling (tinggi dan lebar pooling)

s_x = *stride* arah horizontal

s_y = *stride* arah vertikal

Berikutnya melakukan proses *flattening* untuk nilai $m_{(p,q)}$ dan diubah menjadi $X_{n \times 1}$. Hal ini dilakukan dengan tujuan untuk mempermudah proses perhitungan pada *fully-connected layer*, dimana setiap jaringan neuron yang ada di dalamnya akan terhubung ke jaringan neuron pada lapisan berikutnya.

3.4.4 Fully Connected Layer

Pada lapisan *fully-connected* yang terdiri dari tiga lapisan, yaitu *input layer* (nilai yang dihasilkan dari proses *flattening*), *hidden layer*, dan *output layer*. *Fully-*

connected layer adalah lapisan neuron yang terhubung secara penuh dengan menggunakan vektor sebelumnya sebagai salah satu parameter dari jumlah kelas yang akan diprediksi. Pada *hidden layer* terdapat fungsi aktivasi yang digunakan yaitu *ReLU*, dan pada output layer juga terdapat fungsi aktivasi yaitu *softmax*, karena dalam kasus klasifikasi dengan lebih dari 2 kelas, fungsi aktivasi tersebut lebih umum digunakan. Tujuan utama dari *fully-connected layer* adalah untuk memproses data sehingga dapat diklasifikasikan. Berikut adalah jumlah neuron pada setiap layer yang digunakan pada penelitian ini:

- a. *Input layer* : Panjangnya menyesuaikan dari *output* pada *flatten*.
- b. *Hidden layer* : menggunakan 84 *node*, karena jumlah neuron 84 dalam *hidden layer* dipilih secara empiris atau diperoleh dari pengalaman dan percobaan yang dilakukan selama pengembangan model berdasarkan eksperimen yang dilakukan oleh Yann Lecun (1998).
- c. *Output Layer* : menggunakan 21 *node*, karena menyesuaikan total *output* kelas yang akan diprediksi.
- d. *Output* : hanya ada 1 *node*, karena *output* dari sistem adalah memprediksi salah satu dari kelas yang ada

Pada bagian *classification layer*, proses dari *neural network* adalah melakukan perhitungan yang dimulai dari *input* sampai *output layer* dinamakan dengan proses *feedforward*. Data yang didapatkan dari hasil proses ekstraksi fitur dimasukkan ke dalam setiap neuron sebagai *input layer* dan dilakukan perkalian dengan bobot, serta menambahkan nilai bias. Kemudian diteruskan pada *layer*

berikutnya, dimana proses yang sama dilakukan kembali sampai akhirnya mencapai pada *output layer*.

Adapun langkah yang terjadi selama proses *feedforward* adalah sebagai berikut:

1. Proses pertama adalah perhitungan pada *input* ke *hidden layer 1*.

$$z_s = \sum_{r=0} x_d w_r + b_1 \quad (3.4)$$

Keterangan:

z_s = *node hidden layer* ke-1 pada indeks ke-s

b = nilai bias pada *hidden layer* ke-1

$\sum_r x_d w_r$ = total nilai dari perkalian bobot *input layer* dan *hidden layer* ke-1.

Persamaan 3.4 menunjukkan bahwa perhitungan pada *hidden layer 1* melibatkan perkalian antara w dan x , kemudian ditambahkan b_1 sebagai bias pada layer pertama.

2. Nilai hasil dari *hidden layer 1* dilakukan proses aktivasi menggunakan fungsi aktivasi *ReLU* yang ada pada Persamaan 3.5.

$$a_g = f(z_s) \quad (3.5)$$

$$a_{1h} = \max(0, a_g)$$

Keterangan:

a_{1h} = nilai aktivasi dari nilai *hidden layer* indeks ke-h

$\max ()$ = fungsi aktivasi *ReLU*.

Tahap ini diproses melalui fungsi aktivasi *ReLU*. Hasilnya adalah matriks a_1 yang berisi nilai aktivasi untuk setiap *node* pada *hidden layer*.

3. Ketika nilai dari *hidden layer 1* sudah didapatkan, maka dilanjutkan ke proses perhitungan pada *hidden layer 2* seperti yang ada pada Persamaan 3.6.

$$o_t = \sum_{u=0} z_s v_u + b_2 \quad (3.6)$$

Keterangan:

o_t = *node hidden layer* ke-2 pada indeks ke-t

b = nilai bias pada *hidden layer* ke-2

$\sum_r z_s v_u$ = total nilai dari perkalian bobot *hidden layer* ke-1 dan *hidden layer* ke-2.

4. Nilai hasil dari *hidden layer* 2 dilakukan proses aktivasi menggunakan fungsi aktivasi *softmax*. Fungsi aktivasi *softmax* digunakan karena *output* yang diinginkan berupa *categorical*. Berikut rumus pertungan yang ada pada Persamaan 3.7.

$$f(p_i) = \frac{\exp(p_i)}{\sum_{j=0}^{12} \exp(p_j)} \quad (3.7)$$

$$\hat{y} = f(p_i)$$

Keterangan:

f = fungsi aktivasi *softmax*

p = *input data*

\hat{y} = hasil *output* dari model

5. Hasil dari perhitungan *softmax* memberikan probabilitas untuk semua kategori, dan ketika probabilitas ini dijumlahkan, totalnya sama dengan 1. Prediksi didasarkan pada kategori dengan probabilitas tertinggi.
6. Terakhir, langkah yang dilakukan selanjutnya adalah menghitung nilai *error* dengan menggunakan *Cross-Entropy Loss*. *Cross-Entropy Loss* ini adalah *Loss function* yang banyak digunakan pada tugas klasifikasi, rumus perhitungannya ada pada Persamaan 3.8.

$$E = - \sum_{j=1}^{12} y \log (\hat{y}) \quad (3.8)$$

Keterangan:

y = *output target ground truth.*

\hat{y} = *output prediksi dari model.*

Untuk dapat menghasilkan nilai *output* yang berupa prediksi kelas dari data *input*, perlu dilakukan perhitungan nilai aktivasi neuron pada setiap lapisan. Hal ini diperlihatkan dengan rumus-rumus diatas yang menunjukkan bagaimana proses nilai aktivasi neuron dihitung pada setiap lapisan dalam *neural network*.

3.5 Proses *Training*

Proses *training* adalah tahapan untuk melakukan pelatihan data pada model *Convolutional Neural Network* yang dilatih menggunakan data *training*. Untuk mendapatkan nilai akurasi yang baik, dibutuhkan proses *training* yang bertujuan untuk mendapatkan nilai bobot dan bias yang optimal sehingga dapat sesuai dengan permasalahan klasifikasi penyakit tanaman pangan. Sebelum dilakukannya proses *training*, diperlukan beberapa nilai parameter seperti *epoch* dan *learning rate*, dimana masing-masing nilai dari parameter tersebut bersifat konstan atau tidak akan berubah seiring berjalannya proses *training*. Namun, untuk nilai bobot dan bias pada model akan berubah seiring berjalannya proses dari *training*.

Dalam melakukan proses *training*, *input* yang digunakan adalah *image* dari data *training* yang telah melewati tahapan *preprocessing*, dimana data tersebut berbentuk matriks. Data tersebut kemudian dimasukkan kedalam *input layer*, selanjutnya dilakukan proses *convolution*, *pooling*, mengubah data menjadi 1D

dengan *flatten*, kemudian masuk pada proses *feedforward* dan *backpropagation* sebanyak jumlah *epoch* yang telah ditentukan.

Berikut ini adalah langkah-langkah yang terjadi selama proses *backpropagation*:

1. Menghitung *error*, turunan bobot, dan turunan bias pada *hidden layer 2*.

$$\delta_2 = (y - o_t) \quad (3.9)$$

$$\frac{dL}{dV} = \delta_2(z)^T \quad (3.10)$$

$$\frac{dL}{db_2} = \delta_2 \quad (3.11)$$

Keterangan:

δ_2 = nilai *error* pada *hidden layer* ke-2.

y = target output.

$\frac{dL}{dV}$ = turunan bobot (*weight*) pada *hidden layer* ke-2.

$\frac{dL}{db_2}$ = turunan bias pada *hidden layer* ke-2.

$(z)^T$ = nilai *transpose* atau matriks baru dari *hidden layer* ke-1.

$\sigma'(o)$ = turunan dari fungsi aktivasi pada *output layer*.

Diketahui perhitungan pada Persamaan 3.9, 3.10 dan 3.11 nilai *error* atau kesalahan pada *hidden layer 2* dihitung dan diteruskan ke *layer* sebelumnya untuk menghitung kesalahan bobot dan bias pada *hidden layer 2*.

2. Menghitung *error*, turunan bobot, dan turunan bias pada *hidden layer 1*.

$$\delta_1 = V^T * \delta_2 * \sigma'(a_1) \quad (3.12)$$

$$\frac{dL}{dW} = \delta_1 x \quad (3.13)$$

$$\frac{dL}{db_1} = \delta_1 \quad (3.14)$$

Keterangan:

δ_1 = nilai *error* pada *hidden layer* ke-1.

$\frac{dL}{dW}$ = turunan bobot (*weight*) pada *hidden layer* ke-1.

$\frac{dL}{db_1}$ = turunan bias pada *hidden layer* ke-1.

V^T = nilai *transpose* matriks bobot antara *hidden layer* ke-1 dan *hidden layer* ke-2.

$\sigma'()$ = turunan dari fungsi aktivasi ReLu pada *hidden layer* ke-1.

x = nilai *input*.

Dari Persamaan 3.12, 3.13 dan 3.14 dapat diketahui nilai *error* dari *hidden layer* kedua akan digunakan untuk mencari nilai *error* pada *hidden layer* pertama. Hasil nilai *error* dari *hidden layer* pertama akan digunakan untuk menghitung turunan dari bobot (*weight*) dan bias pada *hidden layer* pertama. Oleh karena itu, penyesuaian untuk bobot dan bias pada *hidden layer* pertama dipengaruhi berdasarkan yang terjadi pada *hidden layer* kedua.

3. Parameter bobot dan bias dapat diperbarui menggunakan rumus pada Persamaan 3.15, 3.16, 3.17, dan 3.18..

$$W_2(new) = W_2 - \eta \frac{dL}{dV} \quad (3.15)$$

$$b_2(new) = b_2 - \eta \frac{dL}{db_2} \quad (3.16)$$

$$W_1(new) = W_1 - \eta \frac{dL}{dW} \quad (3.17)$$

$$b_1(new) = b_1 - \eta \frac{dL}{db_1} \quad (3.18)$$

Keterangan:

η = nilai dari laju pembelajaran (*learning rate*)

$\frac{dL}{dV}$ = nilai turunan bobot pada *hidden layer* ke-2.

$\frac{dL}{db_2}$ = nilai turunan bias pada *hidden layer* ke-2.

$\frac{dL}{dW}$ = nilai turunan bobot pada *hidden layer* ke-1.

$\frac{dL}{db_1}$ = nilai turunan bias pada *hidden layer* ke-1.

Rumus dari perubahan atau *update* parameter menggunakan turunan *error* sebagai arahan untuk perubahan bobot dan bias, serta laju pembelajaran atau *learning rate* sebagai kontrol dari kecepatan perubahan, dalam implementasinya proses ini akan berhenti sampai batas *epoch* tertentu.

BAB IV

HASIL DAN PEMBAHASAN

4.1 Langkah-Langkah Uji Coba

Pengujian dilakukan dengan rangkaian yang sistematis, dengan tujuan memastikan bahwa proses pengujian dapat dilakukan secara konsisten dan mudah dipahami. Prosedur pengujian dalam penelitian ini diuraikan sebagai berikut.

4.1.1 Data Pengujian

Dataset uji terdiri atas 12 kategori berbeda, dengan masing-masing kelas terdiri dari 100 gambar daun tanaman yang terkena penyakit dengan total dataset menjadi 1200 gambar. Dataset tersebut bersumber dari Mendeley dan Kaggle. Contoh dataset dapat ditemukan di Tabel 4.1.

Tabel 4.1 Dataset Penelitian

Kelas	Jumlah
<i>Corn Common Rust</i>	100 data
<i>Corn Healthy</i>	100 data
<i>Corn Nothorn Leaf Blight</i>	100 data
<i>Potato Early Blight</i>	100 data
<i>Potato Healthy</i>	100 data
<i>Potato Late Blight</i>	100 data
<i>Rice Brown Spot</i>	100 data
<i>Rice Healthy</i>	100 data
<i>Rice Scald</i>	100 data
<i>Tomato Bacterial Spot</i>	100 data
<i>Tomato Healthy</i>	100 data
<i>Tomato Mosaic Virus</i>	100 data

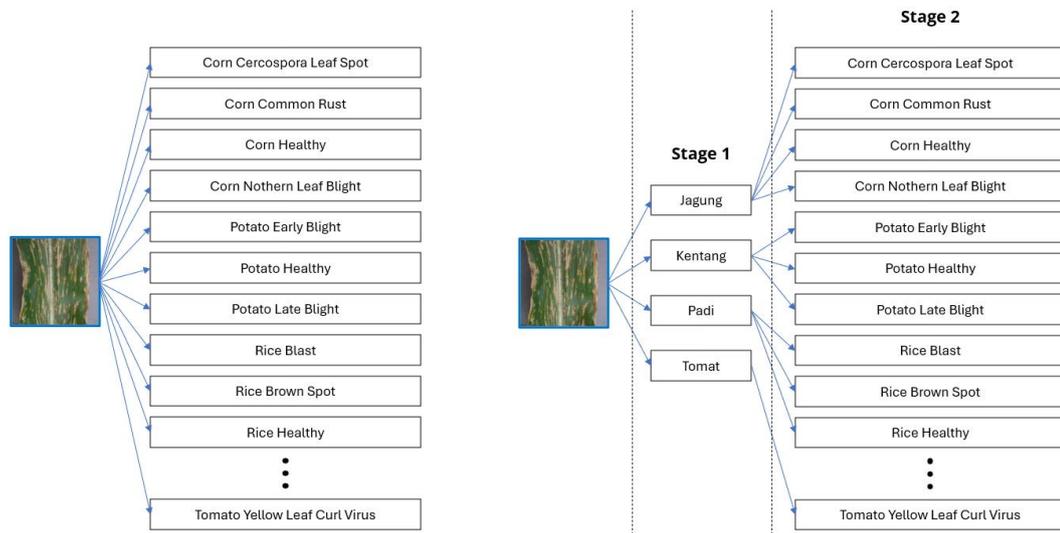
Selanjutnya, *dataset* akan mengalami tahap *preprocessing* yang bertujuan untuk memperbanyak data latih dengan menggunakan augmentasi data seperti *rotation*, *zoom*, *horizontal flip* dan *vertical flip*.

4.1.2 Skenario Pengujian

Dalam penelitian ini, peneliti akan mengadopsi pendekatan pembagian *dataset* sebagai skenario pengujian. Pendekatan ini melibatkan pembagian *dataset* menjadi dua bagian, yaitu data pelatihan dan data pengujian, dengan proporsi 70:30, 80:20, dan 90:10. Angka pertama dalam setiap rasio menunjukkan persentase data yang dialokasikan untuk pelatihan, sedangkan angka kedua menunjukkan persentase data yang dialokasikan untuk pengujian.. Pada penelitian ini, pembagian data dilakukan secara manual sehingga data sudah memiliki ukuran yang *fixed* sesuai dengan rasio pembagian *dataset* untuk data *training* dan data *testing*.

Selain itu, dalam penelitian ini akan diterapkan metode *single stage classification* dan *multi stage classification*. Metode *multi stage classification* memungkinkan hierarki pembagian kelas, sehingga memungkinkan pengelompokan data secara lebih terstruktur (Żarski et al., 2021). Hal ini dilakukan karena dalam penelitian ini memiliki cukup banyak kelas yaitu sebanyak 12 kelas *output*. Penggunaan metode *multi stage classification* ini digunakan sebagai pembandingan performa untuk *single stage classification*. Alasan digunakannya *multi stage classification* dikarenakan dalam *single stage classification*, semua kelas dipertimbangkan secara langsung dalam satu tahap. Artinya, model hanya membuat prediksi berdasarkan satu langkah klasifikasi. Namun, dalam *multi stage classification*, proses klasifikasi dilakukan dalam beberapa tahap atau tingkatan. Setiap tahap mempertimbangkan subset kelas tertentu, yang memungkinkan model untuk membuat prediksi dengan lebih cermat. Dengan menggunakan *multi stage classification* diharapkan dapat memberikan fleksibilitas dan keakuratan yang lebih tinggi, terutama ketika jumlah kelas yang besar seperti dalam penelitian ini. Berikut

contoh gambaran *single stage classification* dan *multi stage classification* ada pada Gambar 4.1.



Gambar 4.1 Contoh *Single* dan *Multi Stage Classification*

Tabel 4.2 menunjukkan 6 skenario pengujian berdasarkan rasio pembagian data serta pengimplementasian *single stage classification* dan *multi stage classification*.

Tabel 4.2 Skenario Pengujian

Uji Coba	Type of Stage Classification	Data Latih	Data Uji
1	<i>Single stage classification</i>	70%	30%
2		80%	20%
3		90%	10%
4	<i>Multi Stage Classification</i>	70%	30%
5		80%	20%
6		90%	10%

Keenam skenario tersebut dilatih sebanyak 300 *epoch* serta *learning rate* sebesar 0.001, dengan jumlah *epoch* dan *learning rate* yang digunakan dapat mendapatkan hasil yang lebih baik (Jiang et al., 2019). Setelah mendapatkan nilai dari hasil, langkah selanjutnya adalah menghitung *confusion matrix*. *Confusion*

matrix membantu untuk memberikan gambaran performa kalsifikasi dari model (Nawwar et al., 2021). Hasil dari *confussion matrix* terdiri dari empat kategori. *True Positive* (TP) adalah ketika model dengan benar memprediksi benar dan benar adanya. *False Positive* (FP) adalah ketika model salah dengan memprediksi benar padahal sebenarnya salah. *True Negative* (TN) adalah ketika model dengan benar memprediksi salah dan prediksi tersebut benar. *False Negative* (FN) adalah ketika model salah memprediksi salah padahal sebenarnya benar. Pada kasus permasalahan multiclass atau lebih dari dua kelas kategori, kelas positif adalah label dimana perhitungan itu dilakukan, sedangkan kelas negatif adalah kelas lainnya (Nawwar et al., 2021).

Hasil precocokan antara kelas prediksi dan kelas sebenarnya akan ditunjukkan melalui konsep *confussion matrix multiclass*. Persamaan 4.1, 4.2, 4.3 dan 4.4 berikut dapat digunakan untuk menghitung *accuracy*, *precision*, *recall* dan *F1-Score*.

$$accuracy = \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \quad (4.1)$$

$$precision_c = \frac{TP_c}{TP_c + FP_c} \times 100\% \quad (4.2)$$

$$recall_c = \frac{TP_c}{TP_c + FN_c} \times 100\% \quad (4.3)$$

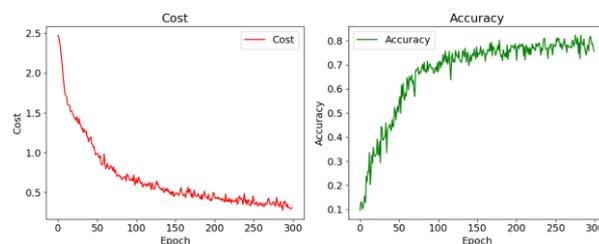
$$F1 - Score_c = \frac{2 \times precision_c \times recall_c}{precision_c + recall_c} \times 100\% \quad (4.4)$$

4.2 Hasil Uji Coba

Sesuai dengan skenario pengujian, penelitian ini melibatkan enam uji coba yang berbeda, di mana *dataset* dibagi menjadi berbagai rasio. Dalam sistem ini, pembagian *dataset* dilakukan secara manual menjadi data pelatihan serta data pengujian dengan proporsi data 70:30, 80:20, dan 90:10, memastikan bahwa data pelatihan lebih banyak dibandingkan data pengujian. Proses selanjutnya dilakukan pengujian menggunakan metode klasifikasi satu tahap (*single-stage*) dan klasifikasi multi-tahap (*multi-stage*). Tujuan dari pengaturan ini adalah untuk menemukan rasio yang optimal antara data latih dan data uji yang menghasilkan performa terbaik untuk model klasifikasi. Setiap model klasifikasi yang dihasilkan dievaluasi menggunakan metrik-metrik seperti *accuracy*, *precision*, *recall* dan *F1-Score*.

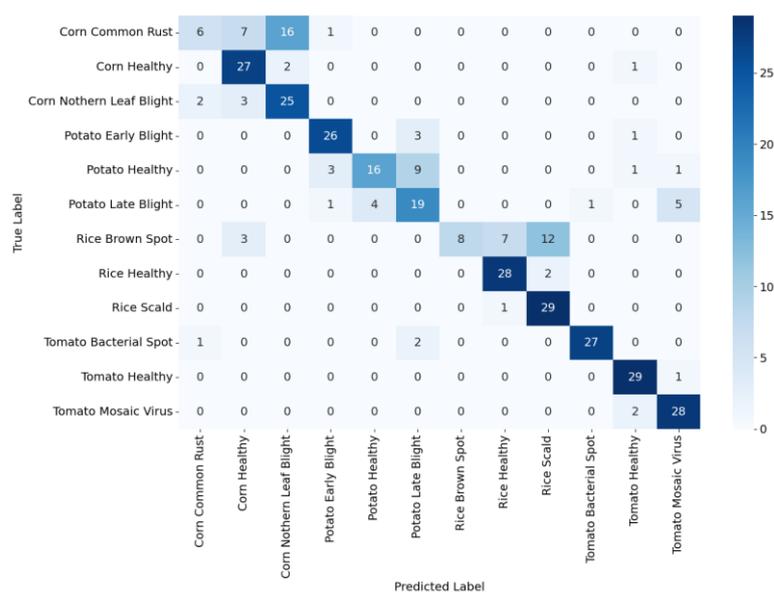
4.2.1 Skenario Uji 1

Skenario uji 1 dilakukan dengan metode *single stage classification* serta rasio skenario pembagian data 70:30 terdiri dari 840 data latih dan 360 data uji. Hasil dari klasifikasi *Convolutional Neural Network* menggunakan rasio perbandingan data sebesar 70:30 adalah sebagai berikut.



Gambar 4.2 Grafik Cost Proses Training Model 1

Gambar 4.2 menunjukkan grafik proses *training* untuk skenario 70:30 *single stage classification*. Dari proses *training* mendapatkan nilai *Cost* sebesar 0,31173 dan akurasi sebesar 75,57%.



Gambar 4.3 Hasil Prediksi Data dengan Rasio 70:30 pada 12 Kelas

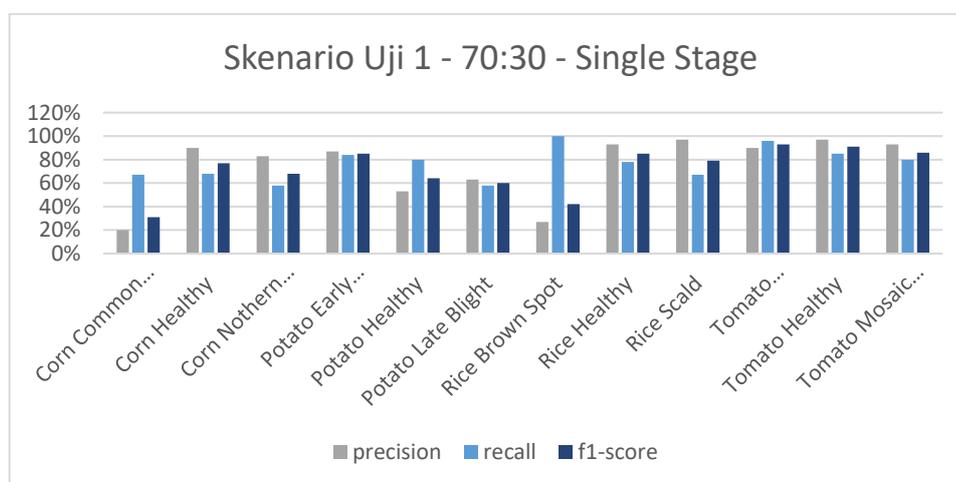
Mengacu pada Gambar 4.3 menunjukkan hasil *confussion matrix* pada data *testing* berhasil memprediksi kelas dengan benar sebanyak 268 data dan gagal memprediksi kelas dengan benar sebanyak 76 data. Berikut adalah nilai-nilai yang dihitung untuk presisi (*precision*), *recall*, dan *F1-Score* dari *confussion matrix* multi-kelas untuk 12 kategori penyakit tanaman yang diidentifikasi berdasarkan citra daun, dengan menggunakan Persamaan 4.1, 4.2, 4.3, dan 4.4 maka hasil disajikan pada Tabel 4.3.

Tabel 4.3 *Score Precision, Recall, F1-Score* pada 12 Kelas Skenario Uji 1

Kelas Jenis Penyakit	<i>Confussion matrix</i>		
	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
<i>Corn Common Rust</i>	20%	67%	31%
<i>Corn Healthy</i>	90%	68%	77%
<i>Corn Nothern Leaf Blight</i>	83%	58%	68%

Kelas Jenis Penyakit	Confussion matrix		
	Precision	Recall	F1-Score
Potato Early Blight	87%	84%	85%
Potato Healthy	53%	80%	64%
Potato Late Blight	63%	58%	60%
Rice Brown Spot	27%	100%	42%
Rice Healthy	93%	78%	85%
Rice Scald	97%	67%	79%
Tomato Bacterial Spot	90%	96%	93%
Tomato Healthy	97%	85%	91%
Tomato Mosaic Virus	93%	80%	86%

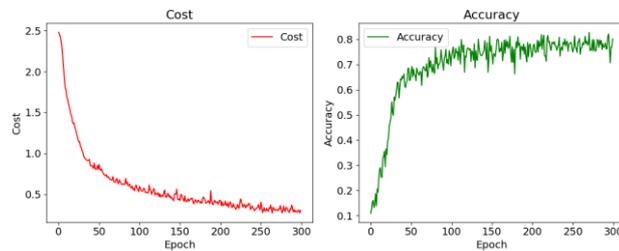
Dan dari *confussion matrix* tersebut, didapatkan nilai *accuracy* pada skenario uji 1 dengan pembagian rasio data 70:30 serta *single stage classification* adalah sebesar 74%.



Gambar 4.4 Visual Performa Skenario Uji Coba 1 Pembagian Data 70:30

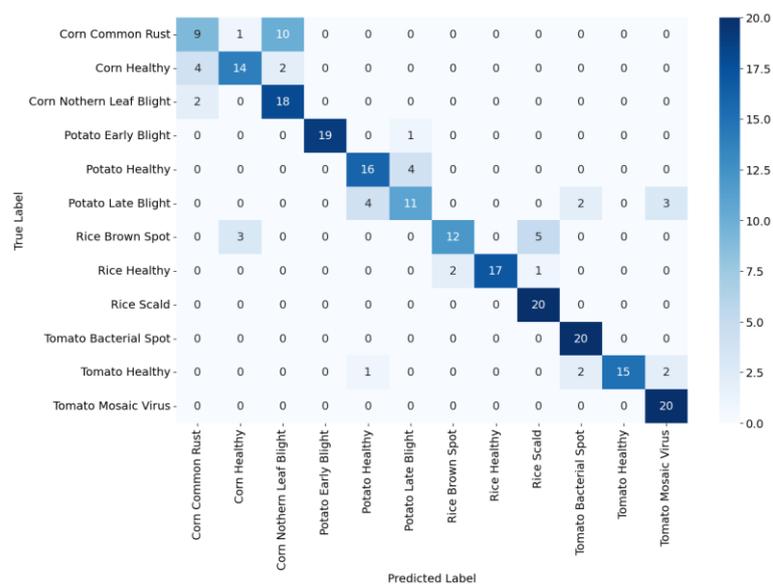
4.2.2 Skenario Uji 2

Skenario uji 2 dilakukan dengan metode *single stage classification* serta rasio skenario pembagian data 80:20 terdiri dari 960 data latih dan 240 data uji. Hasil dari klasifikasi *Convolutional Neural Network* menggunakan rasio perbandingan data sebesar 80:20 adalah sebagai berikut.



Gambar 4.5 Grafik Cost Proses Training Model 2

Gambar 4.5 menunjukkan grafik proses *training* untuk skenario 80:20 *single stage classification*. Dari proses *training* mendapatkan nilai *Cost* sebesar 0,30589 dan akurasi sebesar 80,20%.



Gambar 4. 6 Hasil Prediksi Data dengan Rasio 80:20 pada 12 Kelas

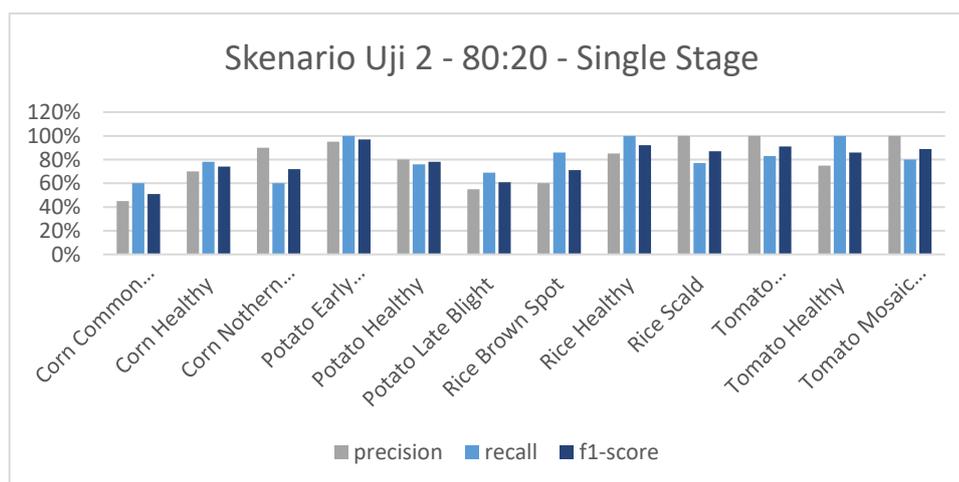
Mengacu pada Gambar 4.6 menunjukkan hasil *confusion matrix* pada data *testing* berhasil memprediksi kelas dengan benar sebanyak 191 data dan gagal memprediksi kelas dengan benar sebanyak 49 data. Berikut adalah nilai-nilai yang dihitung untuk presisi (*precision*), *recall*, dan *F1-Score* dari *confusion matrix* multi-kelas untuk 12 kategori penyakit tanaman yang diidentifikasi berdasarkan

citra daun, dengan menggunakan Persamaan 4.1, 4.2, 4.3, dan 4.4 maka hasil disajikan pada Tabel 4.4.

Tabel 4.4 *Score Precision, Recall, F1-Score* pada 12 Kelas Skenario Uji 2

Kelas Jenis Penyakit	Confusion matrix		
	Precision	Recall	F1-Score
<i>Corn Common Rust</i>	45%	60%	51%
<i>Corn Healthy</i>	70%	78%	74%
<i>Corn Nothern Leaf Blight</i>	90%	60%	72%
<i>Potato Early Blight</i>	95%	100%	97%
<i>Potato Healthy</i>	80%	76%	78%
<i>Potato Late Blight</i>	55%	69%	61%
<i>Rice Brown Spot</i>	60%	86%	71%
<i>Rice Healthy</i>	85%	100%	92%
<i>Rice Scald</i>	100%	77%	87%
<i>Tomato Bacterial Spot</i>	100%	83%	91%
<i>Tomato Healthy</i>	75%	100%	86%
<i>Tomato Mosaic Virus</i>	100%	80%	89%

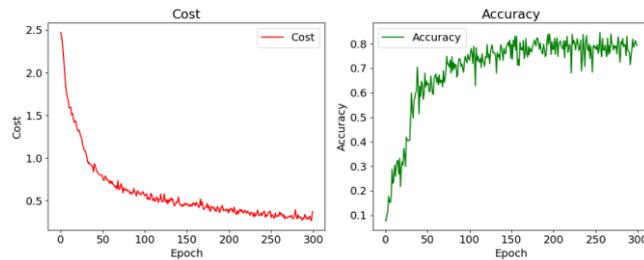
Dan dari *confusion matrix* tersebut, didapatkan nilai *accuracy* pada skenario uji 2 dengan pembagian rasio data 80:20 serta *single stage classification* adalah sebesar 80%.



Gambar 4. 7 Visual Performa Skenario Uji Coba 2 Pembagian Data 80:20

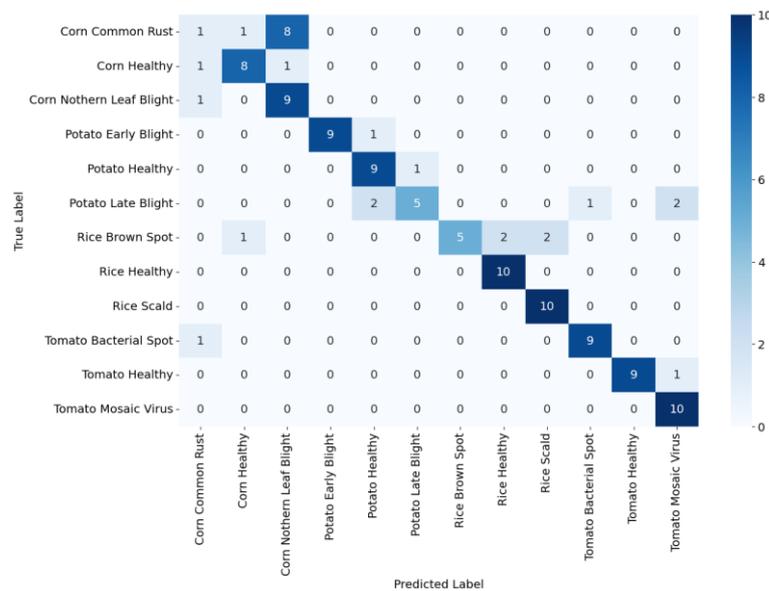
4.2.3 Skenario Uji 3

Skenario uji 3 dilakukan dengan metode *single stage classification* serta rasio skenario pembagian data 90:10 terdiri dari 1080 data latih dan 120 data uji. Hasil dari klasifikasi *Convolutional Neural Network* menggunakan rasio perbandingan data sebesar 90:10 adalah sebagai berikut.



Gambar 4.8 Grafik Cost Proses Training Model 3

Gambar 4.8 menunjukkan grafik proses *training* untuk skenario 90:10 *single stage classification*. Dari proses *training* mendapatkan nilai *Cost* sebesar 0,37199 dan akurasi sebesar 79,12%.



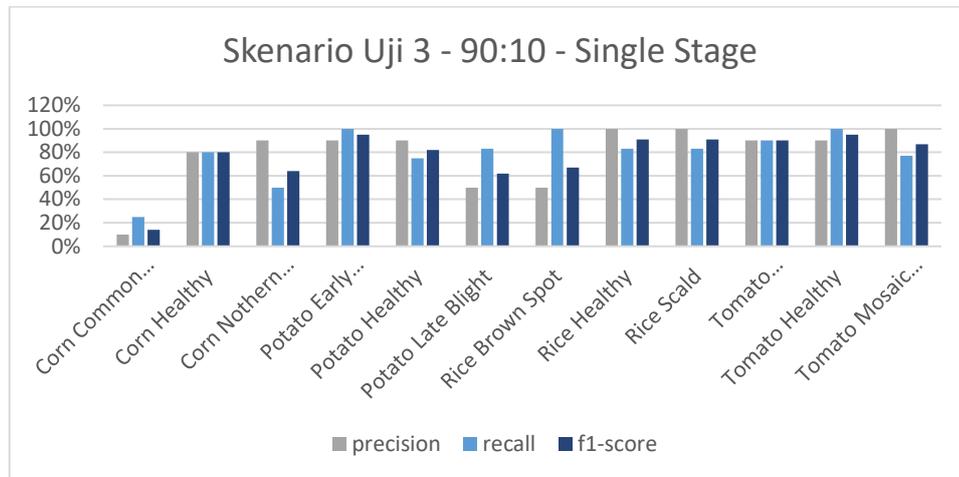
Gambar 4.9 Hasil Prediksi Data dengan Rasio 90:10 pada 12 Kelas

Mengacu pada Gambar 4.9 menunjukkan hasil *confussion matrix* pada data *testing* berhasil memprediksi kelas dengan benar sebanyak 94 data dan gagal memprediksi kelas dengan benar sebanyak 26 data. Berikut adalah nilai-nilai yang dihitung untuk presisi (*precision*), *recall*, dan *F1-Score* dari *confussion matrix* multi-kelas untuk 12 kategori penyakit tanaman yang diidentifikasi berdasarkan citra daun, dengan menggunakan Persamaan 4.1, 4.2, 4.3, dan 4.4 maka hasil disajikan pada Tabel 4.5.

Tabel 4.5 *Score Precision, Recall, F1-Score* pada 12 Kelas Skenario Uji 3

Kelas Jenis Penyakit	<i>Confussion matrix</i>		
	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
<i>Corn Common Rust</i>	10%	25%	14%
<i>Corn Healthy</i>	80%	80%	80%
<i>Corn Nothern Leaf Blight</i>	90%	50%	64%
<i>Potato Early Blight</i>	90%	100%	95%
<i>Potato Healthy</i>	90%	75%	82%
<i>Potato Late Blight</i>	50%	83%	62%
<i>Rice Brown Spot</i>	50%	100%	67%
<i>Rice Healthy</i>	100%	83%	91%
<i>Rice Scald</i>	100%	83%	91%
<i>Tomato Bacterial Spot</i>	90%	90%	90%
<i>Tomato Healthy</i>	90%	100%	95%
<i>Tomato Mosaic Virus</i>	100%	77%	87%

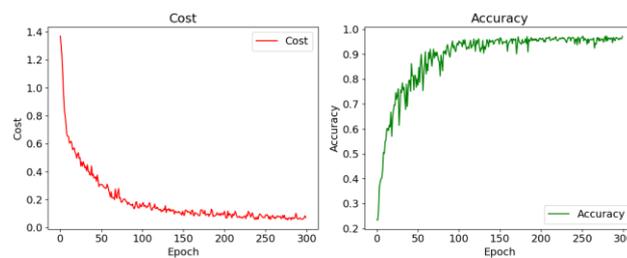
Dan dari *confussion matrix* tersebut, didapatkan nilai *accuracy* pada skenario uji 3 dengan pembagian rasio data 90:10 serta *single stage classification* adalah sebesar 78%.



Gambar 4.10 Visual Performa Skenario Uji Coba 3 Pembagian Data 90:10

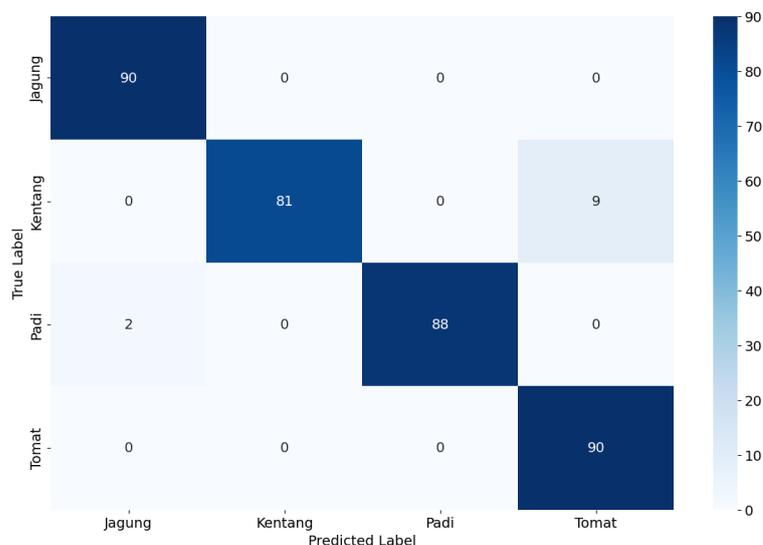
4.2.4 Skenario Uji 4

Skenario uji 4 dilakukan dengan metode *multi stage classification* serta rasio skenario pembagian data 70:30, stage pertama terdiri dari 840 data latih dan 360 data uji. Hasil dari klasifikasi *Convolutional Neural Network* menggunakan rasio perbandingan data sebesar 70:30 adalah sebagai berikut.



Gambar 4.11 Grafik Cost Proses Training Model 4 Stage 1

Gambar 4.11 menunjukkan grafik proses *training* untuk skenario 70:30 *multi stage classification*. Dari proses *training* mendapatkan nilai *Cost* sebesar 0,07140 dan akurasi sebesar 97,13%.



Gambar 4.12 Hasil Prediksi Data dengan Rasio 70:30 pada 4 Kelas

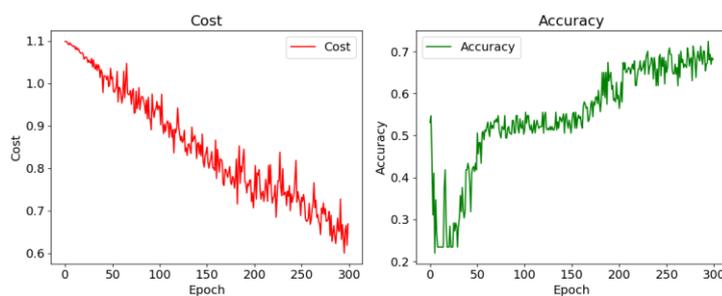
Mengacu pada Gambar 4.12 menunjukkan hasil *confussion matrix* pada data *testing* berhasil memprediksi kelas dengan benar sebanyak 349 data dan gagal memprediksi kelas dengan benar sebanyak 11 data. Berikut adalah nilai-nilai yang dihitung untuk presisi (*precision*), *recall*, dan *F1-Score* dari *confussion matrix* multi-kelas untuk 4 kategori jenis tanaman yang diidentifikasi berdasarkan citra daun, dengan menggunakan Persamaan 4.1, 4.2, 4.3, dan 4.4 maka hasil disajikan pada Tabel 4.6.

Tabel 4.6 *Score Precision, Recall, F1-Score* pada 4 Kelas Jenis Tanaman

Kelas Jenis Penyakit	<i>Confussion matrix</i>		
	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
Jagung	100%	98%	99%
Kentang	90%	100%	95%
Padi	98%	100%	99%
Tomat	100%	91%	95%

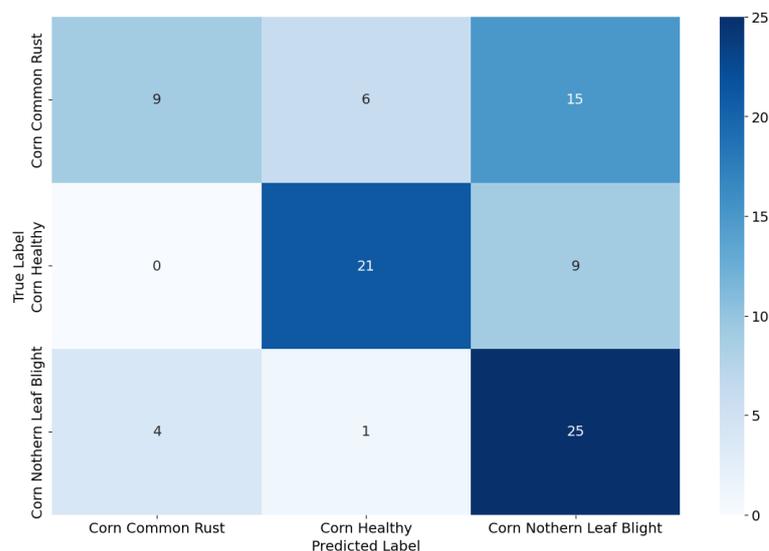
Dan dari *confussion matrix* tersebut, didapatkan nilai *accuracy* pada skenario uji 4 *stage* pertama dengan pembagian rasio data 70:30 serta *multi stage*

classification adalah sebesar 97%. Selanjutnya, dilakukan pelatihan untuk stage kedua pada penyakit tanaman jagung yang terdiri dari 210 data latih dan 90 data uji. Hasil dari klasifikasi *Convolutional Neural Network* menggunakan rasio perbandingan data sebesar 70:30 adalah sebagai berikut.



Gambar 4.13 Grafik Cost Proses Training Model 4 Stage 2 Penyakit Tanaman Jagung

Gambar 4.13 menunjukkan grafik proses *training* untuk skenario 70:30 *multi stage classification*. Dari proses *training* mendapatkan nilai *Cost* sebesar 0,66890 dan akurasi sebesar 68,08%.



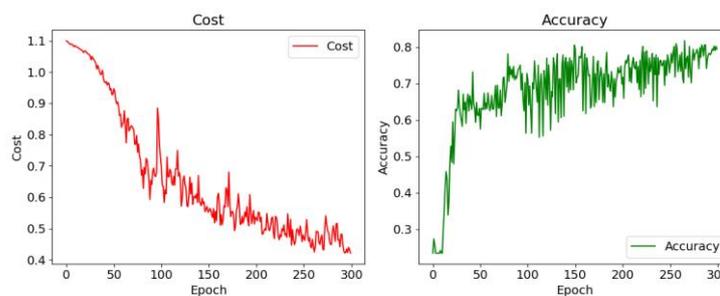
Gambar 4.14 Hasil Prediksi Data dengan Rasio 70:30 pada 3 Kelas Penyakit Tanaman Jagung

Mengacu pada Gambar 4.14 menunjukkan hasil *confussion matrix* pada data *testing* berhasil memprediksi kelas dengan benar sebanyak 55 data dan gagal memprediksi kelas dengan benar sebanyak 35 data. Berikut adalah nilai-nilai yang dihitung untuk presisi (*precision*), *recall*, dan *F1-Score* dari *confussion matrix* multi-kelas untuk 3 kategori jenis penyakit tanaman yang diidentifikasi berdasarkan citra daun, dengan menggunakan Persamaan 4.1, 4.2, 4.3, dan 4.4 maka hasil disajikan pada Tabel 4.7.

Tabel 4.7 *Score Precision, Recall, F1-Score* pada 3 Kelas Penyakit Tanaman Jagung

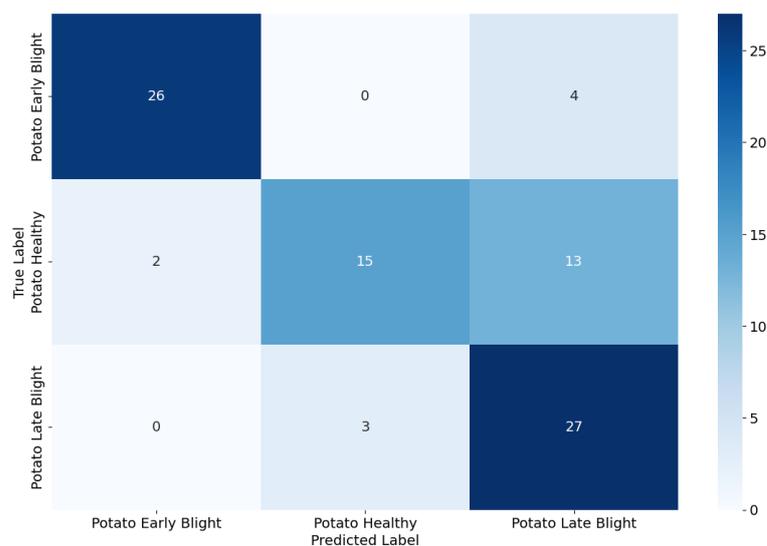
Kelas Jenis Penyakit	<i>Confussion matrix</i>		
	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
<i>Corn Common Rust</i>	30%	69%	42%
<i>Corn Healthy</i>	70%	75%	72%
<i>Corn Nothern Leaf Blight</i>	83%	51%	63%

Dan dari *confussion matrix* tersebut, didapatkan nilai *accuracy* pada *stage* kedua tanaman jagung dengan pembagian rasio data 70:30 serta *multi stage classification* adalah sebesar 61%. Selanjutnya, dilakukan pelatihan untuk *stage* kedua pada penyakit tanaman kentang yang terdiri dari 210 data latih dan 90 data uji. Hasil dari klasifikasi *Convolutional Neural Network* menggunakan rasio perbandingan data sebesar 70:30 adalah sebagai berikut.



Gambar 4.15 Grafik Cost Proses Training Model 4 Stage 2 Penyakit Tanaman Kentang

Gambar 4.15 menunjukkan grafik proses *training* untuk skenario 70:30 *multi stage classification*. Dari proses *training* mendapatkan nilai *Cost* sebesar 0,42122 dan akurasi sebesar 79,38%.



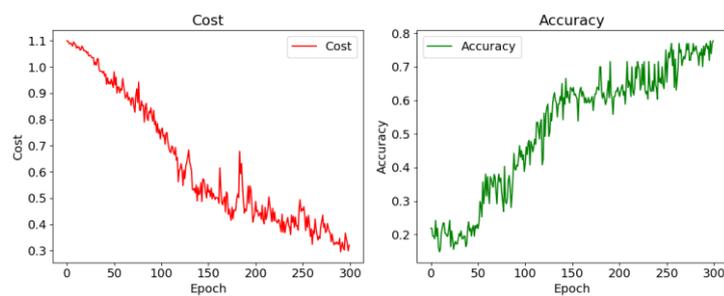
Gambar 4.16 Hasil Prediksi Data dengan Rasio 70:30 pada 3 Kelas Penyakit Tanaman Kentang

Mengacu pada Gambar 4.16 menunjukkan hasil *confussion matrix* pada data *testing* berhasil memprediksi kelas dengan benar sebanyak 68 data dan gagal memprediksi kelas dengan benar sebanyak 22 data. Berikut adalah nilai-nilai yang dihitung untuk presisi (*precision*), *recall*, dan *F1-Score* dari *confussion matrix* multi-kelas untuk 3 kategori jenis penyakit tanaman yang diidentifikasi berdasarkan citra daun, dengan menggunakan Persamaan 4.1, 4.2, 4.3, dan 4.4 maka hasil disajikan pada Tabel 4.8.

Tabel 4.8 *Score Precision, Recall, F1-Score* pada 3 Kelas Penyakit Tanaman Kentang

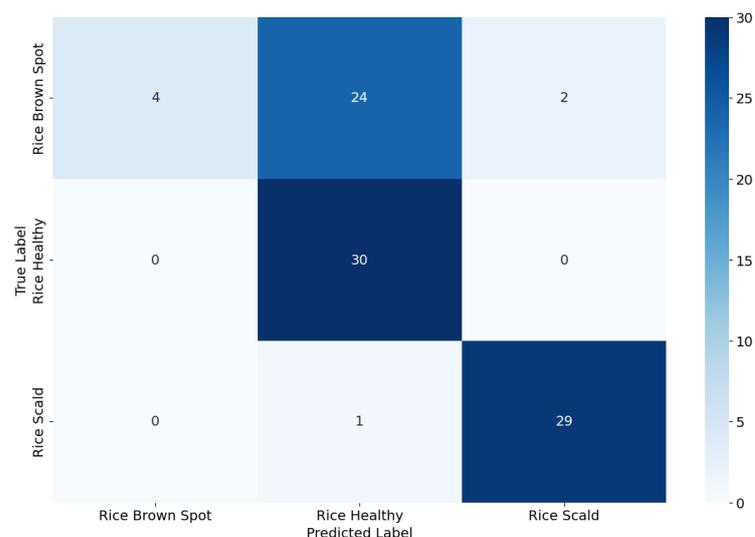
Kelas Jenis Penyakit	<i>Confussion matrix</i>		
	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
<i>Potato Early Blight</i>	87%	93%	90%
<i>Potato Healthy</i>	50%	83%	62%
<i>Potato Late Blight</i>	90%	61%	73%

Dan dari *confusion matrix* tersebut, didapatkan nilai *accuracy* pada *stage* kedua tanaman kentang dengan pembagian rasio data 70:30 serta *multi stage classification* adalah sebesar 76%. Selanjutnya, dilakukan pelatihan untuk *stage* kedua pada penyakit tanaman padi yang terdiri dari 210 data latih dan 90 data uji. Hasil dari klasifikasi *Convolutional Neural Network* menggunakan rasio perbandingan data sebesar 70:30 adalah sebagai berikut.



Gambar 4.17 Grafik Cost Proses Training Model 4 Stage 2 Penyakit Tanaman Padi

Gambar 4.17 menunjukkan grafik proses *training* untuk skenario 70:30 *multi stage classification*. Dari proses *training* mendapatkan nilai *Cost* sebesar 0,32039 dan akurasi sebesar 77,76%.



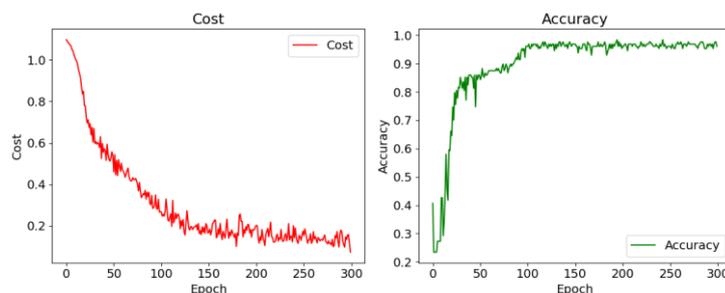
Gambar 4.18 Hasil Prediksi Data dengan Rasio 70:30 pada 3 Kelas Penyakit Tanaman Padi

Mengacu pada Gambar 4.18 menunjukkan hasil *confussion matrix* pada data *testing* berhasil memprediksi kelas dengan benar sebanyak 63 data dan gagal memprediksi kelas dengan benar sebanyak 27 data. Berikut adalah nilai-nilai yang dihitung untuk presisi (*precision*), *recall*, dan *F1-Score* dari *confussion matrix* multi-kelas untuk 3 kategori jenis penyakit tanaman yang diidentifikasi berdasarkan citra daun, dengan menggunakan Persamaan 4.1, 4.2, 4.3, dan 4.4 maka hasil disajikan pada Tabel 4.9.

Tabel 4.9 *Score Precision, Recall, F1-Score* pada 3 Kelas Penyakit Tanaman Padi

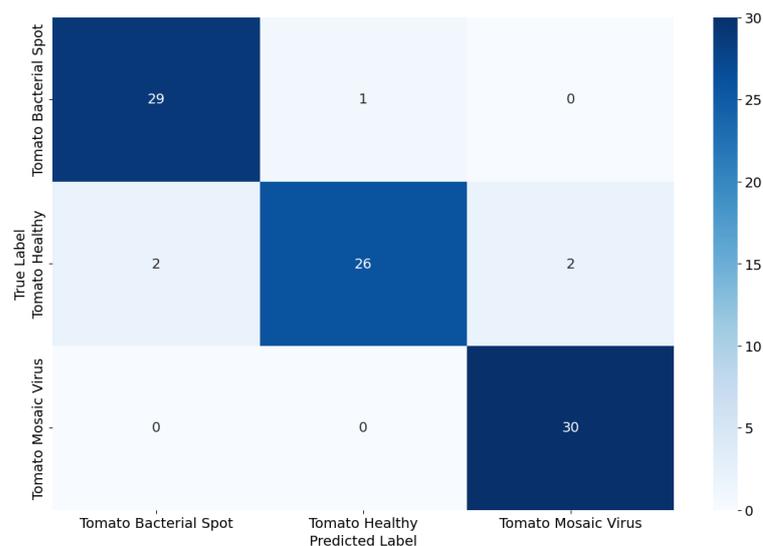
Kelas Jenis Penyakit	<i>Confussion matrix</i>		
	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
<i>Rice Brown Spot</i>	13%	100%	24%
<i>Rice Healthy</i>	100%	55%	71%
<i>Rice Scald</i>	97%	94%	95%

Dan dari *confussion matrix* tersebut, didapatkan nilai *accuracy* pada *stage* kedua tanaman padi dengan pembagian rasio data 70:30 serta *multi stage classification* adalah sebesar 70%. Selanjutnya, dilakukan pelatihan untuk *stage* kedua pada penyakit tanaman Tomat yang terdiri dari 210 data latih dan 90 data uji. Hasil dari klasifikasi *Convolutional Neural Network* menggunakan rasio perbandingan data sebesar 70:30 adalah sebagai berikut.



Gambar 4.19 Grafik Cost Proses Training Model 4 Stage 2 Penyakit Tanaman Tomat

Gambar 4.19 menunjukkan grafik proses *training* untuk skenario 70:30 *multi stage classification*. Dari proses *training* mendapatkan nilai *Cost* sebesar 0,07269 dan akurasi sebesar 96,09%.



Gambar 4.20 Hasil Prediksi Data dengan Rasio 70:30 pada 3 Kelas Penyakit Tanaman Tomat

Mengacu pada Gambar 4.20 menunjukkan hasil *confussion matrix* pada data *testing* berhasil memprediksi kelas dengan benar sebanyak 85 data dan gagal memprediksi kelas dengan benar sebanyak 5 data. Berikut adalah nilai-nilai yang dihitung untuk presisi (*precision*), *recall*, dan *F1-Score* dari *confussion matrix* multi-kelas untuk 3 kategori jenis penyakit tanaman yang diidentifikasi berdasarkan citra daun, dengan menggunakan Persamaan 4.1, 4.2, 4.3, dan maka hasil disajikan pada Tabel 4.10.

Tabel 4.10 *Score Precision, Recall, F1-Score* pada 3 Kelas Penyakit Tanaman Tomat

Kelas Jenis Penyakit	<i>Confussion matrix</i>		
	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
<i>Tomato Bacterial Spot</i>	97%	94%	95%
<i>Tomato Healthy</i>	87%	96%	91%

Kelas Jenis Penyakit	Confussion matrix		
	Precision	Recall	F1-Score
Tomato Mosaic Virus	100%	94%	97%

Dan dari *confussion matrix* tersebut, didapatkan nilai *accuracy* pada *stage* kedua tanaman tomat dengan pembagian rasio data 70:30 serta *multi stage classification* adalah sebesar 94%. Selanjutnya, setelah diketahui semua nilai dari setiap *stage*, maka selanjutnya adalah menggabungkan performa yang didapatkan dan memberikan nilai rata-rata dengan cara mengalikan antara *stage* ke-1 dan *stage* ke-2, dan hasilnya disajikan pada Tabel 4.11.

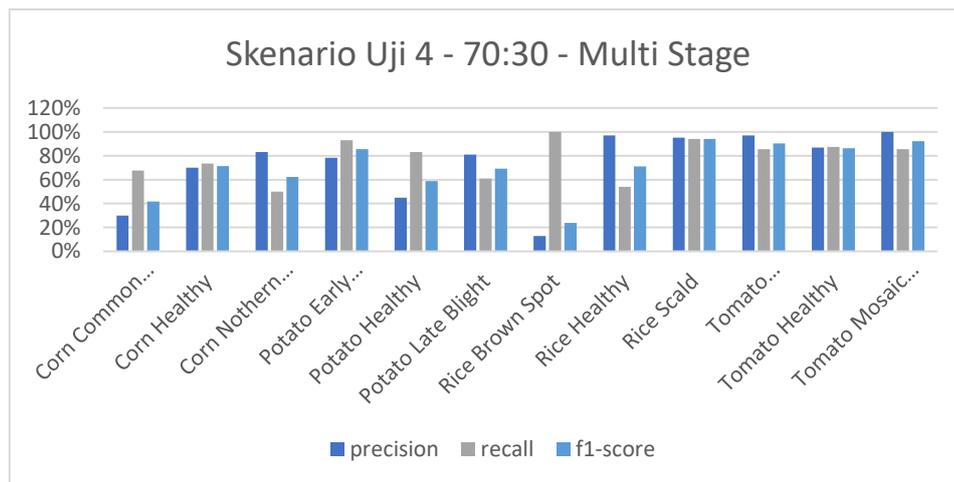
Tabel 4.11 Performa Hasil Uji dengan Metode Multi stage classification rasio data 70:30

Multi Stage Performa	Precision	Recall	F1-Score
Corn Common Rust	30%	68%	42%
Corn Healthy	70%	74%	71%
Corn Nothern Leaf Blight	83%	50%	62%
Potato Early Blight	78%	93%	86%
Potato Healthy	45%	83%	59%
Potato Late Blight	81%	61%	69%
Rice Brown Spot	13%	100%	24%
Rice Healthy	97%	54%	71%
Rice Scald	95%	94%	94%
Tomato Bacterial Spot	97%	86%	90%
Tomato Healthy	87%	87%	86%
Tomato Mosaic Virus	100%	86%	92%

Hasil dari tahap pertama dan tahap kedua tersebut, didapatkan nilai *accuracy* rata-rata sebesar 73%, dengan pembagian rasio data 70:30 serta *multi stage classification*. Sebelum dirata-rata, *accuracy* yang didapatkan setelah menggabungkan hasil tahap pertama dan tahap kedua secara berurutan adalah sebagai berikut. *Accuracy* penyakit tanaman jagung sebesar 59%, *accuracy*

penyakit tanaman kentang sebesar 74%, *accuracy* penyakit tanaman padi sebesar 68%, dan *accuracy* penyakit tanaman tomat sebesar 91%.

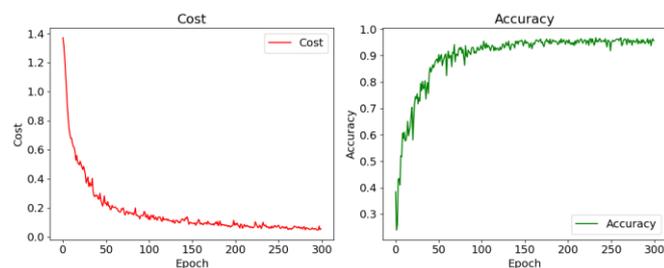
Dari Tabel 4.11 dapat diketahui visual performa model menggunakan metode *multi stage classification* adalah sebagai berikut:



Gambar 4.21 Visual Performa Skenario Uji Coba 4 Pembagian Data 70:30

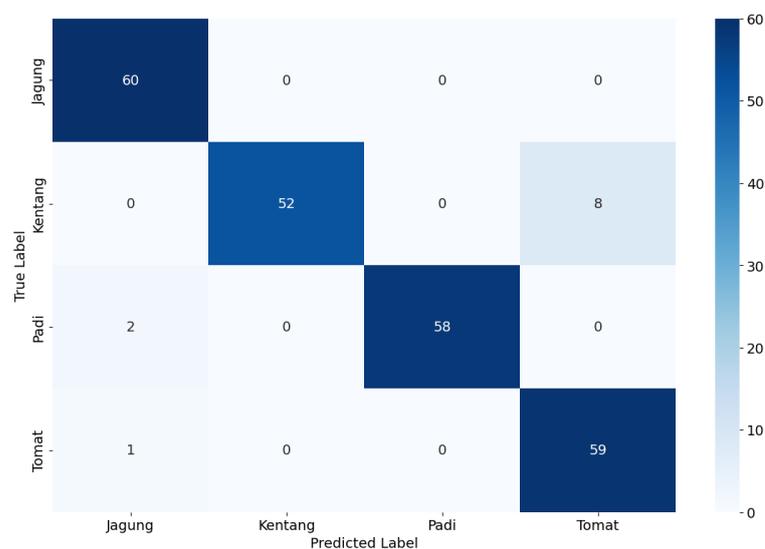
4.2.5 Skenario Uji 5

Skenario uji 5 dilakukan dengan metode *multi stage classification* serta rasio skenario pembagian data 80:20, stage pertama terdiri dari 960 data latih dan 240 data uji. Hasil dari klasifikasi *Convolutional Neural Network* menggunakan rasio perbandingan data sebesar 80:20 adalah sebagai berikut.



Gambar 4.22 Grafik Cost Proses Training Model 5 Stage 1

Gambar 4.22 menunjukkan grafik proses *training* untuk skenario 80:20 *multi stage classification*. Dari proses *training* mendapatkan nilai *Cost* sebesar 0,05439 dan akurasi sebesar 95,57%.



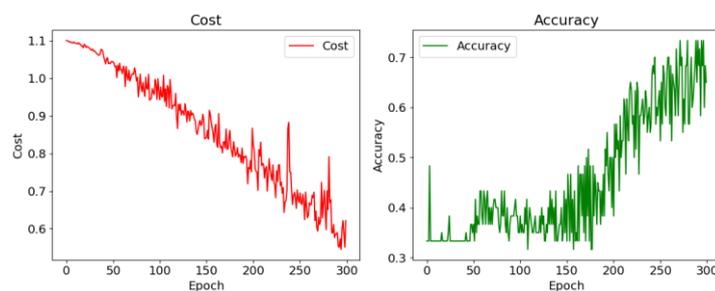
Gambar 4.23 Hasil Prediksi Data dengan Rasio 80:20 pada 4 Kelas

Mengacu pada Gambar 4.23 menunjukkan hasil *confussion matrix* pada data *testing* berhasil memprediksi kelas dengan benar sebanyak 229 data dan gagal memprediksi kelas dengan benar sebanyak 11 data. Berikut adalah nilai-nilai yang dihitung untuk presisi (*precision*), *recall*, dan *F1-Score* dari *confussion matrix* multi-kelas untuk 4 kategori jenis tanaman yang diidentifikasi berdasarkan citra daun, dengan menggunakan Persamaan 4.1, 4.2, 4.3, dan 4.4 maka hasil disajikan pada Tabel 4.12.

Tabel 4.12 *Score Precision, Recall, F1-Score* pada 4 Kelas Jenis Tanaman

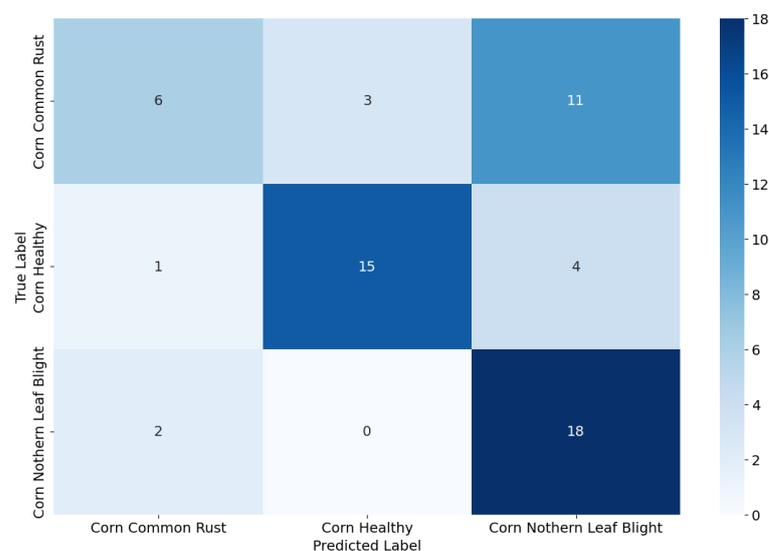
Kelas Jenis Penyakit	<i>Confussion matrix</i>		
	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
Jagung	100%	95%	98%
Kentang	87%	100%	93%
Padi	97%	100%	98%
Tomat	98%	88%	93%

Dan dari *confussion matrix* tersebut, didapatkan nilai *accuracy* pada skenario uji 5 *stage* pertama dengan pembagian rasio data 80:20 serta *multi stage classification* adalah sebesar 95%. Selanjutnya, dilakukan pelatihan untuk stage kedua pada penyakit tanaman jagung yang terdiri dari 240 data latih dan 60 data uji. Hasil dari klasifikasi *Convolutional Neural Network* menggunakan rasio perbandingan data sebesar 80:20 adalah sebagai berikut.



Gambar 4.24 Grafik Cost Proses Training Model 5 Stage 2 Penyakit Tanaman Jagung

Gambar 4.24 menunjukkan grafik proses *training* untuk skenario 80:20 *multi stage classification*. Dari proses *training* mendapatkan nilai *Cost* sebesar 0,62124 dan akurasi sebesar 65,00%.



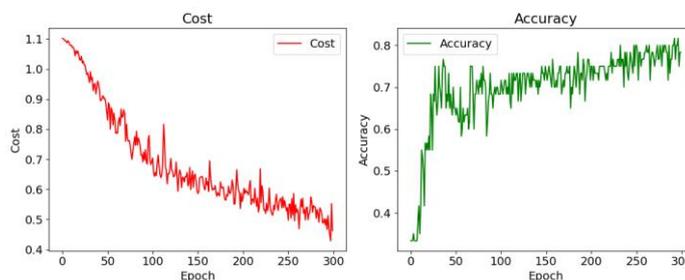
Gambar 4.25 Hasil Prediksi Data dengan Rasio 80:20 pada 3 Kelas Penyakit Tanaman Jagung

Mengacu pada Gambar 4.25 menunjukkan hasil *confussion matrix* pada data *testing* berhasil memprediksi kelas dengan benar sebanyak 39 data dan gagal memprediksi kelas dengan benar sebanyak 21 data. Berikut adalah nilai-nilai yang dihitung untuk presisi (*precision*), *recall*, dan *F1-Score* dari *confussion matrix* multi-kelas untuk 3 kategori jenis penyakit tanaman yang diidentifikasi berdasarkan citra daun, dengan menggunakan Persamaan 4.1, 4.2, 4.3, dan 4.4 maka hasil disajikan pada Tabel 4.13.

Tabel 4.13 *Score Precision, Recall, F1-Score* pada 3 Kelas Penyakit Tanaman Jagung

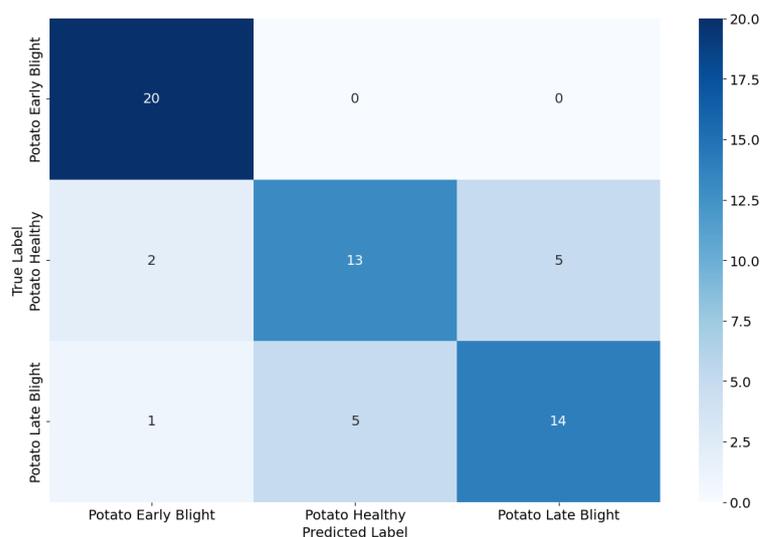
Kelas Jenis Penyakit	<i>Confussion matrix</i>		
	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
<i>Corn Common Rust</i>	30%	67%	41%
<i>Corn Healthy</i>	75%	83%	79%
<i>Corn Nothern Leaf Blight</i>	90%	55%	68%

Dan dari *confussion matrix* tersebut, didapatkan nilai *accuracy* pada *stage* kedua tanaman jagung dengan pembagian rasio data 80:20 serta *multi stage classification* adalah sebesar 65%. Selanjutnya, dilakukan pelatihan untuk *stage* kedua pada penyakit tanaman kentang yang terdiri dari 240 data latih dan 60 data uji. Hasil dari klasifikasi *Convolutional Neural Network* menggunakan rasio perbandingan data sebesar 80:20 adalah sebagai berikut.



Gambar 4.26 Grafik Cost Proses Training Model 5 Stage 2 Penyakit Tanaman Kentang

Gambar 4.26 menunjukkan grafik proses *training* untuk skenario 80:20 *multi stage classification*. Dari proses *training* mendapatkan nilai *cost* sebesar 0,46297 dan akurasi sebesar 78,33%.



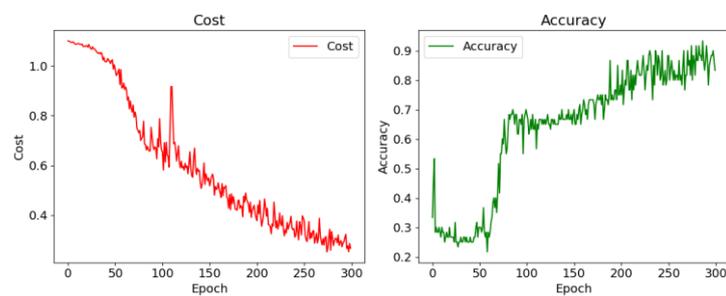
Gambar 4.27 Hasil Prediksi Data dengan Rasio 80:20 pada 3 Kelas Penyakit Tanaman Kentang

Mengacu pada Gambar 4.27 menunjukkan hasil *confussion matrix* pada data *testing* berhasil memprediksi kelas dengan benar sebanyak 47 data dan gagal memprediksi kelas dengan benar sebanyak 13 data. Berikut adalah nilai-nilai yang dihitung untuk presisi (*precision*), *recall*, dan *F1-Score* dari *confussion matrix* multi-kelas untuk 3 kategori jenis penyakit tanaman yang diidentifikasi berdasarkan citra daun, dengan menggunakan Persamaan 4.1, 4.2, 4.3, dan 4.4 maka hasil disajikan pada Tabel 4.14.

Tabel 4.14 *Score Precision, Recall, F1-Score* pada 3 Kelas Penyakit Tanaman Kentang

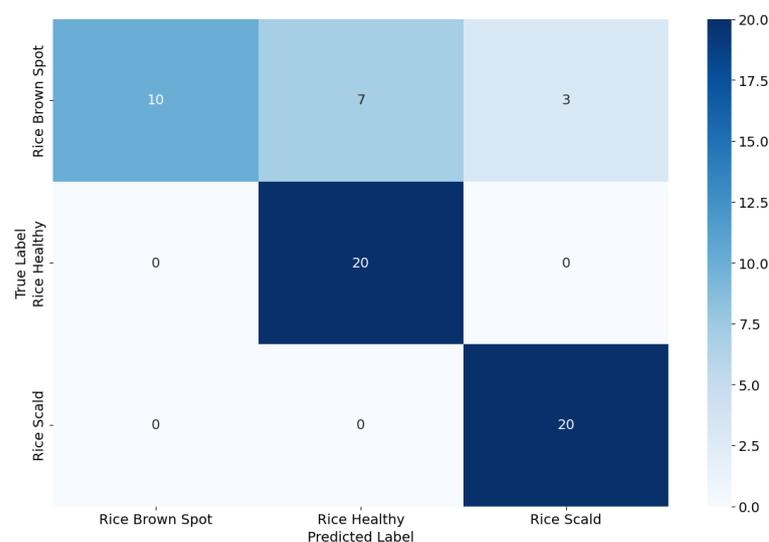
Kelas Jenis Penyakit	<i>Confussion matrix</i>		
	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
<i>Potato Early Blight</i>	100%	87%	93%
<i>Potato Healthy</i>	65%	72%	68%
<i>Potato Late Blight</i>	70%	74%	72%

Dan dari *confusion matrix* tersebut, didapatkan nilai *accuracy* pada *stage* kedua tanaman kentang dengan pembagian rasio data 80:20 serta *multi stage classification* adalah sebesar 78%. Selanjutnya, dilakukan pelatihan untuk *stage* kedua pada penyakit tanaman padi yang terdiri dari 240 data latih dan 60 data uji. Hasil dari klasifikasi *Convolutional Neural Network* menggunakan rasio perbandingan data sebesar 80:20 adalah sebagai berikut.



Gambar 4.28 Grafik Cost Proses Training Model 5 Stage 2 Penyakit Tanaman Padi

Gambar 4.28 menunjukkan grafik proses *training* untuk skenario 80:20 *multi stage classification*. Dari proses *training* mendapatkan nilai *cost* sebesar 0,26681 dan akurasi sebesar 83,33%.



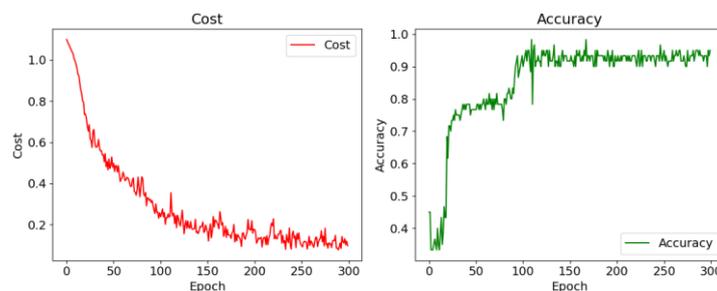
Gambar 4.29 Hasil Prediksi Data dengan Rasio 80:20 pada 3 Kelas Penyakit Tanaman Padi

Mengacu pada Gambar 4.29 menunjukkan hasil *confussion matrix* pada data *testing* berhasil memprediksi kelas dengan benar sebanyak 50 data dan gagal memprediksi kelas dengan benar sebanyak 10 data. Berikut adalah nilai-nilai yang dihitung untuk presisi (*precision*), *recall*, dan *F1-Score* dari *confussion matrix* multi-kelas untuk 3 kategori jenis penyakit tanaman yang diidentifikasi berdasarkan citra daun, dengan menggunakan Persamaan 4.1, 4.2, 4.3, dan 4.4 maka hasil disajikan pada Tabel 4.9.

Tabel 4.15 *Score Precision, Recall, F1-Score* pada 3 Kelas Penyakit Tanaman Padi

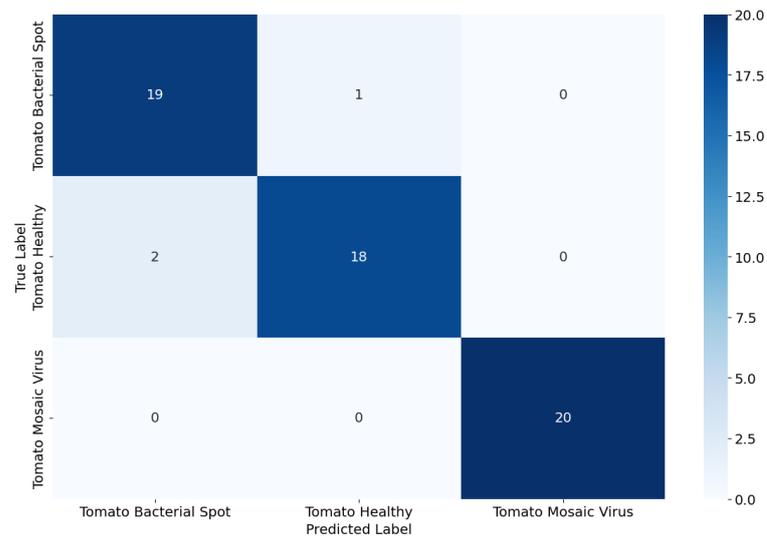
Kelas Jenis Penyakit	<i>Confussion matrix</i>		
	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
<i>Rice Brown Spot</i>	50%	100%	67%
<i>Rice Healthy</i>	100%	74%	85%
<i>Rice Scald</i>	100%	87%	93%

Dan dari *confussion matrix* tersebut, didapatkan nilai *accuracy* pada *stage* kedua tanaman padi dengan pembagian rasio data 80:20 serta *multi stage classification* adalah sebesar 83%. Selanjutnya, dilakukan pelatihan untuk *stage* kedua pada penyakit tanaman Tomat yang terdiri dari 240 data latih dan 60 data uji. Hasil dari klasifikasi *Convolutional Neural Network* menggunakan rasio perbandingan data sebesar 80:20 adalah sebagai berikut.



Gambar 4.30 Grafik Cost Proses Training Model 5 Stage 2 Penyakit Tanaman Tomat

Gambar 4.30 menunjukkan grafik proses *training* untuk skenario 80:20 *multi stage classification*. Dari proses *training* mendapatkan nilai *cost* sebesar 0,09744 dan akurasi sebesar 95,00%.



Gambar 4.31 Hasil Prediksi Data dengan Rasio 80:20 pada 3 Kelas Penyakit Tanaman Tomat

Mengacu pada Gambar 4.31 menunjukkan hasil *confusion matrix* pada data *testing* berhasil memprediksi kelas dengan benar sebanyak 57 data dan gagal memprediksi kelas dengan benar sebanyak 3 data. Berikut adalah nilai-nilai yang dihitung untuk presisi (*precision*), *recall*, dan *F1-Score* dari *confusion matrix* multi-kelas untuk 3 kategori jenis penyakit tanaman yang diidentifikasi berdasarkan citra daun, dengan menggunakan Persamaan 4.1, 4.2, 4.3, dan 4.4 maka hasil disajikan pada Tabel 4.16.

Tabel 4.16 *Score Precision, Recall, F1-Score* pada 3 Kelas Penyakit Tanaman Tomat

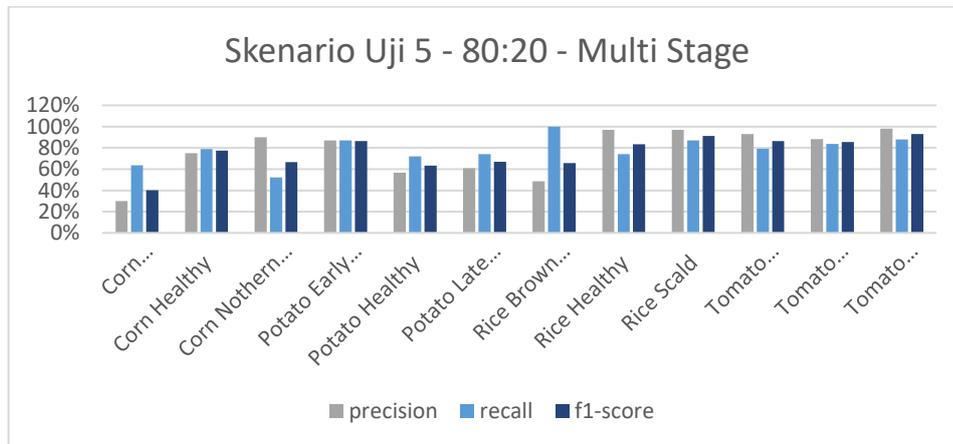
Kelas Jenis Penyakit	<i>Confusion matrix</i>		
	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
<i>Tomato Bacterial Spot</i>	95%	90%	93%
<i>Tomato Healthy</i>	90%	95%	92%
<i>Tomato Mosaic Virus</i>	100%	100%	100%

Dan dari *confussion matrix* tersebut, didapatkan nilai *accuracy* pada *stage* kedua tanaman tomat dengan pembagian rasio data 80:20 serta *multi stage classification* adalah sebesar 95%. Setelah diketahui semua nilai dari setiap *stage*, maka selanjutnya adalah menggabungkan performa yang didapatkan dan memberikan nilai rata-rata dengan cara mengalikan antara *stage* ke-1 dan *stage* ke-2, dan hasilnya disajikan pada Tabel 4.17.

Tabel 4.17 Performa Hasil Uji dengan Metode Multi stage classification rasio data 80:20

Multi Stage Performa	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
<i>Corn Common Rust</i>	30%	64%	40%
<i>Corn Healthy</i>	75%	79%	77%
<i>Corn Nothern Leaf Blight</i>	90%	52%	67%
<i>Potato Early Blight</i>	87%	87%	86%
<i>Potato Healthy</i>	57%	72%	63%
<i>Potato Late Blight</i>	61%	74%	67%
<i>Rice Brown Spot</i>	49%	100%	66%
<i>Rice Healthy</i>	97%	74%	83%
<i>Rice Scald</i>	97%	87%	91%
<i>Tomato Bacterial Spot</i>	93%	79%	86%
<i>Tomato Healthy</i>	88%	84%	86%
<i>Tomato Mosaic Virus</i>	98%	88%	93%

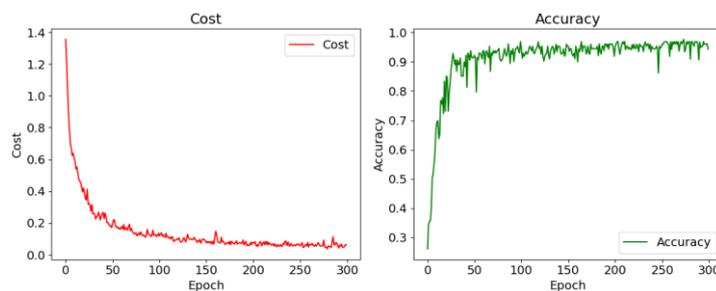
Hasil dari tahap pertama dan tahap kedua tersebut, didapatkan nilai *accuracy* rata-rata sebesar 76%, dengan pembagian rasio data 80:20 serta *multi stage classification*. Sebelum dirata-rata, *accuracy* yang didapatkan setelah menggabungkan hasil tahap pertama dan tahap kedua secara berurutan adalah sebagai berikut. *Accuracy* penyakit tanaman jagung sebesar 62%, *accuracy* penyakit tanaman kentang sebesar 74%, *accuracy* penyakit tanaman padi sebesar 79%, dan *accuracy* penyakit tanaman tomat sebesar 90%.



Gambar 4.32 Visual Performa Skenario Uji Coba 5 Pembagian Data 80:20

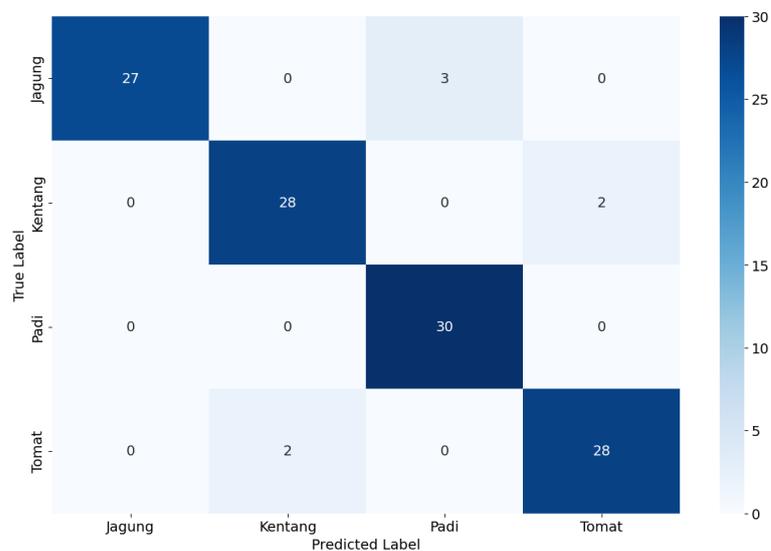
4.2.6 Skenario Uji 6

Skenario uji 6 dilakukan dengan metode *multi stage classification* serta rasio skenario pembagian data 90:10, stage pertama terdiri dari 1080 data latih dan 120 data uji. Hasil dari klasifikasi *Convolutional Neural Network* menggunakan rasio perbandingan data sebesar 90:10 adalah sebagai berikut.



Gambar 4.33 Grafik Cost Proses Training Model 6 Stage 1

Gambar 4.33 menunjukkan grafik proses *training* untuk skenario 90:10 *multi stage classification*. Dari proses *training* mendapatkan nilai *cost* sebesar 0,06196 dan akurasi sebesar 94,30%.



Gambar 4.34 Hasil Prediksi Data dengan Rasio 90:10 pada 4 Kelas

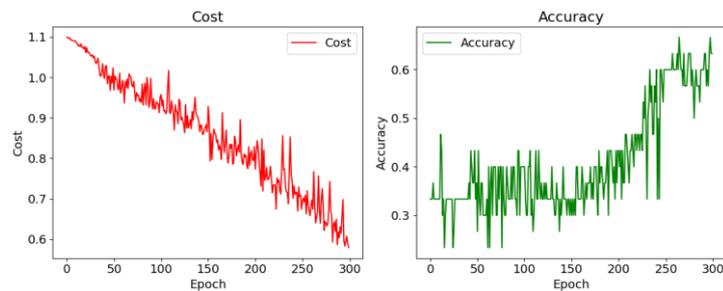
Mengacu pada Gambar 4.34 menunjukkan hasil *confusion matrix* pada data *testing* berhasil memprediksi kelas dengan benar sebanyak 113 data dan gagal memprediksi kelas dengan benar sebanyak 7 data. Berikut adalah nilai-nilai yang dihitung untuk presisi (*precision*), *recall*, dan *F1-Score* dari *confusion matrix* multi-kelas untuk 4 kategori jenis tanaman yang diidentifikasi berdasarkan citra daun, dengan menggunakan Persamaan 4.1, 4.2, 4.3, dan 4.4 maka hasil disajikan pada Tabel 4.18.

Tabel 4.18 *Score Precision, Recall, F1-Score* pada 4 Kelas Jenis Tanaman

Kelas Jenis Penyakit	<i>Confusion matrix</i>		
	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
Jagung	90%	100%	95%
Kentang	93%	93%	93%
Padi	100%	91%	95%
Tomat	93%	93%	93%

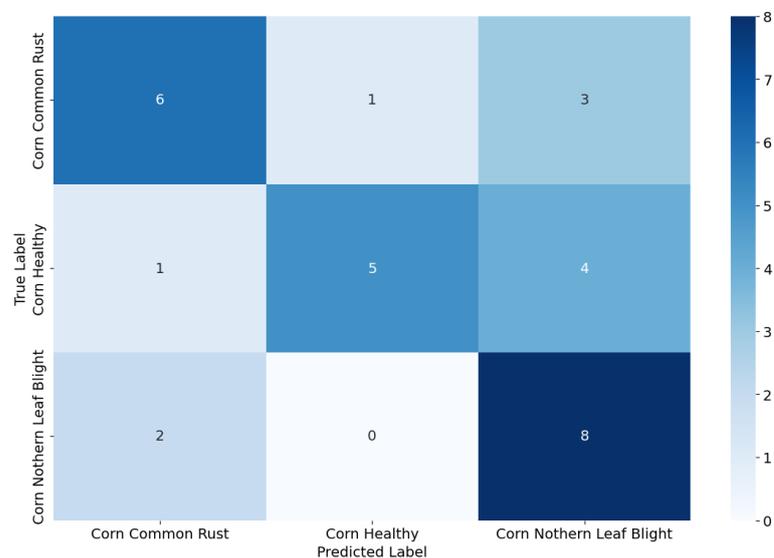
Dan dari *confusion matrix* tersebut, didapatkan nilai *accuracy* pada skenario uji 6 *stage* pertama dengan pembagian rasio data 90:10 serta *multi stage classification* adalah sebesar 94%. Selanjutnya, dilakukan pelatihan untuk *stage*

kedua pada penyakit tanaman jagung yang terdiri dari 270 data latih dan 30 data uji. Hasil dari klasifikasi *Convolutional Neural Network* menggunakan rasio perbandingan data sebesar 90:10 adalah sebagai berikut.



Gambar 4.35 Grafik Cost Proses Training Model 6 Stage 2 Penyakit Tanaman Jagung

Gambar 4.35 menunjukkan grafik proses *training* untuk skenario 90:10 *multi stage classification*. Dari proses *training* mendapatkan nilai *cost* sebesar 0,57911 dan akurasi sebesar 63,33%.



Gambar 4.36 Hasil Prediksi Data dengan Rasio 90:0 pada 3 Kelas Penyakit Tanaman Jagung

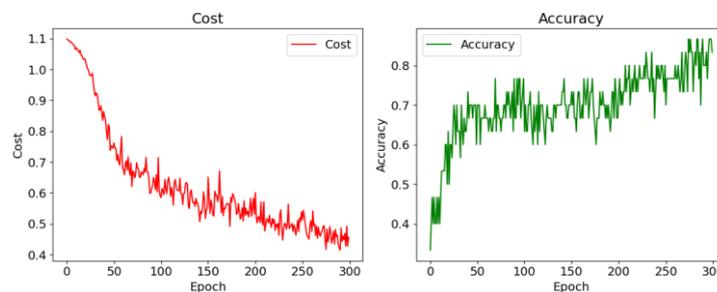
Mengacu pada Gambar 4.36 menunjukkan hasil *confusion matrix* pada data *testing* berhasil memprediksi kelas dengan benar sebanyak 19 data dan gagal

memprediksi kelas dengan benar sebanyak 11 data. Berikut adalah nilai-nilai yang dihitung untuk presisi (*precision*), *recall*, dan *F1-Score* dari *confussion matrix* multi-kelas untuk 3 kategori jenis penyakit tanaman yang diidentifikasi berdasarkan citra daun, dengan menggunakan Persamaan 4.1, 4.2, 4.3, dan 4.4 maka hasil disajikan pada Tabel 4.19.

Tabel 4.19 *Score Precision, Recall, F1-Score* pada 3 Kelas Penyakit Tanaman Jagung

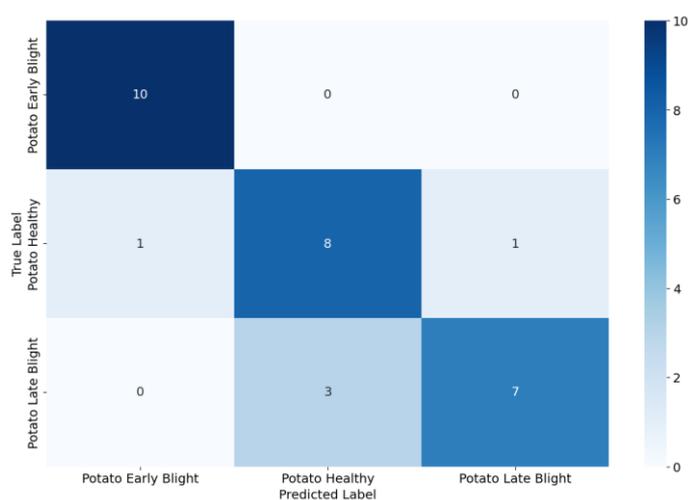
Kelas Jenis Penyakit	<i>Confussion matrix</i>		
	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
<i>Corn Common Rust</i>	60%	67%	63%
<i>Corn Healthy</i>	50%	83%	62%
<i>Corn Nothern Leaf Blight</i>	80%	53%	64%

Dan dari *confussion matrix* tersebut, didapatkan nilai *accuracy* pada *stage* kedua tanaman jagung dengan pembagian rasio data 90:10 serta *multi stage classification* adalah sebesar 63%. Selanjutnya, dilakukan pelatihan untuk *stage* kedua pada penyakit tanaman kentang yang terdiri dari 270 data latih dan 30 data uji. Hasil dari klasifikasi *Convolutional Neural Network* menggunakan rasio perbandingan data sebesar 90:10 adalah sebagai berikut.



Gambar 4.37 Grafik Cost Proses Training Model 6 Stage 2 Penyakit Tanaman Kentang

Gambar 4.37 menunjukkan grafik proses *training* untuk skenario 90:10 *multi stage classification*. Dari proses *training* mendapatkan nilai *cost* sebesar 0,45671 dan akurasi sebesar 83,33%.



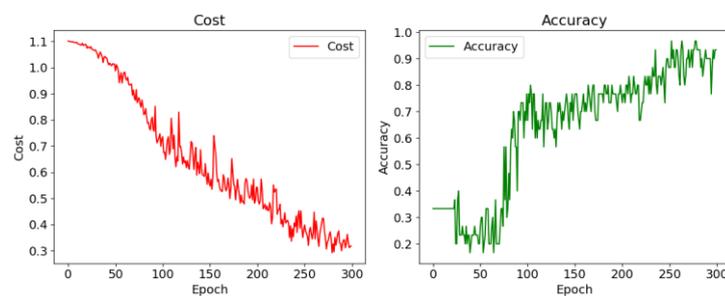
Gambar 4.38 Hasil Prediksi Data dengan Rasio 90:10 pada 3 Kelas Penyakit Tanaman Kentang

Mengacu pada Gambar 4.38 menunjukkan hasil *confusion matrix* pada data *testing* berhasil memprediksi kelas dengan benar sebanyak 225 data dan gagal memprediksi kelas dengan benar sebanyak 5 data. Berikut adalah nilai-nilai yang dihitung untuk presisi (*precision*), *recall*, dan *F1-Score* dari *confusion matrix* multi-kelas untuk 3 kategori jenis penyakit tanaman yang diidentifikasi berdasarkan citra daun, dengan menggunakan Persamaan 4.1, 4.2, 4.3, dan 4.4 maka hasil disajikan pada Tabel 4.20.

Tabel 4.20 *Score Precision, Recall, F1-Score* pada 3 Kelas Penyakit Tanaman Kentang

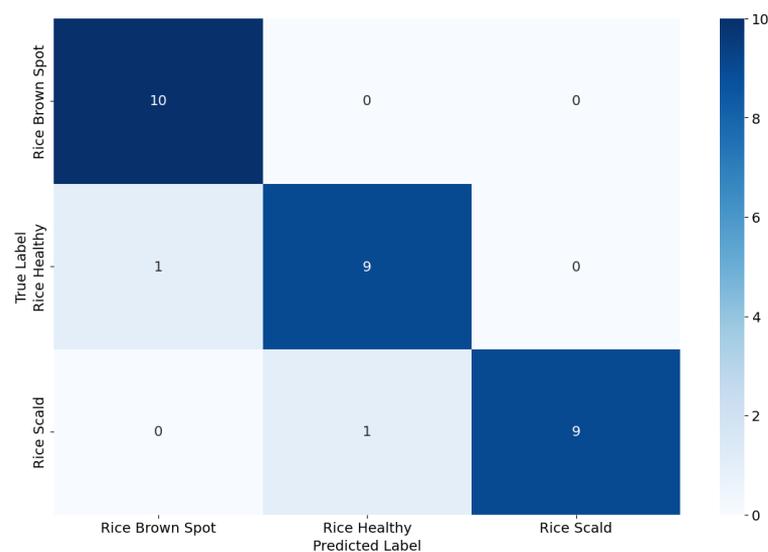
Kelas Jenis Penyakit	<i>Confusion matrix</i>		
	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
<i>Potato Early Blight</i>	100%	91%	95%
<i>Potato Healthy</i>	80%	73%	76%
<i>Potato Late Blight</i>	70%	88%	78%

Dan dari *confusion matrix* tersebut, didapatkan nilai *accuracy* pada *stage* kedua tanaman kentang dengan pembagian rasio data 90:10 serta *multi stage classification* adalah sebesar 83%. Selanjutnya, dilakukan pelatihan untuk *stage* kedua pada penyakit tanaman padi yang terdiri dari 270 data latih dan 30 data uji. Hasil dari klasifikasi *Convolutional Neural Network* menggunakan rasio perbandingan data sebesar 90:10 adalah sebagai berikut.



Gambar 4.39 Grafik Cost Proses Training Model 6 Stage 2 Penyakit Tanaman Padi

Gambar 4.39 menunjukkan grafik proses *training* untuk skenario 90:10 *multi stage classification*. Dari proses *training* mendapatkan nilai *cost* sebesar 0,31854 dan akurasi sebesar 93,33%.



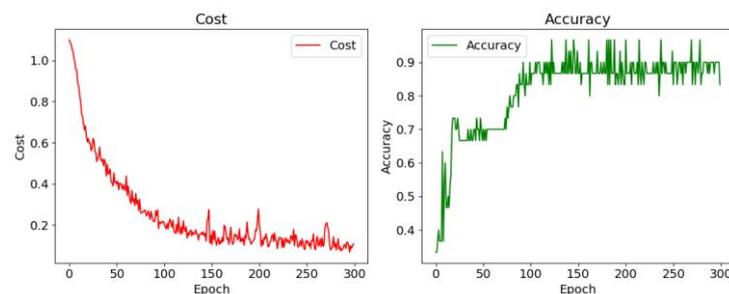
Gambar 4.40 Hasil Prediksi Data dengan Rasio 90:10 pada 3 Kelas Penyakit Tanaman Padi

Mengacu pada Gambar 4.40 menunjukkan hasil *confussion matrix* pada data *testing* berhasil memprediksi kelas dengan benar sebanyak 28 data dan gagal memprediksi kelas dengan benar sebanyak 2 data. Berikut adalah nilai-nilai yang dihitung untuk presisi (*precision*), *recall*, dan *F1-Score* dari *confussion matrix* multi-kelas untuk 3 kategori jenis penyakit tanaman yang diidentifikasi berdasarkan citra daun, dengan menggunakan Persamaan 4.1, 4.2, 4.3, dan 4.4 maka hasil disajikan pada Tabel 4.21.

Tabel 4.21 *Score Precision, Recall, F1-Score* pada 3 Kelas Penyakit Tanaman Padi

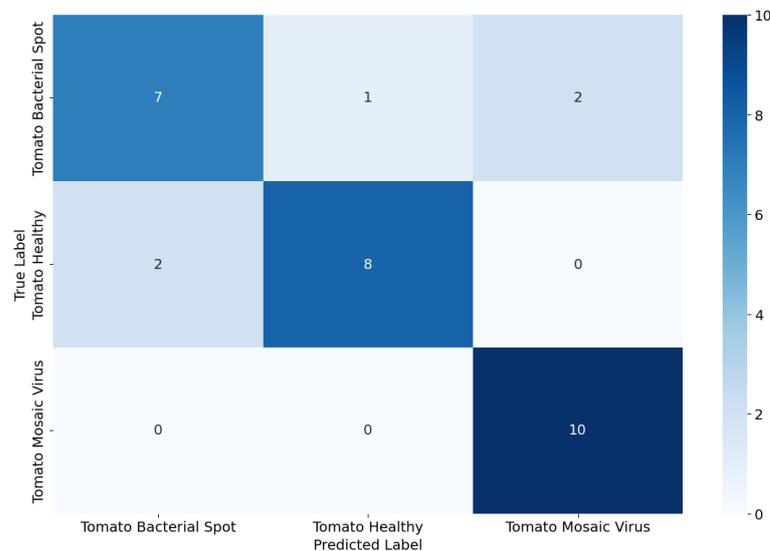
Kelas Jenis Penyakit	<i>Confussion matrix</i>		
	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
<i>Rice Brown Spot</i>	100%	91%	95%
<i>Rice Healthy</i>	90%	90%	90%
<i>Rice Scald</i>	90%	100%	95%

Dan dari *confussion matrix* tersebut, didapatkan nilai *accuracy* pada *stage* kedua tanaman padi dengan pembagian rasio data 90:10 serta *multi stage classification* adalah sebesar 93%. Selanjutnya, dilakukan pelatihan untuk *stage* kedua pada penyakit tanaman Tomat yang terdiri dari 270 data latih dan 30 data uji. Hasil dari klasifikasi *Convolutional Neural Network* menggunakan rasio perbandingan data sebesar 90:10 adalah sebagai berikut.



Gambar 4.41 Grafik Cost Proses Training Model 6 Stage 2 Penyakit Tanaman Tomat

Gambar 4.41 menunjukkan grafik proses *training* untuk skenario 90:10 *multi stage classification*. Dari proses *training* mendapatkan nilai *cost* sebesar 0,10825 dan akurasi sebesar 83,33%.



Gambar 4.42 Hasil Prediksi Data dengan Rasio 90:10 pada 3 Kelas Penyakit Tanaman Tomat

Mengacu pada Gambar 4.42 menunjukkan hasil *confussion matrix* pada data *testing* berhasil memprediksi kelas dengan benar sebanyak 25 data dan gagal memprediksi kelas dengan benar sebanyak 5 data. Berikut adalah nilai-nilai yang dihitung untuk presisi (*precision*), *recall*, dan *F1-Score* dari *confussion matrix* multi-kelas untuk 3 kategori jenis penyakit tanaman yang diidentifikasi berdasarkan citra daun, dengan menggunakan Persamaan 4.1, 4.2, 4.3, dan 4.4 maka hasil disajikan pada Tabel 4.22.

Tabel 4. 22 Score Precision, Recall, F1-Score pada 3 Kelas Penyakit Tanaman Tomat

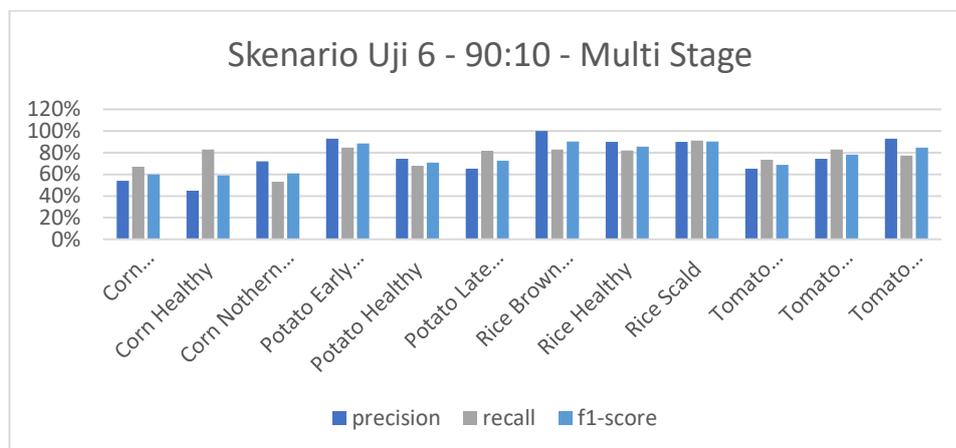
Kelas Jenis Penyakit	Confussion matrix		
	Precision	Recall	F1-Score
Tomato Bacterial Spot	70%	78%	74%
Tomato Healthy	80%	89%	84%
Tomato Mosaic Virus	100%	83%	91%

Dan dari *confussion matrix* tersebut, didapatkan nilai *accuracy* pada *stage* kedua tanaman tomat dengan pembagian rasio data 90:10 serta *multi stage classification* adalah sebesar 83%. Setelah diketahui semua nilai dari setiap *stage*, maka selanjutnya adalah menggabungkan performa yang didapatkan dan memberikan nilai rata-rata dengan cara mengalikan antara *stage* ke-1 dan *stage* ke-2, dan hasilnya disajikan pada Tabel 4.23.

Tabel 4.23 Performa Hasil Uji dengan Metode Multi stage classification rasio data 90:10

Multi Stage Performa	Precision	Recall	F1-Score
<i>Corn Common Rust</i>	54%	67%	60%
<i>Corn Healthy</i>	45%	83%	59%
<i>Corn Nothern Leaf Blight</i>	72%	53%	61%
<i>Potato Early Blight</i>	93%	85%	88%
<i>Potato Healthy</i>	74%	68%	71%
<i>Potato Late Blight</i>	65%	82%	73%
<i>Rice Brown Spot</i>	100%	83%	90%
<i>Rice Healthy</i>	90%	82%	86%
<i>Rice Scald</i>	90%	91%	90%
<i>Tomato Bacterial Spot</i>	65%	73%	69%
<i>Tomato Healthy</i>	74%	83%	78%
<i>Tomato Mosaic Virus</i>	93%	77%	85%

Hasil dari tahap pertama dan tahap kedua tersebut, didapatkan nilai *accuracy* rata-rata sebesar 76%, dengan pembagian rasio data 90:10 serta *multi stage classification*. Sebelum dirata-rata, *accuracy* yang didapatkan setelah menggabungkan hasil tahap pertama dan tahap kedua secara berurutan adalah sebagai berikut. *Accuracy* penyakit tanaman jagung sebesar 59%, *accuracy* penyakit tanaman kentang sebesar 78%, *accuracy* penyakit tanaman padi sebesar 87%, dan *accuracy* penyakit tanaman tomat sebesar 78%.



Gambar 4.43 Visual Performa Skenario Uji Coba 6 Pembagian Data 90:10

4.3 Pembahasan

Berdasarkan hasil uji coba yang dilakukan, terdapat enam skenario pengujian yang dengan menggunakan pembagian rasio data yang berukuran 70:30, 80:20, dan 90:10. Selain itu juga digunakan metode *single stage classification* dan *multi stage classification*. Pembagian data dilakukan secara manual dengan proporsi tertentu untuk data latih dan data uji sesuai dengan skenario yang ditentukan. Setelah *dataset* dipisahkan, data latih digunakan untuk melatih model, sementara data uji digunakan untuk menguji performa model.

Terdapat enam skenario pengujian yang menggunakan pembagian data berbeda, yakni 70:30, 80:20, dan 90:10 serta *single stage classification* dan *multi stage classification*. Pembagian data dilakukan secara manual dengan proporsi tertentu untuk data latih dan data uji sesuai dengan skenario yang ditentukan. Setelah *dataset* dipisahkan, data latih digunakan untuk melatih model, sementara data uji digunakan untuk menguji performa model.

Tabel 4.24 Performa kelas a) Jagung, b) Kentang, c) Padi, dan d) Tomat skenario uji pertama

Jagung				Kentang			
Jenis Penyakit	precision	recall	F1-Score	Jenis Penyakit	precision	recall	F1-Score
Corn Common Rust	20%	67%	31%	Potato Early Blight	87%	84%	85%
Corn Healthy	90%	68%	77%	Potato Healthy	53%	80%	64%
Corn Nothern Leaf Blight	83%	58%	68%	Potato Late Blight	63%	58%	60%

(a) (b)

Padi				Tomat			
Jenis Penyakit	precision	recall	F1-Score	Jenis Penyakit	precision	recall	F1-Score
Rice Brown Spot	27%	100%	42%	Tomato Bacterial Spot	90%	96%	93%
Rice Healthy	93%	78%	85%	Tomato Healthy	97%	85%	91%
Rice Scald	97%	67%	79%	Tomato Mosaic Virus	93%	80%	86%

(c) (d)

Pada Tabel 4.24 dapat dilihat bahwa evaluasi performa pada hasil skenario uji pertama untuk pembagian rasio data 70:30 dengan menggunakan *single stage classification*, kelas *potato early blight*, *rice healthy*, *rice scald*, *tomato bacterial spot*, *tomato healthy* dan *tomato mosaic virus* memiliki performa yang lebih baik dibandingkan kelas yang lainnya sehingga memiliki nilai *F1-Score* yang tinggi. Disisi lain kelas *corn common rust* dan *rice brown spot* menunjukkan hasil performa yang kurang baik dibandingkan kelas yang lainnya, sehingga hanya mendapatkan nilai *F1-Score* paling kecil. Namun secara keseluruhan nilai rata-rata *accuracy* 74%, *precision* 74%, *recall* 77% dan *F1-Score* 72% pada skenario uji pertama.

Tabel 4.25 Performa kelas a) Jagung, b) Kentang, c) Padi, dan d) Tomat skenario uji kedua

Jagung				Kentang			
Jenis Penyakit	precision	recall	F1-Score	Jenis Penyakit	precision	recall	F1-Score
Corn Common Rust	45%	60%	51%	Potato Early Blight	95%	100%	97%
Corn Healthy	70%	78%	74%	Potato Healthy	80%	76%	78%
Corn Nothern Leaf Blight	90%	60%	72%	Potato Late Blight	55%	69%	61%

(a) (b)

Padi			
Jenis Penyakit	precision	recall	F1-Score
Rice Brown Spot	60%	86%	71%
Rice Healthy	85%	100%	92%
Rice Scald	100%	77%	87%

(c)

Tomat			
Jenis Penyakit	precision	recall	F1-Score
Tomato Bacterial Spot	100%	83%	91%
Tomato Healthy	75%	100%	86%
Tomato Mosaic Virus	100%	80%	89%

(d)

Kemudian pada Tabel 4.25 menunjukkan evaluasi performa pada hasil skenario uji kedua untuk pembagian rasio data 80:20 dengan menggunakan *single stage classification* menunjukkan hasil yang baik, secara nilai *accuracy* 80%, *precision* 80%, *recall* 81% dan *F1-Score* 79%. Oleh karena itu, skenario uji kedua ini menjadi hasil terbaik dari rata-rata keseluruhan kelas pada dibandingkan skenario uji yang lain. Hal ini ditunjukkan dengan kelas *potato early blight*, *potato healthy*, *rice healthy*, *rice scald*, *tomato bacterial spot*, *tomato healthy* dan *tomato mosaic virus* memiliki performa yang lebih baik, sehingga memiliki nilai performa yang lebih tinggi dibandingkan skenario uji sebelumnya. Disisi lain kelas *corn common rust* masih tetap menunjukkan hasil performa yang kurang baik, namun masih menunjukkan peningkatan dibandingkan dengan skenario uji pertama.

Tabel 4.26 Performa kelas a) Jagung, b) Kentang, c) Padi, dan d) Tomat skenario uji ketiga

Jagung			
Jenis Penyakit	precision	recall	F1-Score
Corn Common Rust	10%	25%	14%
Corn Healthy	80%	80%	80%
Corn Northern Leaf Blight	90%	50%	64%

(a)

Kentang			
Jenis Penyakit	precision	recall	F1-Score
Potato Early Blight	90%	100%	95%
Potato Healthy	90%	75%	82%
Potato Late Blight	50%	83%	62%

(b)

Padi			
Jenis Penyakit	precision	recall	F1-Score
Rice Brown Spot	50%	100%	67%
Rice Healthy	100%	83%	91%
Rice Scald	100%	83%	91%

(c)

Tomat			
Jenis Penyakit	precision	recall	F1-Score
Tomato Bacterial Spot	90%	90%	90%
Tomato Healthy	90%	100%	95%
Tomato Mosaic Virus	100%	77%	87%

(d)

Selanjutnya dapat dilihat pada Tabel 4.26 diketahui evaluasi performa pada hasil skenario uji ketiga untuk pembagian rasio data 90:10 dengan menggunakan *single stage classification* menunjukkan hasil yang baik, secara keseluruhan nilai rata-rata *accuracy* 78%, *precision* 78%, *recall* 79% dan *F1-Score* 77. Skenario uji ketiga ini menjadi hasil terbaik jika dilihat pada performa setiap kelasnya dibandingkan dengan hasil skenario uji yang lain. Seperti yang telah penulis tunjukkan sebelumnya, hal ini dipengaruhi oleh kelas *corn healthy*, *potato early blight*, *potato healthy*, *rice healthy*, *ricel scald*, *tomato bacterial spot*, *tomato healthy* dan *tomato mosaic virus* yang memiliki performa yang lebih baik sehingga nilai performa yang sedikit lebih tinggi dibandingkan skenario uji sebelumnya. Disisi lain kelas *corn common rust* masih menunjukkan hasil yang kurang baik dan penurunan performa pada kelas tersebut.

Tabel 4.27 Performa kelas a) Jagung, b) Kentang, c) Padi, dan d) Tomat skenario uji keempat

Jagung			
Jenis Penyakit	precision	recall	F1-Score
Corn Common Rust	30%	68%	42%
Corn Healthy	70%	74%	71%
Corn Nothern Leaf Blight	83%	50%	62%

(a)

Kentang			
Jenis Penyakit	precision	recall	F1-Score
Potato Early Blight	78%	93%	86%
Potato Healthy	45%	83%	59%
Potato Late Blight	81%	61%	69%

(b)

Padi			
Jenis Penyakit	precision	recall	F1-Score
Rice Brown Spot	13%	100%	24%
Rice Healthy	97%	54%	71%
Rice Scald	95%	94%	94%

(c)

Tomat			
Jenis Penyakit	precision	recall	F1-Score
Tomato Bacterial Spot	97%	86%	90%
Tomato Healthy	87%	87%	86%
Tomato Mosaic Virus	100%	86%	92%

(d)

Kemudian pada Tabel 4.27 menunjukkan hasil yang kurang lebih hampir sama dengan hasil skenario uji pertama, hal ini dapat dilihat pada hasil skenario uji keempat yang menunjukkan bahwa evaluasi performa model untuk pembagian

rasio data 70:30 dengan menggunakan *multi stage classification*, pada kelas dengan performa terbaiknya yaitu *potato early blight*, *rice scald*, *tomato bacterial spot*, *tomato healthy* dan *tomato mosaic virus* memiliki performa dengan selisih yang tidak jauh dibandingkan hasil skenario uji pertama. Namun, pada skenario uji keempat ini kelas *corn common rust* dan *rice brown spot* juga menunjukkan hasil performa yang kurang baik dibandingkan kelas yang lainnya. Pada hasil skenario uji keempat ini, secara keseluruhan nilai rata-rata *accuracy* 73%, *precision* 73%, *recall* 78% dan *F1-Score* 71%.

Tabel 4.28 Performa kelas a) Jagung, b) Kentang, c) Padi, dan d) Tomat skenario uji kelima

Jagung			
Jenis Penyakit	precision	recall	F1-Score
Corn Common Rust	30%	64%	40%
Corn Healthy	75%	79%	77%
Corn Northern Leaf Blight	90%	52%	67%

(a)

Kentang			
Jenis Penyakit	precision	recall	F1-Score
Potato Early Blight	87%	87%	86%
Potato Healthy	57%	72%	63%
Potato Late Blight	61%	74%	67%

(b)

Padi			
Jenis Penyakit	precision	recall	F1-Score
Rice Brown Spot	49%	100%	66%
Rice Healthy	97%	74%	83%
Rice Scald	97%	87%	91%

(c)

Tomat			
Jenis Penyakit	precision	recall	F1-Score
Tomato Bacterial Spot	93%	79%	86%
Tomato Healthy	88%	84%	86%
Tomato Mosaic Virus	98%	88%	93%

(d)

Pada Tabel 4.28 menunjukkan evaluasi performa hasil skenario uji kelima untuk pembagian rasio data 80:20 dengan menggunakan *multi stage classification* menunjukkan hasil yang baik, secara keseluruhan nilai rata-rata *accuracy* 76%, *precision* 77%, *recall* 78% dan *F1-Score* 76%. Pada hasil skenario uji kelima ini memiliki performa yang paling baik diantara skenario uji lain yang menggunakan *multi stage classification*. Hal tersebut ditunjukkan dengan nilai performa yang ditunjukkan diatas. Performa setiap kelas juga tidak jauh berbeda dengan hasil skenario uji kedua, hanya ada selisih sedikit pada beberapa kelasnya, namun

skenario uji kelima ini masih dibawah skenario uji kedua. Kemudian untuk kelas *corn healthy*, *potato early blight*, *rice healthy*, *rice scald*, *tomato bacterial spot*, *tomato healthy* dan *tomato mosaic virus* memiliki performa sama baik dengan skenario uji kedua. Disisi lain kelas *corn common rust* tetap menunjukkan hasil performa yang kurang baik dan menunjukkan penurunan dibandingkan hasil skenario uji kedua.

Tabel 4.29 Performa kelas a) Jagung, b) Kentang, c) Padi, dan d) Tomat skenario uji keenam

Jagung			
Jenis Penyakit	precision	recall	F1-Score
Corn Common Rust	54%	67%	60%
Corn Healthy	45%	83%	59%
Corn Nothern Leaf Blight	72%	53%	61%

(a)

Kentang			
Jenis Penyakit	precision	recall	F1-Score
Potato Early Blight	93%	85%	88%
Potato Healthy	74%	68%	71%
Potato Late Blight	65%	82%	73%

(b)

Padi			
Jenis Penyakit	precision	recall	F1-Score
Rice Brown Spot	100%	83%	90%
Rice Healthy	90%	82%	86%
Rice Scald	90%	91%	90%

(c)

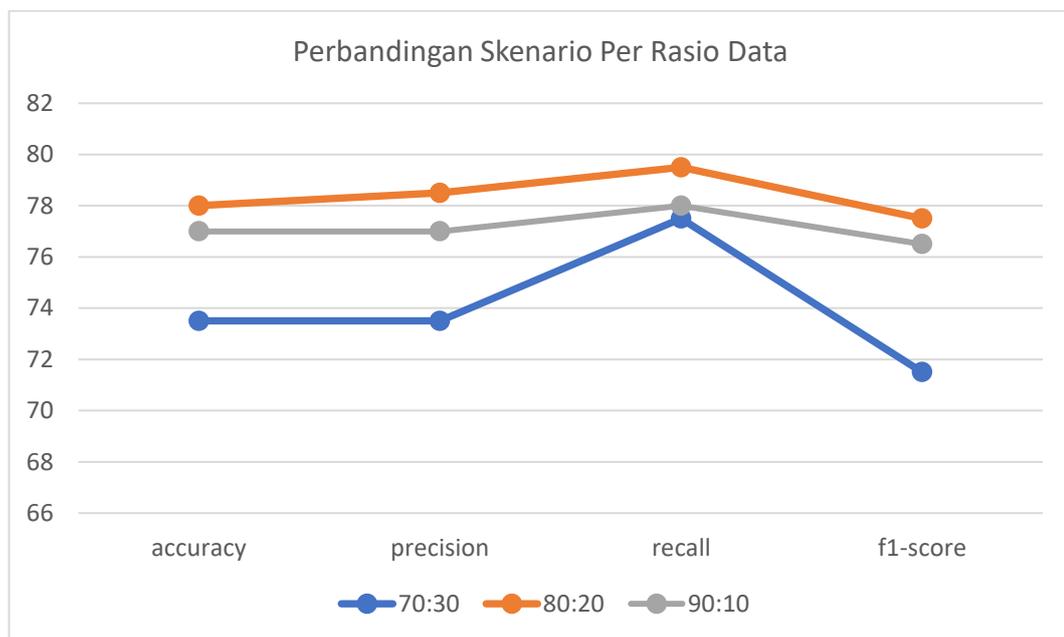
Tomat			
Jenis Penyakit	precision	recall	F1-Score
Tomato Bacterial Spot	65%	73%	69%
Tomato Healthy	74%	83%	78%
Tomato Mosaic Virus	93%	77%	85%

(d)

Terakhir pada Tabel 4.29 diketahui evaluasi performa hasil skenario uji keenam untuk pembagian rasio data 90:10 dengan menggunakan *multi stage classification*, menunjukkan hasil yang hampir sama dengan skenario uji sebelumnya, secara keseluruhan nilai rata-rata *accuracy* 76%, *precision* 76%, *recall* 77% dan *F1-Score* 76%. Skenario uji keenam ini memiliki performa yang cukup stabil tiap kelasnya, namun mendapatkan performa rata-rata yang masih dibawah skenario uji kedua, ketiga dan kelima. Pada skenario keenam ini kelas *potato early blight*, *rice brown spot*, *rice healthy*, *rice scald*, *tomato healthy* dan *tomato mosaic virus* yang memiliki performa yang lebih baik diantara kelas lainnya pada skenario

uji keenam. Dan untuk kelas *corn healthy* menunjukkan hasil performa yang kurang baik dibandingkan dengan hasil skenario uji yang lainnya.

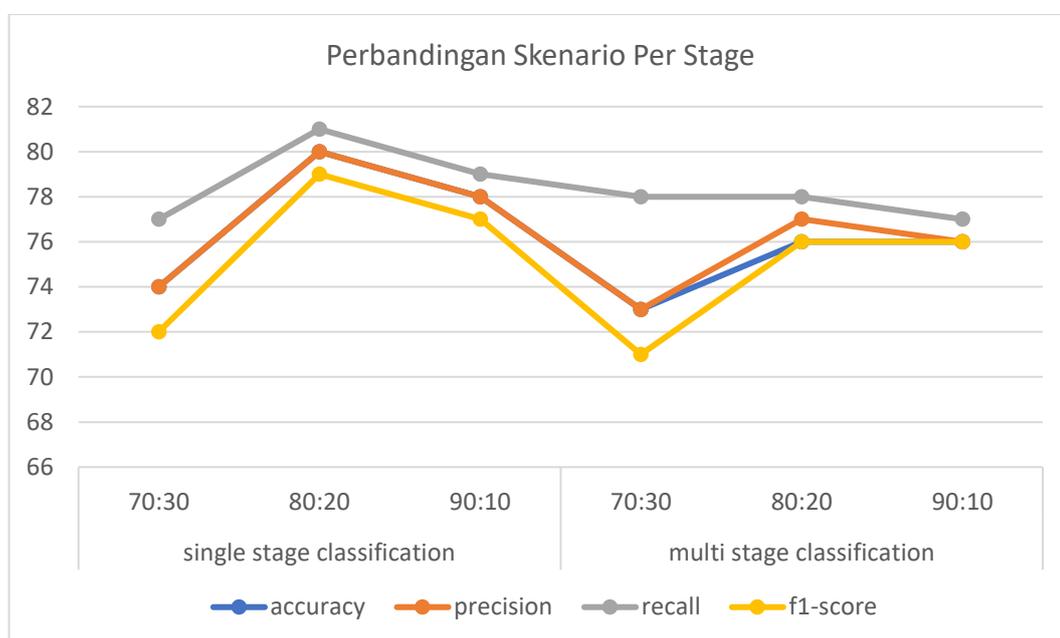
Berdasarkan analisis hasil yang dilakukan dalam penelitian ini, dari enam skenario uji yang dievaluasi, diketahui bahwa skenario uji 2 memiliki performa tertinggi dibandingkan dengan skenario uji lainnya. Skenario uji 2 menunjukkan performa yang unggul dengan berbagai metrik evaluasi, termasuk akurasi sebesar 80%, presisi sebesar 80%, *recall* sebesar 81%, dan skor F1 sebesar 79%. Keunggulan skenario ini menunjukkan bahwa metode yang digunakan dalam skenario uji 2 lebih efektif dalam mengklasifikasikan penyakit tanaman pangan dibandingkan dengan metode yang digunakan pada skenario lainnya.



Gambar 4.44 Perbandingan Skenario Uji Per Rasio Data

Selanjutnya, jika dilihat dari aspek pembagian rasio data, Gambar 4.44 menampilkan perbandingan performa hasil skenario uji berdasarkan rasio pembagian datanya. Gambar ini memberikan gambaran yang jelas tentang

bagaimana variasi dalam rasio pembagian data dapat mempengaruhi kinerja model klasifikasi. Dengan membandingkan hasil dari berbagai skenario uji, kita dapat melihat bahwa skenario uji 2 tidak hanya memiliki metrik performa yang unggul, tetapi juga menunjukkan kestabilan dalam hasilnya ketika rasio pembagian data diubah. Hal ini menunjukkan pentingnya pemilihan rasio data yang tepat dalam meningkatkan akurasi dan efisiensi model klasifikasi penyakit tanaman pangan.



Gambar 4.45 Perbandingan Skenario Uji Per Stage

Selanjutnya, jika dilihat dari aspek penggunaan *stage classification*, Gambar 4.45 menampilkan perbandingan performa antara *single stage classification* dan *multi stage classification*. Dari gambar tersebut, diperoleh bahwa performa terbaik dalam hasil uji coba pada penelitian ini adalah pada *single stage classification*. Namun, jika dilihat secara sekilas, performa kedua metode tersebut tidak terlalu jauh berbeda. Perbedaannya terletak pada kecepatan konvergensi. *Single stage classification* sudah mencapai konvergensi pada epoch ke-300, sementara *multi*

stage classification belum sepenuhnya mencapai konvergensi, meskipun mendekati. Hal ini menunjukkan bahwa *single stage classification* memiliki keunggulan dalam hal kecepatan pelatihan. Namun, jika dilihat dari nilai performa per kelasnya, metode *multi stage classification* menunjukkan beberapa peningkatan signifikan dalam performanya. Beberapa kelas pada *multi stage classification* memiliki nilai yang lebih baik dibandingkan dengan *single stage classification*. Ini menunjukkan bahwa meskipun secara keseluruhan performa *multi stage classification* sedikit tertinggal dalam hal konvergensi, metode ini memiliki potensi untuk memberikan hasil yang lebih baik dan lebih stabil untuk beberapa kelas penyakit tanaman. Oleh karena itu, meskipun *single stage classification* menunjukkan performa terbaik secara keseluruhan dan mencapai konvergensi lebih cepat, metode *multi stage classification* tetap menunjukkan keunggulan dalam meningkatkan performa per kelas. Ini menegaskan bahwa meskipun *single stage classification* lebih efisien dalam hal waktu pelatihan, *multi stage classification* memiliki potensi untuk menghasilkan klasifikasi yang lebih akurat dan lebih andal untuk penyakit tertentu.

Tujuan dari penelitian ini adalah untuk mengklasifikasikan penyakit tanaman, sehingga dapat membantu dalam mengenali berbagai jenis penyakit tanaman, terutama bagi petani baru yang baru terjun ke bidang pertanian. Meskipun sistem yang telah dibangun ini menunjukkan hasil yang menjanjikan, masih diperlukan beberapa perbaikan untuk meningkatkan performa sistem agar lebih baik dan lebih efektif. Dengan demikian, sistem ini dapat memberikan manfaat yang lebih luas bagi banyak orang, termasuk petani yang membutuhkan solusi cepat dan akurat

untuk identifikasi penyakit tanaman. Perbaikan tersebut diharapkan dapat meningkatkan akurasi, efisiensi, dan kegunaan sistem dalam praktik sehari-hari, sehingga berkontribusi pada peningkatan produktivitas dan kesehatan tanaman secara keseluruhan.

Sebagaimana firman Allah *Suhanahu wa Ta'ala* dalam surat Al-A'la ayat 1-3 yang berbunyi:

سَبِّحْ اسْمَ رَبِّكَ الْأَعْلَى الَّذِي خَلَقَ فَسَوَّى وَالَّذِي قَدَّرَ فَهَدَى

“Sucikanlah nama Tuhanmu Yang Maha Tinggi, yang menciptakan, lali menyempurnakan (ciptaan-Nya), yang menentukan kadar (masing-masing) dan memberi petunjuk,” (QS. Al-A'la: 1-3)

Dalam tafsir Jalalayn disebutkan (Sucikanlah nama Rabbmu) maksudnya sucikanlah Dia dari sifat-sifat yang tidak layak bagi-Nya, lafal Ismu adalah lafal Za'id (Yang Maha Tinggi) lafal Al-A'la berkedudukan sebagai kata sifat bagi lafal Rabbika. (Yang menciptakan lalu menyempurnakan) ciptaan-Nya, yakni Dia menjadikan makhluk-Nya itu seimbang semua bagian-bagiannya dan tidak pincang atau berbeda-beda. (Dan Yang Menentukan) apa yang dikehendaki-Nya (dan Yang memberi petunjuk) kepada apa yang telah ditentukan-Nya berupa amal kebaikan dan amal keburukan (Al-Mahalli et al., 2010). Ayat tersebut sejalan dengan hasil dari penelitian ini dimana dengan rasio pembagian data dan pembagian metode *stage classification* yang tepat dan sesuai dengan ukuran dan kadarnya dapat memberikan hasil performa yang baik pada model. Kemudian dalam surah Al-Qamar ayat 49, berbunyi:

إِنَّا كُلَّ شَيْءٍ خَلَقْنَاهُ بِقَدَرٍ

“*Sesungguhnya Kami menciptakan segala sesuatu sesuai dengan ukuran.*” (QS. Al-Qamar : 49)

Dalam Tafsir Jalalyn disebutkan (Sesungguhnya segala sesuatu itu Kami) dinasabkan oleh *Fi'il* yang terdapat pada firman selanjutnya yang berfungsi menafsirkan (ciptakan menurut ukuran) masing-masing. Dan menurut Tafsir Ibnu Katsir, surah Al Qamar ayat 49 tersebut menjelaskan bahwa Allah *Subhanahu wa Ta'ala* telah menentukan ukuran masing-masing untuk makhluk-Nya dan Dia memberi petunjuk kepada semua makhluk-Nya. Kata Ibnu Katsir, karena itulah para imam dari kalangan ahlussunnah menyimpulkan, dalil ayat ini membuktikan akan kebenaran takdir Allah *Subhanahu wa Ta'ala* yang terdahulu terhadap makhluk-Nya. Maksud takdir terdahulu ini adalah pengetahuan Allah *Subhanahu wa Ta'ala* tentang segala sesuatu sebelum terjadiannya dan ketetapan atas mereka itu diciptakan oleh Allah *Subhanahu wa Ta'ala* (Abdul Ghoffar E.M, 2003).

Ayat Al-Qur'an tersebut mengajarkan bahwa Allah menciptakan segala sesuatu sesuai ukuran yang sesuai. Dengan berlandaskan hal tersebut, segala sesuatu hal yang ada di alam ini termasuk penyakit tanaman menjadi bukti yang mencerminkan kebijaksanaan dan kebesaran Allah *Subhanahu wa Ta'ala*. Hal ini juga menjadi pengingat bagi manusia terhadap keterbatasan mereka dalam mengetahui jenis, waktu dan bentuk penyakit dari tanaman. Meskipun tidak sepenuhnya manusia dapat mengetahuinya, namun mereka masih memiliki akal untuk belajar dan memiliki tanggung jawab untuk melakukan upaya-upaya yang terukur untuk mengurangi dampak bagi dirinya.

Klasifikasi jenis penyakit tanaman pangan berdasarkan citra daun dengan menggunakan metode klasifikasi yang akurat akan mempengaruhi tindakan penanganan penyakit tanaman agar lebih efektif dan cepat. Informasi tentang jenis penyakit tanaman pangan dapat membantu petani dalam melakukan penanganan yang tepat untuk pemulihan tanaman mereka. Berdasarkan hasil klasifikasi penyakit tanaman pangan dengan performa terbaik, dapat diidentifikasi karakteristik ideal dari berbagai jenis penyakit tanaman pangan berdasarkan citra daun sebagai berikut. *Corn common rust* dapat dikenali jika daun memiliki bintik-bintik atau corak berwarna sedikit menguning dan layu. *Corn healthy* ditandai dengan daun yang memiliki bentuk dan warna yang sehat tanpa kerusakan. *Corn northern leaf blight* terlihat jika daun berubah warna menjadi kuning dan kemerahan serta sedikit layu. *Potato early blight* dapat diidentifikasi jika daun memiliki bercak hitam atau sebagian daun menjadi berkerut, layu, dan berubah warna menjadi coklat seperti terserang hama. *Potato healthy* ditandai dengan daun pada tanaman kentang yang memiliki warna dan bentuk sehat tanpa perubahan apapun. *Potato late blight* memiliki kondisi yang hampir sama dengan *potato early blight*, namun tidak ada perubahan warna pada daun, tetapi perubahan bentuk daunnya lebih jelas terlihat. *Rice brown spot* terlihat jika terdapat titik coklat pada daun, sementara *rice healthy* ditandai dengan tidak adanya perubahan pada bentuk serta warna daun. *Rice scald* dapat dikenali jika terdapat corak kering berwarna merah kecokelatan pada daun serta kerusakan bentuk daun. *Tomato bacterial spot* terlihat jika pada daun terdapat bintik coklat serta perubahan warna menjadi sedikit menguning. *Tomato healthy* ditandai dengan daun yang terlihat sehat tanpa

perubahan warna dan bentuk. *Tomato mosaic virus* terlihat jika terdapat bintik-bintik kuning pada daun. Dengan klasifikasi yang akurat, tindakan penanganan terhadap penyakit tanaman dapat dilakukan dengan lebih tepat, sehingga meningkatkan efektivitas dalam mengatasi masalah kesehatan tanaman.

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Bab sebelumnya telah menjelaskan secara rinci tentang pengujian yang dilakukan untuk mengevaluasi performa metode *Convolutional Neural Network* dengan arsitektur LeNet-5 dalam klasifikasi penyakit tanaman pangan. Proses pengujian ini melibatkan beberapa langkah penting. Langkah pertama adalah preprocessing data, yang mencakup *resize*, *rotation*, *zoom*, *horizontal flip*, *vertical flip*, dan konversi gambar menjadi *grayscale*. Setelah itu, data dibagi menjadi tiga rasio yang berbeda yaitu 70% data latih dan 30% data uji, 80% data latih dan 20% data uji, serta 90% data latih dan 10% data uji. Selanjutnya, data tersebut dibagi lagi untuk proses *stage classification* menggunakan *single stage classification* dan *multi stage classification*. Langkah berikutnya adalah evaluasi model menggunakan *confusion matrix* untuk mengukur performanya. Hasil pengujian menunjukkan bahwa model pada skenario uji 2, yang menggunakan *single stage classification* dengan rasio 80% data latih dan 20% data uji, mencapai performa terbaik. Model ini berhasil mencapai *accuracy* 80%, *precision* 80%, *recall* 81%, dan *F1-Score* 79%. Model skenario uji 2 mampu mendeteksi dengan benar 191 dari 240 data uji. Namun, model ini juga mengalami beberapa kesalahan deteksi, dengan total 49 kesalahan prediksi, terutama pada klasifikasi penyakit tanaman jagung yang hasil prediksinya masih banyak yang meleset. Meskipun demikian, berdasarkan hasil performa yang diperoleh, dapat disimpulkan bahwa model pada skenario uji 2 memiliki kemampuan yang baik dalam mengidentifikasi penyakit tanaman pangan.

Keberhasilan model ini dalam mendeteksi sebagian besar data uji dengan benar menunjukkan potensi besar dalam aplikasi nyata, membantu petani, terutama petani baru, dalam mengenali dan mengatasi penyakit tanaman secara lebih efektif. Dengan demikian, skenario uji 2 tidak hanya menunjukkan performa yang unggul dalam berbagai metrik evaluasi, tetapi juga menegaskan kemampuannya sebagai solusi untuk klasifikasi penyakit tanaman pangan. Perbaikan dan penyempurnaan lebih lanjut pada model ini dapat lebih meningkatkan akurasi dan keandalannya, sehingga memberikan manfaat yang lebih besar bagi sektor pertanian.

5.2 Saran

Setelah melakukan analisis terhadap hasil pengujian, penulis menyadari bahwa penelitian ini masih memiliki beberapa kekurangan dan memerlukan penyempurnaan lebih lanjut. Berdasarkan hal tersebut, penulis mengajukan beberapa rekomendasi yang dapat dipertimbangkan untuk penelitian di masa mendatang:

1. Menambahkan jumlah *epoch*: Tujuannya adalah untuk mendapatkan nilai konvergensi yang lebih baik serta meningkatkan performa pada *multi stage classification*. Dengan jumlah *epoch* yang lebih banyak, model memiliki kesempatan lebih besar untuk belajar dan menyesuaikan bobot dengan lebih optimal.
2. Melakukan seleksi dalam pengumpulan data serta menentukan jumlah kelas yang sesuai dengan model yang digunakan: Seleksi data yang baik dan penentuan jumlah kelas yang sesuai dapat meningkatkan performa model

dengan arsitektur yang sederhana. Ini akan membantu model dalam mengenali pola dengan lebih baik dan mengurangi *overfitting*.

3. Menerapkan dan menguji metode CNN dengan arsitektur yang lebih kompleks: Contohnya, dengan menambahkan lapisan *convolution*, *pooling*, serta *hidden layer* dan *node* pada *fully connected layer*. Selain itu, dapat juga menerapkan CNN dengan arsitektur lain seperti VGG16. Tujuannya adalah agar model dapat mempelajari pola yang lebih kompleks dari data yang mungkin tidak dapat dipelajari secara maksimal pada arsitektur yang sederhana.
4. Menerapkan input 3 *channel* atau gambar RGB: Dengan menggunakan gambar RGB, model akan memiliki kemampuan untuk mempelajari lebih banyak fitur dari data. Ini dapat meningkatkan akurasi dan keandalan dalam mengidentifikasi penyakit tanaman karena informasi warna yang lebih kaya dapat diolah oleh model.

DAFTAR PUSTAKA

- Abdul Ghoffar E.M. (2003). *Tafsir Ibnu Katsir 5.1*.
- Adistya, R., & Muslim, M. A. (2016). Deteksi dan Klasifikasi Kendaraan menggunakan Algoritma Backpropagation dan Sobel. In *Journal of Mechanical Engineering and Mechatronics Submitted* (Vol. 1, Issue 2).
- Akther, J., Harun-Or-Roshid, M., Nayan, A. A., & Kibria, M. G. (2021). Transfer learning on VGG16 for the Classification of Potato Leaves Infected by Blight Diseases. *2021 Emerging Technology in Computing, Communication and Electronics, ETCCE 2021*.
<https://doi.org/10.1109/ETCCE54784.2021.9689792>
- Al-Mahalli, J. M. bin A., As-Suyuthi Jalaluddin, & Junaidi, N. (2010). *Tafsir Jalalain*.
- Ambarwari, A., Husni, M., & Mahayana, D. (2023). Perkembangan Metode Klasifikasi Citra Penginderaan Jauh dalam Perspektif Revolusi Ilmiah Thomas Kuhn. *Jurnal Filsafat Indonesia*, 6.
- Anggiratih, E., Siswanti, S., Octaviani, S. K., & Sari, A. (2021). Klasifikasi Penyakit Tanaman Padi Menggunakan Model Deep Learning Efficientnet B3 dengan Transfer Learning. *Jurnal Ilmiah SINUS*, 19(1), 75.
<https://doi.org/10.30646/sinus.v19i1.526>
- Anggraeni, D. S., Widayana, A., Rahayu, P. D., Rozikin, C., Informatika, T., & Karawang, U. S. (2022). *STRING (Satuan Tulisan Riset dan Inovasi Teknologi) METODE ALGORITMA CONVOLUTIONAL NEURAL NETWORK PADA KLASIFIKASI PENYAKIT TANAMAN CABAI*.
- Asrafil, A., Paliwang, A., Ridwan, M., Septian, D., Cahyanti, M., Ericks, D., Swedia, R., & Informatika, J. T. (2018). *KLASIFIKASI PENYAKIT TANAMAN APEL DARI CITRA DAUN DENGAN CONVOLUTIONAL NEURAL NETWORK*.
- Baranwal, S., Khandelwal, S., & Arora, A. (2019). *Deep Learning Convolutional Neural Network for Apple Leaves Disease Detection under responsibility of International Conference on Sustainable Computing in Science, Technology and Management*. <https://ssrn.com/abstract=3351641>
- Chellapandi, B., Vijayalakshmi, M., & Chopra, S. (2021). Comparison of pre-trained models using transfer learning for detecting plant disease. *Proceedings - IEEE 2021 International Conference on Computing, Communication, and Intelligent Systems, ICCIS 2021*, 383–387.
<https://doi.org/10.1109/ICCIS51004.2021.9397098>

- Felix, F., Wijaya, W., Sutra, S. P., Kokasih, P. W., & Sirait, P. (2020). Implementasi Convolutional Neural Network Untuk Identifikasi Jenis Tanaman Melalui Daun. *J. SIFO Mikrosil*, 21, 1–10.
- Guo, Y., & Wang, X. (2022). Modulation Signal Classification Algorithm Based on Denoising Residual Convolutional Neural Network. *IEEE Access*, 10, 121733–121740. <https://doi.org/10.1109/ACCESS.2022.3221475>
- Hasan, Moh. A., Riyanto, Y., & Riana, D. (2021). Grape leaf image disease classification using CNN-VGG16 model. *Jurnal Teknologi Dan Sistem Komputer*, 9(4), 218–223. <https://doi.org/10.14710/jtsiskom.2021.14013>
- Irfansyah, D., Mustikasari, M., Suroso, A., Sistem Informasi Bisnis, J., Ilmu Komputer dan Teknologi Informasi, F., Gunadarma, U., Sistem Informasi, J., Bani Saleh, S., Margonda Raya No, J., Depok, B., & Hasibuan No, J. M. (2021). *Arsitektur Convolutional Neural Network (CNN) Alexnet Untuk Klasifikasi Hama Pada Citra Daun Tanaman Kopi*. 6(2). <https://data.mendeley.com/datasets/c5yvn32dzg/2>.
- Jiang, Y., Chen, L., Zhang, H., & Xiao, X. (2019). Breast cancer histopathological image classification using convolutional neural networks with small SE-ResNet module. *PLoS ONE*, 14(3). <https://doi.org/10.1371/journal.pone.0214587>
- Kaya, A., Keceli, A. S., Catal, C., Yalic, H. Y., Temucin, H., & Tekinerdogan, B. (2019). Analysis of transfer learning for deep neural network based plant classification models. *Computers and Electronics in Agriculture*, 158, 20–29. <https://doi.org/10.1016/j.compag.2019.01.041>
- Lecun, Y., Eon Bottou, L., Bengio, Y., & Abstract|, P. H. (1998). *Gradient-Based Learning Applied to Document Recognition*.
- Nawwar, N., Kasban, H., & salama, may. (2021). Improvement of confusion matrix for Hand Vein Recognition Based On Deep- Learning multi-classifier Decisions. *Arab Journal of Nuclear Sciences and Applications*, 0(0), 1–14. <https://doi.org/10.21608/ajnsa.2021.70450.1460>
- Nuryanto, B. (2018). PENGENDALIAN PENYAKIT TANAMAN PADI BERWAWASAN LINGKUNGAN MELALUI PENGELOLAAN KOMPONEN EPIDEMIK. *Jurnal Penelitian Dan Pengembangan Pertanian*, 37(1), 1. <https://doi.org/10.21082/jp3.v37n1.2018.p1-8>
- Pujiati, R., & Rochmawati, N. (2022). Identifikasi Citra Daun Tanaman Herbal Menggunakan Metode Convolutional Neural Network (CNN). *Journal of Informatics and Computer Science*, 03.
- Sabrina, S. A., & Maki W.F. (2022). *Klasifikasi Penyakit pada Tanaman Kopi Robusta Berdasarkan Citra Daun Menggunakan Convolutional Neural Network*.

- Sahro Winanto, T., Rozikin, C., & Jamaludin, A. (2023a). Analisa Performa Arsitektur Transfer Learning Untuk Mengidentifikasi Penyakit Daun Pada Tanaman Pangan. In *Journal of Applied Informatics and Computing (JAIC)* (Vol. 7, Issue 1). <http://jurnal.polibatam.ac.id/index.php/JAIC>
- Sahro Winanto, T., Rozikin, C., & Jamaludin, A. (2023b). Analisa Performa Arsitektur Transfer Learning Untuk Mengidentifikasi Penyakit Daun Pada Tanaman Pangan. In *Journal of Applied Informatics and Computing (JAIC)* (Vol. 7, Issue 1). <http://jurnal.polibatam.ac.id/index.php/JAIC>
- Sheila, S., Kharil Anwar, M., Saputra, A. B., Pujiyanto, R., & Sari, I. P. (2020). *Deteksi Penyakit pada Daun Padi Berbasis Pengolahan Citra Menggunakan Metode Convolutional Neural Network (CNN)*. <https://www.kaggle.com/datasets/tedisetiady/leaf->
- Sholihati, R. A., Sulistijono, I. A., Risnumawan, A., & Kusumawati, E. (2020). Potato Leaf Disease Classification Using Deep Learning Approach. *IES 2020 - International Electronics Symposium: The Role of Autonomous and Intelligent Systems for Human Life and Comfort*, 392–397. <https://doi.org/10.1109/IES50839.2020.9231784>
- Singh, V., & Misra, A. K. (2017). Detection of plant leaf diseases using image segmentation and soft computing techniques. *Information Processing in Agriculture*, 4(1), 41–49. <https://doi.org/10.1016/j.inpa.2016.10.005>
- Suganda, T., Dinda, D., Wulandari, Y., & Jatinangor -Jatinangor, K. (2018). Curvularia sp. Jamur Patogen Baru Penyebab Penyakit Bercak Daun pada Tanaman Sawi. *Jurnal Agrikultura*, 29(3), 119–123. <https://www.britmycolsoc>.
- Sutarman, O. (n.d.). *Dasar Ilmu Penyakit Tanaman*.
- Ulfah Nur Oktaviana, Ricky Hendrawan, Alfian Dwi Khoirul Annas, & Galih Wasis Wicaksono. (2021). Klasifikasi Penyakit Padi berdasarkan Citra Daun Menggunakan Model Terlatih Resnet101. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 5(6), 1216–1222. <https://doi.org/10.29207/resti.v5i6.3607>
- Wijaya, J., Putra Sutra, S., Wahyu Kosasih, P., Sirait, P., & SIFO Mikroskil, J. (2020). Implementasi Convolutional Neural Network Untuk Identifikasi Jenis Tanaman Melalui Daun. *Julyxxxx*, 21, 1–5.
- Wiyono, S. (2007). *Perubahan Iklim dan Ledakan hama dan penyakit tanaman*.
- Zalvadila, A., Syafie, L., & Darwis, H. (2023). *Klasifikasi Penyakit Tanaman Bawang Merah Menggunakan Metode SVM dan CNN*. 8(3).
- Żarski, M., Wójcik, B., & Miszczak, J. A. (2021). KrakN: Transfer Learning framework and dataset for infrastructure thin crack detection. *SoftwareX*, 16. <https://doi.org/10.1016/j.softx.2021.100893>

