



UIN SUSKA RIAU

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:

a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.

b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.

© Hak cipta milik UIN Suska Riau

State Islamic University of Sultan Syarif Kasim Riau



# KLASIFIKASI CITRA PENYAKIT TOMAT BERDASARKAN CITRA DAUN MENGGUNAKAN ALGORITMA *CONVOLUTIONAL NEURAL NETWORK*

## TUGAS AKHIR

Diajukan Sebagai Salah Satu Syarat  
untuk Memperoleh Gelar Sarjana Komputer pada  
Program Studi Sistem Informasi

Oleh:

**NAYLA HUSNA RYANDA**

**12250321428**



UIN SUSKA RIAU

UIN SUSKA RIAU

**FAKULTAS SAINS DAN TEKNOLOGI  
UNIVERSITAS ISLAM NEGERI SULTAN SYARIF KASIM RIAU  
PEKANBARU  
2026**

## LEMBAR PERSETUJUAN

### KLASIFIKASI CITRA PENYAKIT TOMAT BERDASARKAN CITRA DAUN MENGGUNAKAN ALGORITMA *CONVOLUTIONAL NEURAL NETWORK*

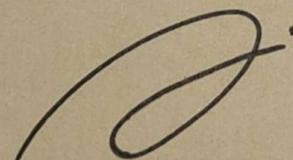
## TUGAS AKHIR

Oleh:

**NAYLA HUSNA RYANDA**  
**12250321428**

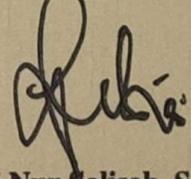
Telah diperiksa dan disetujui sebagai laporan tugas akhir  
di Pekanbaru, pada tanggal 20 Januari 2026

Pembimbing I



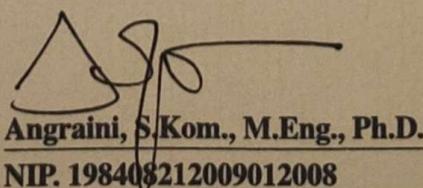
**Inggih Permana, ST., M.Kom.**  
**NIP. 198812102015031006**

Pembimbing II



**Febi Nur Salisah, S.Kom., M.Kom.**  
**NIP. 19900222023212038**

Ketua Program Studi



**Angraini, S.Kom., M.Eng., Ph.D.**  
**NIP. 198408212009012008**

## LEMBAR PENGESAHAN

### KLASIFIKASI CITRA PENYAKIT TOMAT BERDASARKAN CITRA DAUN MENGGUNAKAN ALGORITMA *CONVOLUTIONAL NEURAL NETWORK*

#### TUGAS AKHIR

Oleh:

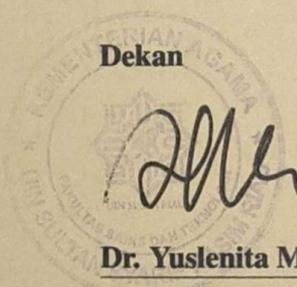
**NAYLA HUSNA RYANDA**

**12250321428**

Telah dipertahankan di depan sidang dewan penguji  
sebagai salah satu syarat untuk memperoleh gelar Sarjana Komputer  
Fakultas Sains dan Teknologi Universitas Islam Negeri Sultan Syarif Kasim Riau  
di Pekanbaru, pada tanggal 15 Januari 2026

Pekanbaru, 15 Januari 2026  
Mengesahkan,

Dekan



**Dr. Yuslenita Muda, S.Si., M.Sc.**  
NIP. 197701032007102001

Ketua Program Studi

**Angraini, S.Kom., M.Eng., Ph.D.**  
NIP. 198408212009012008

#### DEWAN PENGUJI:

Ketua : Nesdi Evrilyan Rozanda, S.Kom., M.Sc.

Sekretaris : Inggih Permana, ST., M.Kom.

Anggota 1 : Febi Nur Salisah, S.Kom., M.Kom.

Anggota 2 : M. Afdal, ST., M.Kom.

Anggota 3 : Siti Monalisa, ST., M.Kom.

Lampiran Surat :

Nomor : Nomor 25/2021

Tanggal : 10 September 2021

### **SURAT PERNYATAAN**

Saya yang bertanda tangan di bawah ini:

Nama : Nayla Husna Ryanda

NIM : 12250321428

Tempat/Tgl. Lahir : Medan / 11 Desember 2003

Fakultas/Pascasarjana : Sains dan Teknologi

Prodi : Sistem Informasi

Judul Skripsi :

**KLASIFIKASI CITRA PENYAKIT TOMAT BERDASARKAN CITRA DAUN  
MENGGUNAKAN ALGORITMA CONVOLUTIONAL NEURAL NETWORK**

Menyatakan dengan sebenar-benarnya bahwa :

1. Penulisan Skripsi dengan judul sebagaimana tersebut di atas adalah hasil pemikiran dan penelitian saya sendiri.
2. Semua kutipan pada karya tulis saya ini sudah disebutkan sumbernya.
3. Oleh karena itu Skripsi saya ini, saya nyatakan bebas dari plagiat.
4. Apa bila dikemudian hari terbukti terdapat plagiat dalam penulisan Skripsi saya tersebut, maka saya bersedia menerima sanksi sesuai peraturan perundang-undangan.

Demikianlah Surat Pernyataan ini saya buat dengan penuh kesadaran dan tanpa paksaan dari pihak manapun juga.

Pekanbaru, 22 Januari 2026

Saya membuat pernyataan



Nayla Husna Ryanda  
NIM: 12250321428



UIN SUSKA RIAU

**Hak Cipta Dilindungi Undang-Undang**

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
  - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
  - b. Pengutipan tidak mengikuti kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

## LEMBAR HAK ATAS KEKAYAAN INTELEKTUAL

Tugas Akhir yang tidak diterbitkan ini terdaftar dan tersedia di Perpustakaan Universitas Islam Negeri Sultan Syarif Kasim Riau adalah terbuka untuk umum, dengan ketentuan bahwa hak cipta ada pada penulis. Referensi kepustakaan diperkenankan dicatat, tetapi pengutipan atau ringkasan hanya dapat dilakukan atas izin penulis dan harus dilakukan mengikuti kaedah dan kebiasaan ilmiah serta menyebutkan sumbernya.

Penggandaan atau penerbitan sebagian atau seluruh Tugas Akhir ini harus memperoleh izin tertulis dari Dekan fakultas universitas. Perpustakaan dapat meminjamkan Tugas Akhir ini untuk anggotanya dengan mengisi nama, tanda peminjaman dan tanggal pinjam pada *form* peminjaman.



UIN SUSKA RIAU

© Hak Cipta UIN Suska Riau

State Islamic University of Sultan Syarif Kasim Riau

**Hak Cipta Dilindungi Undang-Undang**

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
  - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
  - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

## LEMBAR PERNYATAAN

Dengan ini saya menyatakan bahwa dalam Tugas Akhir ini tidak terdapat karya yang pernah diajukan untuk memperoleh gelar kesarjanaan di suatu Perguruan Tinggi, dan sepanjang pengetahuan saya juga tidak terdapat karya atau pendapat yang pernah ditulis atau diterbitkan oleh orang lain kecuali yang secara tertulis diacu dalam naskah ini dan disebutkan di dalam daftar pustaka.

Pekanbaru, 15 Januari 2026

Yang membuat pernyataan,

**NAYLA HUSNA RYANDA**  
**NIM. 12250321428**

**UIN SUSKA RIAU**



**Hak Cipta Dilindungi Undang-Undang**

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
  - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
  - b. Pengutipan tidak mengurangi kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

## LEMBAR PERSEMBAHAN

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ

*Assalamu'alaikum Warahmatullahi Wabarakatuh.*

*Alhamdulillah wa syukurillah*, sebagai bentuk rasa syukur peneliti atas segala nikmat yang telah didapatkan tanpa ada kekurangan sekalipun. Sholawat berserta salam tak lupa peneliti ucapkan kepada Nabi Muhammad *Shalallahu 'Alaihi Wa Sallam* dengan melafalkan *Allahumma Shalli 'ala Sayyidina Muhammad wa 'ala Ali Sayyidina Muhammad*. Semoga kita semua senantiasa mendapat syafaatNya di dunia maupun di akhirat. *Amin Ya Rabbal 'Alamiin.*

Tugas Akhir ini peneliti persembahkan kepada Ayahanda Alm. Al Harry Harlan dan Ibunda Emilda Syahyani yang tidak henti-hentinya memberikan semangat, dukungan, dan doa kepada peneliti sehingga dapat menyelesaikan pendidikan Strata Satu (S-1) dengan baik. Akhirnya peneliti berhasil menyelesaikan Laporan Tugas Akhir ini. Peneliti mendedikasikan Tugas Akhir ini sebagai tolak ukur keberhasilan kepada keluarga besar tercinta.

Terima kasih kepada sahabat peneliti yang selalu memberikan dukungan selama pengerjaan Tugas Akhir ini. Terima kasih kepada Bapak Inggih Permana, ST., M.Kom dan Ibu Febi Nur Salisah, S.Kom., M.Kom. yang telah sabar membimbing peneliti untuk menyelesaikan Tugas Akhir ini dan selalu menyempatkan waktu untuk mengajari serta membimbing peneliti dalam semua hal yang berkaitan dengan Tugas Akhir ini.

Semoga Allah *Subhanahu Wa Ta'ala* memberikan keberkahan serta rahmatNya dan senantiasa menjadikan kita hamba yang terus berdoa kepada-Nya. *Amin Ya Rabbal 'Alamiin.*

*Wassalamu'alaikum Warahmatullahi Wabarakatuh.*

**Hak Cipta Dilindungi Undang-Undang**

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:

a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.

b. Pengutipan tidak mengikuti kepentingan yang wajar UIN Suska Riau.

2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

## KATA PENGANTAR

Puji dan syukur peneliti panjatkan ke hadirat Allah SWT atas segala rahmat, karunia, dan hidayah-Nya, sehingga peneliti dapat menyelesaikan Tugas Akhir yang berjudul “KLASIFIKASI CITRA PENYAKIT TOMAT BERDASARKAN CITRA DAUN MENGGUNAKAN ALGORITMA CONVUTIONAL NEURAL NETWORK” dengan baik. Penyusunan Tugas Akhir ini merupakan salah satu syarat untuk menyelesaikan pendidikan Strata Satu (S1) pada Program Studi Sistem Informasi, Fakultas Sains dan Teknologi. Peneliti menyadari bahwa penyusunan Tugas Akhir ini tidak terlepas dari bantuan, bimbingan, dukungan, dan doa dari berbagai pihak. Oleh karena itu, pada kesempatan ini peneliti menyampaikan ucapan terima kasih dan penghargaan yang setulus-tulusnya kepada:

1. Ibu Prof. Dr. Hj. Leny Nofianti, MS., SE., M.Si., AK., C.A sebagai Rektor Universitas Islam Negeri Sultan Syarif Kasim Riau.
2. Ibu Dr. Yuslenita Muda, S.Si., M.Sc sebagai Dekan Fakultas Sains dan Teknologi.
3. Ibu Angraini, S.Kom., M.Eng., Ph.D sebagai Ketua Program Studi Sistem Informasi.
4. Bapak Saide, S.Kom., M.Kom., M.I.M., Ph.D sebagai Dosen Pembimbing Akademik yang telah membimbing dan memberikan arahan serta masukan dari awal memulai perkuliahan hingga akan diselesaiannya masa perkuliahan ini.
5. Bapak Inggh Permana, ST., M.Kom sebagai Dosen Pembimbing Pertama tugas akhir ini saya yang telah berkenan membimbing, mengarahkan dan memberi kemudahan peneliti dalam menyelesaikan Laporan Tugas Akhir ini.
6. Ibu Febi Nur Salisah, S.Kom., M.Kom sebagai Dosen Pembimbing Kedua tugas akhir saya.
7. Bapak M. Afdal, ST., M.Kom sebagai Koordinator Tugas Akhir Program Studi Sistem Informasi sekaligus Dosen Penguji I yang telah banyak memberikan arahan dan masukan dalam penulisan Laporan Tugas Akhir ini.
8. Ibu Siti Monalisa, ST., M.Kom sebagai Dosen Penguji II Tugas Akhir yang memberikan arahan, kritik dan saran yang bermanfaat dalam penyelesaian Tugas Akhir ini.
9. Bapak Nesdi Evrilyan Rozanda, S.Kom., M.Sc sebagai Ketua Sidang yang memimpin Sidang Tugas Akhir yang memberikan arahan, kritik dan saran yang bermanfaat dalam penyelesaian Tugas Akhir ini.

- © Hak Cipta milik UIN Suska Riau**
- Hak Cipta Dilindungi Undang-Undang**
10. Bapak Ibu Dosen Sistem Informasi, Fakultas Sains dan Teknologi, Universitas Islam Negeri Sultan Syarif Kasim Riau, yang senantiasa memberikan ilmu yang bermanfaat serta memberikan semangat kepada peneliti.
  11. Kepada Alm Bapak AL Harry Harlan, seorang papa yang paling penulis rindukan dan menjadi alasan penulis bertahan sejauh ini. Kehadiranmu yang penuh kasih tetap hidup didalam hati dan menjadi sumber kekuatan yang tak ternilai. penulis berterimakasih atas kenangan, tawa, dan kebersamaan, yang menjadi penyemangat penulis dalam menyelesaikan tugas akhir ini.
  12. Kepada bunda tercinta, Ibu Emilda Syahyani, yang selalu memberikan doa, support, motivasi, nasihat, semangat, sehingga peneliti dapat menyelesaikan Laporan Tugas Akhir ini.
  13. Abang Hafiz Azri Ryanda dan adik Sulthan Faturrahman tercinta yang menjadi penyemangat untuk menyelesaikan Laporan Tugas Akhir ini.
  14. Sahabat seperjuangan penulis yaitu Ekatri Yulisara dan Irma Fitriani yang selalu memberikan semangat, dukungan tiada henti dan bantuan dalam segala hal selama dari maba hingga menyelesaikan tugas akhir ini.
  15. Seluruh teman-teman sistem informasi angkatan 2022 kelas D yang selalu membersamai proses perkuliahan ini dari awal hingga akhir.
  16. Semua pihak yang namanya tidak dapat disebutkan satu-persatu yang telah banyak membantu peneliti selama menyelesaikan Tugas Akhir ini.
- Peneliti menyadari bahwa Tugas Akhir ini masih jauh dari sempurna. Jika terdapat kritik, saran, atau pertanyaan terkait Tugas Akhir ini, silakan menghubungi peneliti melalui e-mail 12250321428@students.uin-suska.ac.id atau nayla.nana1112@gmail.com. Akhir kata, semoga Tugas Akhir ini dapat memberikan manfaat bagi semua pihak yang membutuhkan dan menjadi referensi untuk pengembangan ilmu pengetahuan di bidang yang terkait.

Pekanbaru, 20 Januari 2026

Peneliti,

**UIN SUSKA RIAU**

**NAYLA HUSNA RYANDA**

**NIM. 12250321428**

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
  - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
  - b. Pengutipan tidak mengikuti kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.



UIN SUSKA RIAU

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:

a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.

b. Pengutipan tidak mengikuti kepentingan yang wajar UIN Suska Riau.

# KLASIFIKASI CITRA PENYAKIT TOMAT BERDASARKAN CITRA DAUN MENGGUNAKAN ALGORITMA CONVOLUTIONAL NEURAL NETWORK

**NAYLA HUSNA RYANDA**  
**NIM: 12250321428**

Tanggal Sidang: 15 Januari 2026

Periode Wisuda:

Program Studi Sistem Informasi  
Fakultas Sains dan Teknologi

Universitas Islam Negeri Sultan Syarif Kasim Riau

Jl. Soebrantas, No. 155, Pekanbaru

## ABSTRAK

Penyakit daun pada tanaman tomat merupakan salah satu faktor utama yang menyebabkan penurunan produktivitas dan kualitas hasil panen. Metode identifikasi manual yang selama ini digunakan petani sering menimbulkan kesalahan diagnosis karena keterbatasan pengetahuan dan perbedaan kondisi lingkungan. Penelitian ini bertujuan untuk mengembangkan model klasifikasi citra penyakit daun tomat menggunakan pendekatan Deep Learning berbasis Convolutional Neural Network (CNN). Tiga arsitektur CNN, yaitu MobileNetV2, InceptionV3, dan DenseNet201, diuji bersama dua algoritma optimasi Adam dan RMSprop untuk memperoleh konfigurasi model paling optimal. Dataset yang digunakan merupakan Tomato Leaf Disease dari Kaggle dengan sepuluh kelas penyakit. Proses penelitian meliputi preprocessing data, augmentasi citra, serta pembagian data menggunakan metode hold-out dengan rasio 80 data latih, 10 data validasi, dan 10 data uji, kemudian pelatihan model dilakukan menggunakan parameter yang seragam pada setiap arsitektur. Evaluasi performa dilakukan menggunakan metrik akurasi, presisi, recall, dan F1-score yang diperoleh melalui confusion matrix. Hasil penelitian menunjukkan bahwa dari seluruh arsitektur dan optimizer yang diuji, model DenseNet201 dengan optimizer Adam memberikan performa paling baik dengan akurasi rata-rata 94, precision 93, recall 94, dan F1-score 94, menunjukkan kemampuan generalisasi yang lebih stabil dalam mengklasifikasikan citra penyakit daun tomat. Temuan ini menegaskan bahwa pemilihan arsitektur dan algoritma optimasi yang tepat dapat meningkatkan efektivitas proses diagnosis otomatis, sehingga penelitian ini berpotensi menjadi dasar dalam pengembangan sistem deteksi dini yang akurat dan efisien untuk mendukung praktik budidaya tomat dan meminimalkan kerugian akibat penyakit daun.

**Kata Kunci:** Convolutional Neural Network, Klasifikasi Citra, Penyakit Daun Tomat



## CARA MEMBUAT TUGAS AKHIR PROGRAM STUDI SISTEM INFORMASI MENGGUNAKAN LATEX

**NAYLA HUSNA RYANDA**  
**NIM: 12250321428**

*Date of Final Exam: January 15<sup>th</sup> 2026*  
*Graduation Period:*

*Department of Information System*  
*Faculty of Science and Technology*  
*State Islamic University of Sultan Syarif Kasim Riau*  
*Soebrantas Street, No. 155, Pekanbaru*

### ABSTRACT

*Leaf disease in tomato plants is one of the main factors causing decreased productivity and quality of harvest. Manual identification methods currently used by farmers often lead to misdiagnosis due to limited knowledge and differences in environmental conditions. This study aims to develop an image classification model for tomato leaf disease using a Convolutional Neural Network (CNN) based Deep Learning approach. Three CNN architectures, namely MobileNetV2, InceptionV3, and DenseNet201, were tested along with two optimization algorithms, Adam and RMSprop, to obtain the most optimal model configuration. The dataset used was Tomato Leaf Disease from Kaggle with ten disease classes. The research process included data preprocessing, image augmentation, and data division using the hold-out method with a ratio of 80 training data, 10 validation data, and 10 test data. Then, model training was carried out using uniform parameters for each architecture. Performance evaluation was carried out using accuracy, precision, recall, and F1-score metrics obtained from the confusion matrix. The results of the study showed that of all the architectures and optimizers tested, the DenseNet201 model with the Adam optimizer provided the best performance with an average accuracy of 94, precision of 93, recall of 94, and F1-score of 94, indicating a more stable generalization ability in classifying tomato leaf disease images. This finding confirms that selecting the right architecture and optimization algorithm can improve the effectiveness of the automatic diagnosis process, so this study has the potential to be the basis for developing an accurate and efficient early detection system to support tomato cultivation practices and minimize losses due to leaf diseases.*

**Keywords:** Convolutional Neural Network, Image Classification, Tomato Leaf Disease

## DAFTAR ISI

<b>LEMBAR PERSETUJUAN</b>	ii
<b>LEMBAR PENGESAHAN</b>	iii
<b>LEMBAR HAK ATAS KEKAYAAN INTELEKTUAL</b>	iv
<b>LEMBAR PERNYATAAN</b>	v
<b>LEMBAR PERSEMBAHAN</b>	vi
<b>KATA PENGANTAR</b>	vii
<b>ABSTRAK</b>	ix
<b>ABSTRACT</b>	x
<b>DAFTAR ISI</b>	xi
<b>DAFTAR GAMBAR</b>	xiv
<b>DAFTAR TABEL</b>	xvi
<b>DAFTAR SINGKATAN</b>	xvii
<b>PENDAHULUAN</b>	1
1.1 Latar Belakang . . . . .	1
1.2 Perumusan Masalah . . . . .	4
1.3 Batasan Masalah . . . . .	4
1.4 Tujuan . . . . .	5
1.5 Manfaat . . . . .	5
1.6 Sistematika Penulisan . . . . .	5
<b>LANDASAN TEORI</b>	8
2.1 Daun Tomat . . . . .	8
2.2 Penyakit Bercak Daun Tomat . . . . .	8
2.2.1 Tomat Sehat (Tomato Healthy) . . . . .	9
2.2.2 Bintik Target (Target Spot) . . . . .	10
2.2.3 Bintik Bakteri (Bacterial Spot) . . . . .	10

- Hak Cipta Dilindungi Undang-Undang**
1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
    - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan karya tulis, penyusunan tinjauan suatu masalah.
  2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

**Hak Cipta Dilindungi Undang-Undang**

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:

a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.

b. Pengutipan tidak mengikuti kepentingan yang wajar UIN Suska Riau.

2.2.4	Virus Keriting Daun Kuning Tomat (Tomato Yellow Leaf Curl Virus) . . . . .	11
2.2.5	Penyakit Busuk Daun (Late Blight) . . . . .	12
2.2.6	Jamur Daun (Leaf Mold) . . . . .	13
2.2.7	Penyakit Busuk Daun Dini (Early blight) . . . . .	13
2.2.8	Tungau Laba-Laba Berbintik Dua (Two-Spotted Spider Mite) . . . . .	14
2.2.9	Virus Mosaik Tomat (Tomato Mosaic Virus) . . . . .	15
2.2.10	Bercak Daun Septoria (Septoria Leaf Spot) . . . . .	15
2.3	Data Mining . . . . .	16
2.4	Deep Learning . . . . .	16
2.5	Convolutional Neural Network (CNN) . . . . .	17
2.6	Arsitektur . . . . .	18
2.6.1	Arsitektur DenseNet201 . . . . .	19
2.6.2	Arsitektur InceptionV3 . . . . .	20
2.6.3	Arsitektur MobileNetV2 . . . . .	21
2.7	Augmentasi Data . . . . .	21
2.8	Optimizer . . . . .	22
2.8.1	Optimizer Adam . . . . .	23
2.8.2	Optimizer RMSprop . . . . .	23
2.9	Penyetelan Hyperparameter . . . . .	24
2.10	Confusion Matrix . . . . .	25
2.11	Penelitian Terdahulu . . . . .	26
2.11.1	Sintesis Penelitian Terdahulu . . . . .	30
2.11.1.1	Gap Penelitian . . . . .	32
	<b>METODOLOGI PENELITIAN</b> . . . . .	<b>33</b>
3.1	Tahap Perencanaan . . . . .	33
3.2	Pengumpulan Data . . . . .	35
3.3	Perancangan Model CNN . . . . .	35
3.3.1	Hold Out Data . . . . .	35
3.3.2	Data Latih, Validasi, dan Uji . . . . .	36
3.3.3	Pre-Processing Data . . . . .	37
3.3.4	Pemodelan Arsitektur CNN . . . . .	37
3.3.5	Optimizer . . . . .	38
3.3.6	Training Model . . . . .	39
3.3.7	Evaluasi Model . . . . .	39
3.4	Seleksi Model Terbaik . . . . .	41

3.5	Perancangan dan pengembangan sistem . . . . .	41
3.5.1	Perencanaan Sistem . . . . .	42
3.5.2	Perancangan Sistem . . . . .	42
3.5.3	Implementasi Sistem . . . . .	42
3.5.4	Pengujian Sistem . . . . .	43
<b>4</b>	<b>HASIL DAN PEMBAHASAN</b>	<b>44</b>
4.1	Proses Pengumpulan Data . . . . .	44
4.2	Pembagian Data . . . . .	45
4.3	Preprocessing Data . . . . .	45
4.4	Pelatihan Menggunakan Mode Deep Learning . . . . .	47
4.5	Evaluasi Model . . . . .	51
4.5.1	Diskusi Penelitian . . . . .	59
4.6	Perencanaan Sistem . . . . .	61
4.7	Perancangan Sistem . . . . .	62
4.7.1	Usecase Diagram . . . . .	63
4.7.2	Activity Diagram . . . . .	64
4.7.3	Sequence Diagram . . . . .	65
4.7.4	Rancangan Antarmuka . . . . .	65
4.8	Implementasi Sistem . . . . .	69
4.9	Pengujian Sistem . . . . .	70
<b>5</b>	<b>PENUTUP</b>	<b>73</b>
5.1	Kesimpulan . . . . .	73
5.2	Saran . . . . .	74

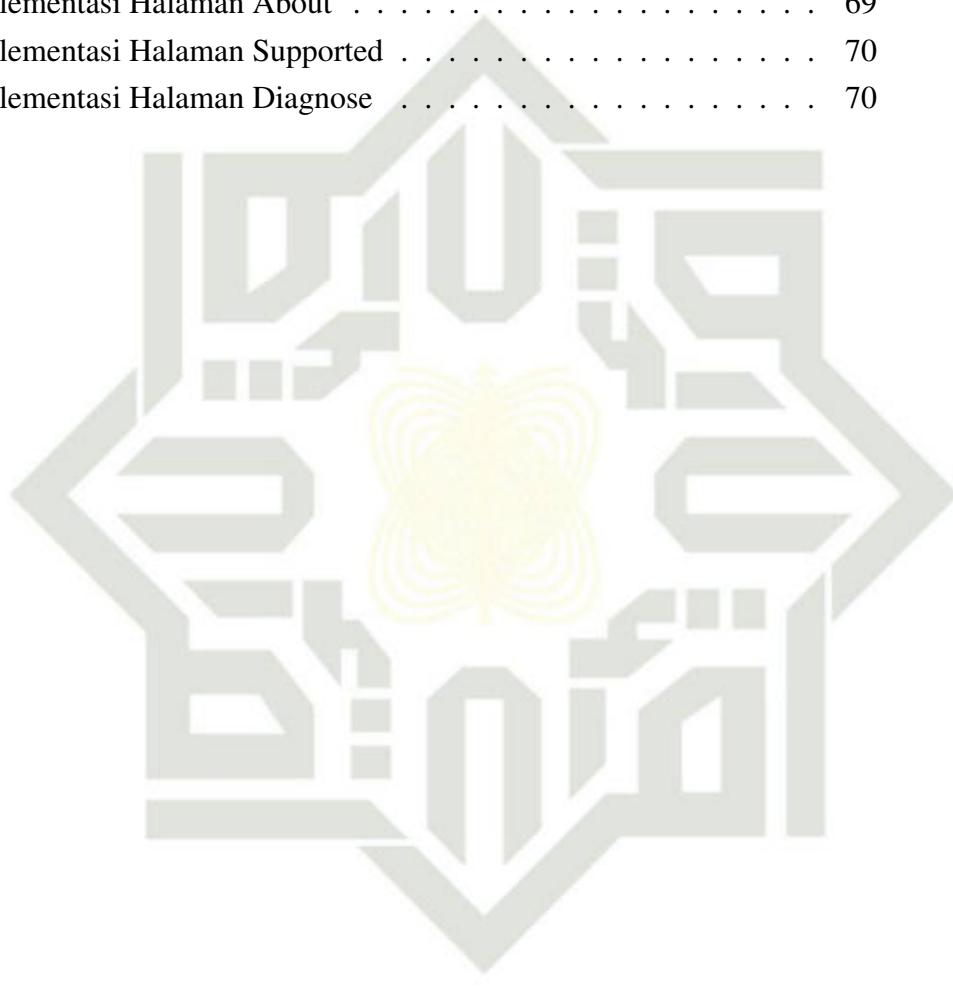
## DAFTAR PUSTAKA

UIN SUSKA RIAU

## DAFTAR GAMBAR

2.1 Tomato Healthy . . . . .	10
2.2 Target Spot . . . . .	10
2.3 Bacterial Spot . . . . .	11
2.4 Tomato Yellow Leaf Curl Virus . . . . .	12
2.5 Late Blight . . . . .	12
2.6 Leaf Mold . . . . .	13
2.7 Early Blight . . . . .	14
2.8 Two spotted spider mite . . . . .	14
2.9 Tomato mosaic virus . . . . .	15
2.10 Tomato septoria spot . . . . .	16
2.11 Lapisan CNN . . . . .	18
2.12 Jaringan Arsitektur DenseNet201 . . . . .	19
2.13 Alur pemrosesan citra pada model Inception V3 . . . . .	20
2.14 Arsitektur MobileNetV2 . . . . .	21
2.15 Confusion Matrix . . . . .	26
3.1 Metodologi . . . . .	33
3.2 Perancangan Model CNN . . . . .	35
4.1 Visualisasi Dataset Citra Penyakit Daun Tomat . . . . .	44
4.2 Hasil Augmentasi . . . . .	46
4.3 Kurva Model Deep Learning DenseNet201 Optimizer Adam . . . . .	48
4.4 Kurva Model Deep Learning DenseNet201 Optimizer RMSprop . . . . .	48
4.5 Kurva Model Deep Learning InceptionV3 Optimizer Adam . . . . .	48
4.6 Kurva Model Deep Learning InceptionV3 Optimizer RMSprop . . . . .	49
4.7 Kurva Model Deep Learning MobilNetV2 Optimizer Adam . . . . .	49
4.8 Kurva Model Deep Learning MobilNetV2 Optimizer RMSprop . . . . .	49
4.9 Confusion Matrix Arsitektur DenseNet201 Optimizer Adam . . . . .	51
4.10 Confusion Matrix Arsitektur DenseNet201 Optimizer RMSprop . . . . .	52
4.11 Confusion Matrix Arsitektur InceptionV3 Optimizer Adam . . . . .	53
4.12 Confusion Matrix Arsitektur InceptionV3 Optimizer RMSprop . . . . .	53
4.13 Confusion Matrix Arsitektur MobileNetV2 Optimizer Adam . . . . .	54
4.14 Confusion Matrix Arsitektur MobileNetV2 Optimizer RMSprop . . . . .	55
4.15 Grafik Batang Evaluasi . . . . .	58
4.16 Flowchart . . . . .	61
4.17 Usecase Diagram . . . . .	63

4.18	Activity Diagram	64
4.19	Sequence Diagram	65
4.20	Halaman Beranda	66
4.21	Halaman About TomatoAi	67
4.22	Halaman Supported	68
4.23	Halaman Diagnose	68
4.24	Implementasi Halaman Home	69
4.25	Implementasi Halaman About	69
4.26	Implementasi Halaman Supported	70
4.27	Implementasi Halaman Diagnose	70



## DAFTAR TABEL

2.1	Penelitian Terdahulu . . . . .	27
4.1	Data yang Digunakan . . . . .	45
4.2	Hasil Pembagian Data Hold Out 80:10:10 . . . . .	45
4.3	Pengaturan Hyperparameter . . . . .	47
4.4	Hasil Akurasi Pelatihan Model . . . . .	50
4.5	Hasil Evaluasi Model CNN . . . . .	56
4.6	Hasil Pengujian Sistem Menggunakan Data Primer . . . . .	71



UIN SUSKA RIAU

## © Hak cipta milik UIN Suska Riau

## State Islamic University of Sultan Syarif Kasim Riau

### Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
  - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
  - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

## DAFTAR SINGKATAN

FAO	: Food and Agriculture Organization
BPS	: Badan Pusat Statistik
CNN	: Convolutional Neural Network
TYLCV	: Tomato Yellow Leaf Curl Virus
TMV	: Tomato Mosaic Virus
DL	: Deep Learning
ML	: Machine Learning
GPU	: Graphics Processing Unit
TPU	: Tensor Processing Unit
RNN	: Recurrent Neural Network
GAN	: Generative Adversarial Network
SGD	: Stochastic Gradient Descent
ADAM	: Adaptive Moment Estimation
RMSProp	: Root Mean Square Propagation
TN	: True Negative
FP	: False Positive
FN	: False Negative
TP	: True Positive

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
  - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
  - b. Pengutipan tidak mengurangi kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

## BAB 1

### PENDAHULUAN

#### 1.1 Latar Belakang

Tanaman tomat merupakan salah satu komoditas pertanian strategis yang memiliki peran penting dalam ketahanan pangan global, baik sebagai bahan pangan maupun sumber pendapatan petani skala kecil. Namun, produktivitas tanaman tomat seringkali terancam oleh serangan berbagai penyakit daun, seperti bercak bakteri (*bacterial spot*), hawar awal (*early blight*), hawar akhir (*late blight*), dan virus keriting kuning (*yellow leaf curl virus*). Penyakit-penyakit ini tidak hanya mengurangi hasil panen secara kuantitas tetapi juga menurunkan kualitas buah, sehingga berdampak signifikan terhadap ekonomi petani (Raza, Hammed, Shaikh, dan Ahmed, 2025a). Menurut Food and Agriculture Organization (FAO), sekitar 40% produksi pertanian global hilang setiap tahun akibat serangan hama dan penyakit, termasuk pada tanaman tomat. (Raza, Hammed, Shaikh, dan Ahmed, 2025b) Di negara-negara berkembang seperti Indonesia, petani umumnya masih menganalisa metode identifikasi penyakit secara manual melalui pengamatan visual, yang sangat rentan terhadap kesalahan diagnosis akibat keterbatasan pengetahuan dan pengalaman. (Jatinderkumar dan Saini, 2023) Kondisi ini seringkali mengakibatkan penanganan yang tidak tepat waktu, memperparah kerusakan tanaman, dan bahkan menyebabkan gagal panen total (Kumar, Sony, Premkumar, Meenakshi, dan Nair, 2024). Selain itu, ketergantungan pada pestisida kimia sebagai solusi utama menimbulkan masalah baru, seperti resistensi patogen, pencemaran lingkungan, dan peningkatan biaya produksi (Qiu, Lu, Wang, Chen, dan Chen, 2024).

Tanaman tomat merupakan salah satu komoditas strategis di Indonesia dengan produksi mencapai 1.168.743 ton pada tahun 2022 dan pertumbuhan sekitar 4,6% per tahun selama lima tahun terakhir berdasarkan data dari Badan Pusat Statistik (BPS). Produksi utama tersebar di provinsi Jawa Barat, Jawa Timur, Sumatera Utara, dan Sumatera Barat. Namun, produktivitas tomat seringkali terancam oleh penyakit daun, seperti bakteri layu yang prevalensinya di daerah seperti Kabupaten Karo mencapai 31,58% hingga 57,07% (Solimani dkk., 2024). Penyakit ini menyebabkan kerusakan daun yang signifikan dan dapat mengakibatkan gagal panen, seperti yang dialami petani dengan varietas Servo F1 di lokasi tersebut (Rahmadhani, 2021). Penanganan dan deteksi penyakit secara tepat, termasuk penggunaan teknologi deep learning yang mampu mengklasifikasi penyakit dengan akurasi tinggi (93%), sangat diperlukan untuk mengurangi kerugian petani (Das, Pathan, Rahman, Kabir, dan Mridha, 2025).

Dari segi dampak ekonomi, penyakit seperti *bacterial spot* pada tomat dapat menyebabkan kerugian hingga 66% dari total produksi, tergantung pada tingkat infeksi dan kondisi iklim (Aishwarya dan Reddy, 2023). Sementara itu, penyakit hawar akhir (*late blight*) yang disebabkan oleh *Phytophthora infestans* bahkan dapat memusnahkan seluruh tanaman dalam waktu singkat jika tidak terdeteksi sejak dini (Joshi, Hooda, Sharma, Sonah, dan Deshmukh, 2025). Data-data ini memperkuat urgensi pengembangan sistem deteksi otomatis yang cepat dan akurat. Selain itu, dengan proyeksi populasi global yang akan melebihi 9 miliar pada tahun 2050, permintaan terhadap produksi tomat diperkirakan meningkat signifikan, sehingga pencegahan kehilangan hasil panen akibat penyakit menjadi semakin kritis (Mo dan Wei, 2025).

Untuk mengatasi permasalahan ini, beberapa solusi telah diusulkan, mulai dari peningkatan kapasitas petani melalui pelatihan identifikasi penyakit hingga penerapan teknologi berbasis kecerdasan buatan (*artificial intelligence*) (Abdullahi, Ackley, Marvellous, dan Ebriba, 2025). Pelatihan petani memang penting, tetapi membutuhkan waktu dan biaya besar serta tidak selalu efektif karena keterbatasan sumber daya manusia di daerah pedesaan (Indolia, Kumar, Mishra, dan Asopa, 2018). Sementara itu, penggunaan pestisida secara rutin, meskipun dapat mencegah penyakit, justru menimbulkan dampak negatif jangka panjang terhadap ekosistem dan kesehatan manusia (Shanthi, Vinutha, Ashwini, dkk., 2024). Oleh karena itu, solusi yang semakin populer dan dianggap paling menjanjikan adalah penerapan teknologi *deep learning*, khususnya *Convolutional Neural Network* (CNN), untuk mengidentifikasi penyakit tanaman secara otomatis berdasarkan citra daun. CNN dipilih karena kemampuannya dalam mengekstraksi fitur-fitur kompleks dari citra secara hierarkis, sehingga dapat membedakan pola visual penyakit dengan akurasi tinggi (Hossain, Jahan, Al, dan Ahmed, 2023). Selain itu, CNN telah terbukti efektif dalam berbagai penelitian serupa, seperti deteksi penyakit pada daun jagung dan padi dengan akurasi di atas 95% (Mashamba, Telukdarie, Munien, Onkonkwo, dan Vermeulen, 2024) (Khan, Saquib, Dag, dan Kumar, 2024).

Solusi berbasis CNN juga didukung oleh kemajuan teknik *transfer learning*, yang memungkinkan penggunaan model pra-terlatih seperti VGG16 atau InceptionV3 untuk mempercepat proses pelatihan dan meningkatkan akurasi (Nobel, Afroj, Kabir, dan Mridha, 2024). Misalnya, Selanjutnya, Muhammad Islahfari Wahid dkk. (2022) mengombinasikan InceptionV3, Xception, dan VGG16 melalui pendekatan ensemble stacking (Wahid, Lawi, dan Siddik, 2022). Penelitian ini menunjukkan bahwa model InceptionV3 memiliki akurasi validasi 91%, sedangkan performa meningkat hingga 99% setelah dilakukan ensemble. Penelitian

**Hak Cipta Dilindungi Undang-Undang**

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:

a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.

2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

oleh (Okamisar, Hayami, dan Fuad, 2025) dan (Awalia, 2022a) menunjukkan bahwa DenseNet mampu memberikan akurasi tinggi (95–92%) dengan stabilitas baik dalam dataset besar seperti PlantVillage (Haycami et al., 2025). Penelitian oleh (Aryaputra, Widodo, dan Sanjaya, 2025) dan (Palupiningsih, Sujiwanto, dan Prawirodirjo, 2023) membuktikan bahwa model MobileNetV2 tetap dapat mencapai akurasi tinggi (>90%) meskipun kompleksitas modelnya rendah, sehingga cocok untuk implementasi pada perangkat dengan sumber daya terbatas (Aryaputra dkk., 2025). Namun, penelitian terdahulu seperti yang dilakukan oleh (Mashamba dkk., 2024) mengungkapkan kelemahan model CNN ketika diuji dengan data lapangan, di mana akurasi turun drastis menjadi 64,32%-69,61% (Shanthy dkk., 2024). Hal ini menunjukkan bahwa model yang dilatih dengan data laboratorium mungkin kurang robust ketika dihadapkan pada variasi kondisi di lapangan, seperti perbedaan pencahayaan, sudut pengambilan gambar, atau tingkat kerusakan daun (Islam dkk., 2022). Oleh karena itu, penelitian ini akan berfokus pada pengembangan model CNN yang tidak hanya akurat tetapi juga generalis, dengan memanfaatkan dataset yang lebih beragam berasal dari beberapa penelitian sebelumnya, serta teknik augmentasi data seperti rotasi, *flipping*, dan *zoom* untuk meningkatkan ketahanan model terhadap variasi input (Singh, Chug, dan Singh, 2023).

Pendekatan Convolutional Neural Network (CNN) telah terbukti efektif dalam mengklasifikasikan berbagai penyakit tanaman, termasuk penyakit pada daun tomat. Meskipun demikian, sebagian besar penelitian sebelumnya masih berfokus pada satu jenis arsitektur CNN tanpa melakukan analisis mendalam terhadap variasi optimizer yang berpotensi meningkatkan kemampuan generalisasi model. Penelitian ini mengusulkan penggunaan CNN dengan tiga arsitektur unggulan MobileNetV2, InceptionV3, dan DenseNet201 serta dua optimizer, yaitu Adam dan RMSprop, untuk meningkatkan akurasi serta kemampuan generalisasi dalam klasifikasi penyakit daun tomat. Evaluasi kinerja model dilakukan menggunakan metrik akurasi, presisi, recall, dan F1-score, dengan pembagian data menggunakan metode hold-out validation pada rasio 80:20. Tujuan utama penelitian ini adalah menemukan kombinasi arsitektur dan algoritma optimasi terbaik untuk klasifikasi citra penyakit daun tomat dari dataset Tomato Leaf Disease. Melalui penelitian ini, diharapkan diperoleh model klasifikasi citra yang mampu mendukung proses deteksi dari penyakit daun tomat secara efisien dengan memanfaatkan pendekatan Deep Learning, khususnya melalui pemodelan Convolutional Neural Network (CNN).

## 1.2 Perumusan Masalah

Berdasarkan latar belakang yang telah dipaparkan, rumusan masalah dalam penelitian ini adalah bagaimana penerapan algoritma Convutional Neural Network (CNN) dengan beberapa arsitektur yaitu MobileNetV2, InceptionV3, dan DenseNet201, dengan dua jenis optimizer yaitu Adam dan RMSprop, dalam mengklasifikasikan penyakit daun tomat.

## 1.3 Batasan Masalah

Dalam melakukan penelitian, penting untuk menetapkan batasan-batasan masalah agar tetap terfokus pada rencana yang telah ditetapkan. Oleh karena itu, batasan masalah pada penelitian ini yaitu:

1. Penelitian ini hanya menggunakan dataset kaggle Tomato Leaf Diseases (<https://www.kaggle.com/datasets/kaustubhb999/tomatoleaf> ) yang berisi gambar daun tomat untuk proses klasifikasi.
2. Objek penelitian hanya difokuskan pada citra daun tomat, baik yang sehat maupun yang terinfeksi penyakit. Penelitian tidak mencakup identifikasi penyakit pada bagian tanaman lain seperti buah, akar, atau batang.
3. Kategori klasifikasi ada 10 kelas yaitu: Tomato Mosaic Virus, Target Spot, Bacterial Spot, Tomato Yellow Leaf Curl Virus, Late Blight, Leaf Mold, Early Blight, Spider Mites, Tomato Healthy, dan Septoria Leaf Spot.
4. Model yang diuji terbatas pada tiga arsitektur CNN, yaitu MobileNetV2, InceptionV3, dan DenseNet201.
5. Optimasi model dilakukan menggunakan dua algoritma optimasi, yaitu Adam dan RMSprop.
6. Pembagian dataset dilakukan menggunakan metode hold-out dengan rasio 80% data latih, 10% data uji, dan 10% data testing
7. Evaluasi performa model hanya menggunakan metrik akurasi, presisi, recall, dan F1-score.
8. Implementasi dan pelatihan dilakukan menggunakan bahasa pemrograman Python dengan Google Colab.
9. Implementasi model dilakukan dalam bentuk prototipe website yang digunakan untuk mengunggah citra daun tomat dan menampilkan hasil prediksi berdasarkan model terbaik. Website ini hanya berfungsi untuk klasifikasi, tanpa integrasi ke database lapangan, sensor IoT, atau real-time monitoring.
10. Model dan sistem yang dikembangkan hanya valid untuk dataset dan ruang lingkup penelitian ini, sehingga hasil prediksi tidak dapat digeneralisasi untuk tanaman atau dataset di luar daun tomat.

#### 1.4 © Hak cipta milik UIN Suska Riau

##### Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
  - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
  - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

#### 1.5 Manfaat

Manfaat penelitian ini adalah:

1. Meningkatkan ketepatan dalam mengenali dan mengklasifikasikan berbagai jenis penyakit daun tomat melalui penerapan algoritma CNN berbasis arsitektur MobileNetV2, InceptionV3, dan DenseNet201.
2. Menjadi referensi metodologis terkait penggunaan tiga arsitektur CNN (DenseNet201, InceptionV3, dan MobileNetV2) serta dua optimizer (Adam dan RMSProp) dalam menentukan konfigurasi model deep learning yang optimal.
3. Memberikan informasi teknis terkait hasil evaluasi model menggunakan metrik akurasi, presisi, recall, dan F1-score yang dapat digunakan sebagai acuan dalam pengembangan penelitian serupa.
4. Menghasilkan prototipe website klasifikasi penyakit daun tomat yang dapat digunakan sebagai alat bantu pendekripsi penyakit secara otomatis berdasarkan citra daun.
5. Membantu pelaku di bidang pertanian, pendidikan, dan pelestarian lingkungan dalam mengidentifikasi penyakit daun tomat secara efisien tanpa harus bergantung pada tenaga ahli.
6. Menjadi referensi bagi peneliti selanjutnya dalam mengembangkan sistem klasifikasi daun tomat dengan model CNN dan algoritma optimasi yang lebih baik.

#### 1.6 Sistematika Penulisan

Penulisan dalam penelitian ini disusun dengan sistematika sebagai berikut:

- Hak Cipta Dilindungi Undang-Undang**
1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
    - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
    - b. Pengutipan tidak mengikuti kepentingan yang wajar UIN Suska Riau.
  2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

## BAB 1. PENDAHULUAN

Bab ini Bagian pendahuluan diawali dengan latar belakang yang menjelaskan pentingnya tanaman tomat sebagai komoditas strategis serta permasalahan yang ditimbulkan oleh berbagai penyakit daun yang menyerang. Selanjutnya, pada bab ini juga disajikan rumusan masalah yang merumuskan pertanyaan utama mengenai bagaimana merancang pemodelan klasifikasi penyakit daun tomat berbasis Convolutional Neural Network (CNN) dengan menggunakan arsitektur MobileNetV2, InceptionV3, dan DenseNet201 yang dioptimasi dengan algoritma Adam dan RMSprop. Selain itu, terdapat batasan masalah yang menegaskan ruang lingkup penelitian agar lebih terfokus, tujuan penelitian yang ingin dicapai, serta manfaat penelitian baik secara teoretis maupun praktis.

## BAB 2. LANDASAN TEORI

Bab ini berisi Teori yang dibahas meliputi penjelasan mengenai penyakit daun tomat, konsep deep learning sebagai salah satu cabang dari kecerdasan buatan, serta penjelasan rinci mengenai Convolutional Neural Network (CNN) sebagai metode utama yang digunakan untuk klasifikasi citra. Selain itu, dibahas pula tiga arsitektur CNN yaitu DenseNet201 dengan koneksi padat antar lapisan, InceptionV3 yang menekankan efisiensi komputasi melalui teknik factorization, serta MobileNetV2 yang dirancang untuk perangkat dengan keterbatasan sumber daya. Pada bagian ini juga dijelaskan algoritma optimasi seperti Adam dan RMSprop yang berperan penting dalam proses pelatihan model, serta konsep confusion matrix beserta metrik evaluasi (akurasi, presisi, recall, dan F1-score) yang digunakan untuk menilai performa model.

## BAB 3. METODOLOGI PENELITIAN

Bab ini menjelaskan secara detail metode yang digunakan dalam penelitian. Proses penelitian dimulai dengan tahap perencanaan yang meliputi identifikasi masalah, penentuan tujuan, penetapan batasan masalah, serta studi pustaka. Kemudian dilanjutkan dengan pengumpulan data menggunakan dataset citra penyakit daun tomat dari Kaggle. Selanjutnya dilakukan preprocessing data kemudian dibagi menggunakan teknik hold-out dengan rasio 80:20. berikutnya adalah pemodelan CNN dengan mengimplementasikan tiga arsitektur (DenseNet201, InceptionV3, dan MobileNetV2) yang dipadukan dengan optimizer Adam dan RMSprop. Bab ini juga memuat tahap evaluasi model yang dilakukan dengan menggunakan confusion matrix untuk memperoleh metrik akurasi, presisi, recall, dan F1-score.

## BAB 4. HASIL DAN PEMBAHASAN

Bab ini menyajikan Hasil yang ditampilkan meliputi visualisasi dataset yang digunakan, hasil dari preprocessing data, serta distribusi pembagian data latih, vali-

**Hak Cipta Dilindungi Undang-Undang**

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
  - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
  - b. Pengutipan tidak mengutip kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

dasi, dan uji. Selanjutnya disajikan hasil pelatihan model CNN pada ketiga arsitektur dengan optimizer yang berbeda, ditunjukkan melalui kurva training dan validation accuracy serta kurva loss. Bagian ini juga memuat hasil evaluasi model berupa confusion matrix yang memperlihatkan performa klasifikasi tiap kelas penyakit daun tomat. Pembahasan dilakukan dengan menganalisis perbedaan performa antar model dan optimizer, kelebihan serta kelemahan masing-masing, serta faktor yang memengaruhi akurasi, presisi, recall, dan F1-score. Hasil perbandingan menunjukkan model terbaik dalam penelitian ini serta memberikan dasar ilmiah bagi penerapan CNN dalam klasifikasi penyakit daun tomat secara lebih luas.

**BAB 5. PENUTUP**

Bab ini berisi Kesimpulan dari hasil penelitian yang telah dilakukan, menegaskan temuan utama terkait penerapan CNN dengan arsitektur MobileNetV2, InceptionV3, dan DenseNet201 serta optimizer Adam dan RMSprop dalam klasifikasi penyakit daun tomat. Selain itu, disajikan juga saran-saran untuk penelitian selanjutnya, seperti eksplorasi arsitektur CNN lainnya, penggunaan dataset yang lebih beragam, serta penerapan teknik augmentasi data yang lebih kompleks guna meningkatkan kemampuan generalisasi model.

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
  - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
  - b. Pengutipan tidak mengurangi kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

## BAB 2

### LANDASAN TEORI

#### 2.1 Daun Tomat

Tanaman tomat (*Solanum lycopersicum* L.) merupakan salah satu tanaman hortikultura yang penting secara ekonomi dan dikenal memiliki berbagai bagian tanaman yang penting, termasuk daun. Daun tomat memiliki susunan spiral, lebar daun 10-30 cm, dan panjang 15-50 cm. Daunnya berbentuk bulat telur hingga lonjong, dan dikelilingi oleh rambut kelenjar (Ayu Purnamasari dan Alfassabiq Khairi, 2024). Morfologi daun ini cukup kompleks dengan permukaan yang berambut halus dan kelenjar yang menghasilkan senyawa kimia tertentu yang berfungsi sebagai mekanisme pertahanan alami tanaman. Daun tomat juga terlibat aktif dalam proses fotosintesis yang sangat penting untuk pertumbuhan dan perkembangan tanaman secara keseluruhan (Raksun, Merta, dan Mertha, 2021).

Secara kimiawi, daun tomat mengandung berbagai metabolit sekunder yang berperan penting dalam aktivitas biologis tanaman maupun potensi aplikasinya dalam dunia kesehatan dan pertanian. Senyawa utama yang ditemukan pada daun tomat meliputi flavonoid, saponin, alkaloid, serta minyak atsiri. Flavonoid dan alkaloid dalam daun tomat telah terbukti memiliki sifat antibakteri dan insektisida, yang dapat digunakan sebagai bahan alami untuk mengendalikan hama seperti nyamuk *Aedes aegypti* (Kanedi, 2020).

Selain manfaat di bidang pertanian, daun tomat juga mengandung antioksidan yang bermanfaat untuk kesehatan. Senyawa fenolik dan flavonoid dalam daun tomat mampu menangkal radikal bebas, sehingga memberikan perlindungan terhadap stres oksidatif yang dapat merusak sel tubuh. Berbagai penelitian telah mengkonfirmasi aktivitas antioksidan dari ekstrak daun tomat yang potensial digunakan dalam produk-produk kesehatan alami. Dengan kandungan senyawa aktif yang cukup melimpah, daun tomat tidak hanya memiliki peranan sebagai bagian tanaman vital, tetapi juga sebagai sumber bioaktif yang menjanjikan untuk aplikasi lebih luas dalam bidang farmasi dan pestisida nabati (Hal, Ulfah, Putra, Irawan, dan Rizki, 2024).

#### 2.2 Penyakit Bercak Daun Tomat

Penyakit bercak daun pada tanaman tomat merupakan salah satu penyakit utama yang dapat menurunkan kualitas dan kuantitas hasil panen. Penyakit ini umumnya disebabkan oleh berbagai patogen seperti bakteri dan jamur. Infeksi bakteri yang paling umum adalah oleh *Xanthomonas* spp. dan *Pseudomonas* sy-

ringae pv. tomato, yang menimbulkan gejala bercak kuning kehijauan pada daun muda yang kemudian berkembang menjadi bercak coklat dengan tepi kekuningan. Bercak tersebut dapat membesar hingga menyebabkan lubang-lubang pada daun akibat kerusakan jaringan. Penyakit ini menyebar melalui air hujan, irigasi, dan kontak langsung dengan tanaman yang terinfeksi, sehingga pengendalian yang efektif dengan sanitasi lahan dan penggunaan agen biokontrol sangat diperlukan untuk memutus rantai penularan (Nuviani, Martosudiro, dan Choliq, 2023) (Istifadah, Monica, Widiani, dan Hartati, 2021).

Selain bakteri, jamur juga menjadi penyebab utama bercak daun tomat, khususnya jamur Alternaria solani yang menyebabkan penyakit bercak coklat (early blight). Jamur ini menimbulkan bercak coklat dengan pola lingkaran konsentris yang menyebabkan daun menguning, layu, dan akhirnya gugur. Serangan berat dapat menyebabkan buah busuk dan gugur sebelum panen. Penggunaan mikrob antagonis dari air rendaman limbah jamur tiram, serta isolat bakteri dan khamir dari kompos, telah menunjukkan efektivitas dalam menekan perkembangan penyakit ini secara biologis, menjadi alternatif ramah lingkungan pengendalian penyakit bercak daun tomat. Penyakit juga dapat disebabkan oleh jamur Septoria lycopersici yang menimbulkan bercak kecil coklat muda pada permukaan bawah daun, berkembang menjadi kelabu dengan tepi hitam dan berpotensi membunuh tanaman jika infeksi parah (Istifadah dkk., 2021)

### 2.2.1 Tomat Sehat (Tomato Healthy)

Tanaman tomat sehat (*Solanum lycopersicum*) merupakan komoditas hortikultura penting yang kondisinya sangat dipengaruhi oleh faktor lingkungan dan pengelolaan budidaya. Tanaman sehat ditandai dengan pertumbuhan optimal, daun hijau segar tanpa gejala penyakit, serta produksi buah yang berkualitas dan berjumlah cukup. Faktor lingkungan seperti suhu, kelembaban, serta ketersediaan nutrisi berperan besar dalam menjaga kesehatan tanaman tomat. Pengelolaan yang baik melalui pemilihan benih unggul, pemberian pupuk yang seimbang, pengendalian hama dan penyakit secara terpadu, serta pemantauan kondisi tanaman secara rutin sangat diperlukan untuk memastikan tanaman tetap sehat dan produktif. Penelitian menunjukkan bahwa peningkatan kesehatan tanaman tomat dapat dicapai dengan optimasi aplikasi pupuk organik dan anorganik yang tepat sehingga mendukung pertumbuhan, pembungaan, dan hasil panen (Wales, Tulung, dan Mamarimbang, 2023). Gambar Tomat Sehat ditunjukkan pada Gambar 2.1.

**Hak Cipta Dilindungi Undang-Undang**

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
  - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
  - b. Pengutipan tidak mengurangi kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.



**Gambar 2.1.** Tomato Healthy

### **2.2.2 Bintik Target (Target Spot)**

Bintik target (Target Spot) pada tanaman tomat disebabkan oleh jamur *Corynespora cassiicola* yang menyerang tanaman mulai dari usia muda. Gejala khas penyakit ini berupa bercak melingkar dengan pola cincin konsentris yang menyerupai target, sehingga memudahkan identifikasi visual. Bercak ini awalnya kecil lalu membesar, diikuti dengan menguningnya jaringan di sekitar bercak dan kematian jaringan daun. Penyakit ini dapat menurunkan kualitas dan kuantitas hasil panen tomat jika tidak dikendalikan dengan baik. Penelitian terbaru menunjukkan bahwa identifikasi penyakit ini bisa dilakukan secara otomatis menggunakan teknologi deep learning dengan akurasi tinggi, yang berpotensi mendukung pengelolaan penyakit secara efisien dalam pertanian modern (Putra, Ridwan, Abi Ansyah, dan Agustin, 2024). Gambar Bintik Target ditunjukkan pada Gambar 2.2.



**Gambar 2.2.** Target Spot

### **2.2.3 Bintik Bakteri (Bacterial Spot)**

Penyakit bintik bakteri pada tomat disebabkan oleh bakteri patogen *Xanthomonas perforans* yang merupakan salah satu penyebab utama kerusakan daun

dan buah tomat. Gejala khasnya berupa bercak coklat kehitaman pada daun, batang, dan buah dengan halo kekuningan di sekeliling bercak tersebut, yang dapat menyebabkan jaringan daun mati dan berlubang (shot-hole). Penyakit ini mudah menyebar melalui air hujan, irrigasi, dan kontak alat pertanian yang terkontaminasi, sehingga cepat menyebar di area penanaman. Pengendalian penyakit bintik bakteri biasanya dilakukan dengan sanitasi yang baik, penggunaan benih bebas patogen, serta aplikasi bahan pengendali seperti tembaga dan penggunaan agen hayati yang sedang dikembangkan untuk alternatif lebih ramah lingkungan (Aulia dan Puspita, 2023). Gambar Bintik Bakteri ditunjukkan pada Gambar 2.3.



**Gambar 2.3. Bacterial Spot**

#### 2.2.4 Virus Keriting Daun Kuning Tomat (Tomato Yellow Leaf Curl Virus)

Virus Keriting Daun Kuning Tomat (TYLCV) merupakan penyakit yang disebabkan oleh virus dari keluarga Geminiviridae, marga Begomovirus, yang ditularkan oleh vektor kutu kebul (Bemisia tabaci). Serangan TYLCV pada tanaman tomat ditandai dengan gejala daun mengkerut, mengecil, berwarna kuning cerah (Klorosis), serta permukaan daun menjadi tebal dan bertekstur kasar. Tanaman yang terinfeksi juga mengalami pertumbuhan yang terhambat atau kerdil, dan jumlah buah yang dihasilkan menurun signifikan. Virus ini tidak ditularkan melalui biji, namun menyebar cepat melalui vektor serangga tersebut, sehingga pengendalian lebih efektif dilakukan dengan pengelolaan vektor dan penggunaan varietas tahan. Infeksi TYLCV menjadi salah satu kendala utama dalam produksi tomat di berbagai daerah terutama di wilayah tropis dan subtropis (Gunaeni dan Purwati, 2013). Gambar Virus Keriting Daun Kuning Tomat ditunjukkan pada Gambar 2.4.

**Hak Cipta Dilindungi Undang-Undang**

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
  - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
  - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.



**Gambar 2.4.** Tomato Yellow Leaf Curl Virus

### 2.2.5 Penyakit Busuk Daun (Late Blight)

Penyakit busuk daun (Late blight) pada tanaman tomat disebabkan oleh patogen oomycete *Phytophthora infestans* yang bersifat sangat merusak. Gejala utama penyakit ini adalah munculnya bercak coklat kehijauan pada daun yang segera melebar dan menyebabkan jaringan daun membusuk dan mati. Dalam kondisi lembap dan basah, penyakit ini berkembang dengan cepat dan dapat menyebar ke seluruh bagian tanaman, bahkan menyebabkan kematian tanaman dalam waktu singkat jika tidak dikendalikan. Late blight juga dapat menyerang buah dan batang, sehingga mengurangi kualitas serta kuantitas hasil panen tomat secara signifikan. Pengendalian yang efektif dilakukan melalui penerapan metode kultur teknis, pengendalian kimiawi dengan fungisida, serta penggunaan varietas tahan penyakit (Humuntal, Silalahi, Sidauruk, dan Sinambela, 2022). Gambar Penyakit Busuk Daun ditunjukkan pada Gambar 2.5.



**Gambar 2.5.** Late Blight

## 2.2.6 Jamur Daun (Leaf Mold)

Penyakit jamur daun (Leaf Mold) pada tomat disebabkan oleh jamur *Cladosporium fulvum* yang umumnya berkembang subur pada lingkungan dengan kelembapan tinggi di atas 80%. Gejala serangan muncul sebagai bercak-bercak kecil berwarna hijau pucat atau kuning pada bagian atas daun, sedangkan di bagian bawah daun tumbuh spora berwarna abu-abu muda yang kemudian berubah menjadi coklat atau hijau kekuningan seperti beludru. Daun yang terinfeksi akan menguning, mengering, menggulung, dan akhirnya gugur sebelum waktunya. Penyakit ini menyebabkan penurunan kualitas daun yang berpotensi menurunkan hasil panen akibat berkurangnya kemampuan fotosintesis tanaman. Pengendalian penyakit ini dapat dilakukan dengan menjaga kelembapan lingkungan agar tidak terlalu tinggi serta penggunaan fungisida yang sesuai serta varietas tahan penyakit (Awalia, 2022b). Gambar Jamur Daun ditunjukkan pada Gambar 2.6.



Gambar 2.6. Leaf Mold

## 2.2.7 Penyakit Busuk Daun Dini (Early blight)

Penyakit busuk daun dini (Early blight) pada tanaman tomat disebabkan oleh jamur patogen *Alternaria solani*. Gejala penyakit ini tampak berupa bercak-bercak coklat dengan pola lingkaran konsentris pada daun yang lama kelamaan menyebabkan jaringan daun mengering dan rontok. Serangan penyakit ini biasanya mulai pada daun yang lebih tua bagian bawah dan dapat menyebar ke seluruh tanaman jika kondisi lingkungan mendukung, seperti kelembapan tinggi dan suhu sedang. Penyakit ini sangat merugikan karena dapat menurunkan produksi dan kualitas buah tomat. Pengendalian dilakukan dengan pemilihan varietas tahan, sanitasi lahan, serta penggunaan fungisida yang tepat (Humuntal dkk., 2022). Gambar Penyakit Busuk Daun Dini ditunjukkan pada Gambar 2.7.

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
- Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
  - Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

**Hak Cipta Dilindungi Undang-Undang**

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
  - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
  - b. Pengutipan tidak mengurangi kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.



**Gambar 2.7. Early Blight**

### 2.2.8 Tungau Laba-Laba Berbintik Dua (Two-Spotted Spider Mite)

Penyakit tungau laba-laba berbintik dua (Two-spotted spider mite), atau *Tetranychus urticae*, merupakan hama penting yang menyerang tanaman tomat dan menyebabkan kerusakan cukup besar pada daun melalui aktivitas penghisapan cairan sel daun. Serangan tungau ini menyebabkan munculnya bercak-bercak klorotik pada permukaan daun, yang lama-kelamaan dapat mengakibatkan daun menguning, mengering, dan rontok sehingga menurunkan kemampuan fotosintesis tanaman secara signifikan. Populasi tungau ini dapat berkembang pesat terutama pada kondisi lingkungan yang kering dan panas. Penelitian terbaru menunjukkan bahwa intercropping tanaman tomat dengan tanaman seperti bawang merah dan penggunaan ekstrak daun tembakau dapat mengurangi populasi tungau ini secara efektif, sebagai alternatif pengendalian yang ramah lingkungan dibandingkan penggunaan insektisida kimia yang rentan menimbulkan resistensi (Liu dkk., 2020). Gambar Tungau Laba-Laba Berbintik Dua ditunjukkan pada Gambar 2.8.



**Gambar 2.8. Two spotted spider mite**

### 2.2.9 Virus Mosaik Tomat (Tomato Mosaic Virus)

Virus mosaik tomat (Tomato mosaic virus/TMV) adalah penyakit yang disebabkan oleh virus dari keluarga Tobamovirus yang menyerang berbagai bagian tanaman tomat. Gejala infeksi TMV ditandai dengan munculnya bercak mosaik berwarna hijau dan kuning pada daun, distorsi daun seperti mengkerut dan menggulung, serta pertumbuhan tanaman yang terhambat hingga tanaman menjadi kerdil. Buah tomat yang terinfeksi sering menunjukkan pembentukan bintik-bintik coklat dan pemasakan yang tidak merata, sehingga berdampak negatif pada produksi. Virus ini dapat menyebar melalui benih, alat pertanian, dan kontak mekanik selama penanganan tanaman. Pengendalian penyakit ini biasanya sulit dilakukan secara kimia, sehingga lebih mengandalkan pencegahan melalui penggunaan benih bebas virus dan praktik budidaya yang baik (Kurniawati dan Suastika, 2015). Gambar Virus Mosaik Tomat ditunjukkan pada Gambar 2.9.



Gambar 2.9. Tomato mosaic virus

### 2.2.10 Bercak Daun Septoria (Septoria Leaf Spot)

Penyakit bercak daun Septoria pada tanaman tomat disebabkan oleh jamur Septoria lycopersici yang menyerang daun, terutama daun yang sudah tua. Gejala penyakit ini adalah munculnya bercak-bercak kecil bulat berwarna coklat muda dan berair pada permukaan bawah daun yang berubah menjadi kelabu dengan tepi berwarna hitam. Bercak ini dapat menyatu, menyebabkan daun menguning, mengering, menggulung, dan akhirnya gugur. Penyakit ini berkembang pesat pada kondisi lingkungan lembap dan menyebar melalui air, angin, serta kontak langsung antar tanaman. Pengendalian penyakit dapat dilakukan melalui penggunaan varietas tahan, sanitasi yang baik, rotasi tanaman, serta aplikasi fungisida berbahan aktif tebuconazole atau azoksistrobin (Muchtar, Nurdin, Afdhal, dkk., 2021). Gambar Bercak Daun Septoria ditunjukkan pada Gambar 2.10.

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
  - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
  - b. Pengutipan tidak mengurangi kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.



**Gambar 2.10.** Tomato septoria spot

## 2.3 Data Mining

Data mining adalah proses otomatis untuk menemukan pola dan informasi berharga dari kumpulan data yang sangat besar, sering dikenal sebagai Big Data. Perkembangan teknologi penyimpanan dan pengumpulan data yang pesat telah menghasilkan volume data yang sangat besar, sehingga memerlukan teknik khusus untuk mengekstrak informasi yang tersembunyi di dalamnya. Data mining menggabungkan berbagai disiplin ilmu seperti kecerdasan buatan, statistik, pengenalan pola, dan machine learning untuk menganalisis data besar tersebut dengan tujuan menemukan pola baru, hubungan, dan tren yang berguna dalam berbagai bidang, termasuk bisnis, kesehatan, dan ilmu sosial. Proses data mining biasanya meliputi tahapan pemahaman data, persiapan data, pemodelan, evaluasi, dan penyebaran hasil (Maulana, 2018).

Pada praktiknya, data mining diaplikasikan untuk menyelesaikan berbagai permasalahan seperti segmentasi pelanggan dalam bisnis, deteksi kecurangan, prediksi tren pasar, dan analisis genom dalam bidang medis. Algoritma yang umum digunakan dalam data mining antara lain decision tree, clustering, regresi, dan neural networks. Keberhasilan data mining bergantung pada kualitas data dan teknik pemodelan yang dipilih sesuai dengan kebutuhan. Dukungan arsitektur yang baik mulai dari basis data, mesin data mining, modul evaluasi pola, hingga antarmuka pengguna yang interaktif sangat membantu dalam proses transformasi data besar menjadi informasi yang dapat digunakan secara nyata (Maulana, 2018).

## 2.4 Deep Learning

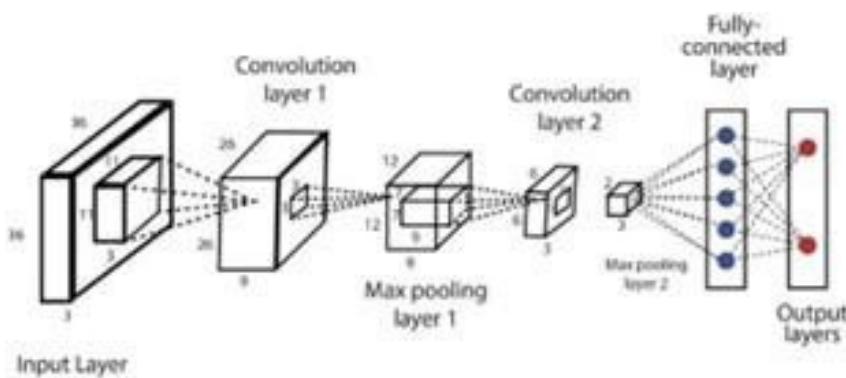
Deep learning adalah cabang dari machine learning yang menggunakan jaringan saraf tiruan dengan banyak lapisan (deep neural networks) untuk mempelajari representasi data secara hierarki dan melakukan ekstraksi fitur secara otomatis dari data mentah (Muhlis dkk., 2025). Teknologi ini berkembang pesat seiring

dengan kemajuan komputasi seperti GPU dan TPU yang memungkinkan pelatihan model yang lebih rumit dan besar serta ketersediaan data besar (big data) dari internet dan berbagai sumber digital. Deep learning memungkinkan pengenalan pola yang sangat kompleks dan hasil pemodelan yang akurat di berbagai bidang, seperti pengenalan wajah, pengolahan bahasa alami, kendaraan otonom, dan diagnosis medis. Fungsi aktivasi seperti ReLU, sigmoid, dan algoritma optimasi seperti Adam mempercepat pelatihan sekaligus meningkatkan kemampuan prediksi model (Fitriani dan Santiani, 2025).

Dalam aspek teknik, deep learning memanfaatkan arsitektur seperti Convolutional Neural Networks (CNN) untuk analisis citra, Recurrent Neural Networks (RNN) dan Transformer untuk data sekuensial, serta Generative Adversarial Networks (GAN) untuk menghasilkan data sintetis (Muhlis dkk., 2025). Keunggulan utama deep learning terletak pada kemampuannya mengidentifikasi fitur tingkat rendah dan menggabungkannya menjadi representasi fitur tingkat tinggi yang lebih bermakna, yang memungkinkan pemecahan masalah yang sangat kompleks dengan tingkat akurasi tinggi. Penerapan deep learning terus diperluas dan menjadi tulang punggung berbagai aplikasi modern, memberikan kontribusi signifikan dalam kemajuan teknologi AI (Akmal dan Maelasari, 2025).

## 2.5 Convolutional Neural Network (CNN)

Jaringan saraf konvolusional (CNN) adalah kelas jaringan saraf dalam yang telah membuktikan keefektifannya dalam tugas-tugas visi komputer (CV), diagnosis berbantuan komputer (CAD), pemrosesan bahasa alami (NLP), dan pengenalan pola. CNN merupakan Salah satu jenis jaringan saraf yang paling disukai, terutama untuk data berdimensi tinggi. Setiap unit dalam lapisan CNN berisi filter berdimensi tinggi yang dikenal sebagai kernel konvolusional. Salah satu kekuatan utama arsitektur CNN adalah dapat menerapkan sejumlah hiperparameter yang wajar guna membantu peneliti untuk membuat berbagai versi model berbasis CNN. CNN dibedakan dari jaringan saraf lainnya oleh lapisan konvolusionalnya, lapisan fitur signifikan yang terdiri dari kumpulan filter konvolusional, Ia mengubah gambar menjadi matriks kompak yang proporsional dengan ukuran kernel dan menekstraksi fitur penting dari gambar (Anam, 2023). Lapisan terhubung penuh, seperti pada Gambar 2.11. (Anton, Nissa, Janiati, Cahya, dan Astuti, 2021).



**Gambar 2.11.** Lapisan CNN

Dalam matematika model CNN menggunakan persamaan sebagai berikut:

$$z^l = f\left(\sum D^{l-1} x * W^l\right) + b^l \quad (2.1)$$

Untuk  $x \in \mathbb{R}^{N \times M}$  yang merepresentasikan sinyal input, di mana  $N$  adalah jumlah sampel dan  $M$  adalah jumlah saluran (misalnya, untuk sinyal satu saluran,  $M = 1$ ). Bobot  $W^l \in \mathbb{R}^{K \times K \times D_{l-1} \times D_l}$  menyatakan matriks bobot dari lapisan konvolusi ke- $l$ , dengan  $K$  sebagai ukuran filter,  $D_{l-1}$  sebagai jumlah saluran input, dan  $D_l$  sebagai jumlah saluran output. Operator  $*$  menyatakan operasi konvolusi,  $f(\cdot)$  adalah fungsi aktivasi, dan  $b^l$  merupakan bias pada lapisan ke- $l$ . Operasi pooling, yang umumnya menggunakan *max pooling*, berfungsi untuk menurunkan resolusi peta fitur guna mengurangi dimensi data serta mengekstraksi fitur-fitur utama (Indolia dkk., 2018).

## 2.6 Arsitektur

Arsitektur dalam konteks deep learning merupakan struktur atau kerangka jaringan saraf tiruan yang mengatur bagaimana lapisan-lapisan neuron tersusun dan saling berinteraksi untuk proses pelatihan model dalam mengenali pola dan fitur dari data. Salah satu arsitektur deep learning yang terkenal adalah VGG-19, yang terdiri dari 19 lapisan dengan 16 lapisan konvolusional dan 3 lapisan fully connected. Model ini menggunakan kernel kecil berukuran  $3 \times 3$  dengan stride 1 yang membantu mempertahankan resolusi spasial input, sehingga memungkinkan ekstraksi fitur penting dari data gambar secara efektif. Peningkatan jumlah filter secara bertahap dari 64 hingga 512 dalam lapisan-lapisan yang lebih dalam memungkinkan model menangkap representasi fitur yang semakin kompleks dan abstrak. Kombinasi arsitektur yang sederhana namun mendalam ini telah terbukti berhasil dalam berbagai tugas pengenalan pola visual dengan performa tinggi, termasuk klasifikasi gambar dan deteksi objek (Ramadhan dan Hernadi, 2025).

**Hak Cipta Dilindungi Undang-Undang**

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:

a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.

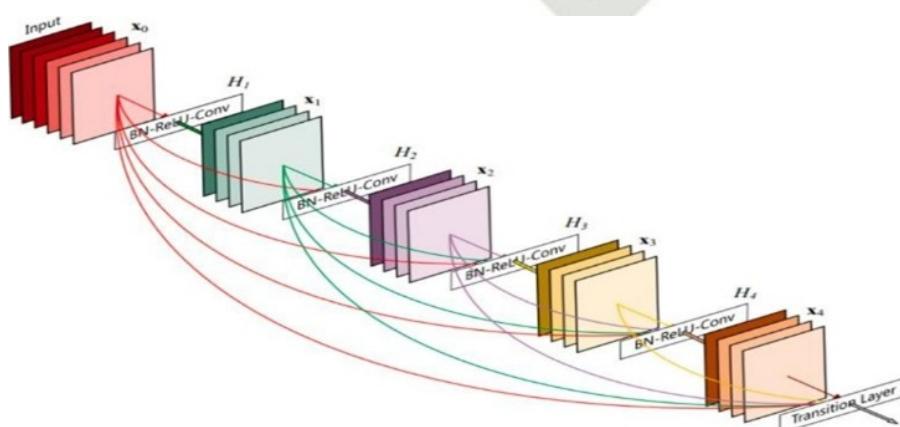
b. Pengutipan tidak menghargai kepentingan yang wajar UIN Suska Riau.

2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

Selain itu, terdapat berbagai arsitektur modern lain seperti ResNet, DenseNet, dan MobileNet yang mengatasi berbagai keterbatasan model terdahulu. ResNet memperkenalkan konsep residual learning yang memungkinkan pembangunan jaringan sangat dalam dengan menghindari masalah hilangnya gradien. DenseNet menghubungkan setiap lapisan dengan lapisan sebelumnya secara langsung untuk meningkatkan aliran informasi dan stabilitas pelatihan, sementara MobileNet dirancang untuk efisiensi tinggi dengan bobot ringan, sesuai untuk perangkat dengan keterbatasan sumber daya. Pengujian menunjukkan bahwa pemilihan arsitektur yang sesuai dapat meningkatkan akurasi dan efisiensi deep learning secara signifikan, membuktikan pentingnya desain arsitektur dalam aplikasi computer vision dan pengolahan citra (Ariawan, 2025).

### 2.6.1 Arsitektur DenseNet201

DenseNet201 adalah jaringan saraf konvolusional (CNN) pembelajaran mendalam yang terdiri dari 201 lapisan. Jaringan ini menonjol karena menggunakan koneksi padat, yang membentuk tautan langsung antara jalur maju dan mundur dalam jaringan saraf. Pilihan arsitektur yang cerdik ini memfasilitasi pembagian dan transmisi fitur yang efisien di berbagai lapisan. Komponen inti DenseNet201 terdiri dari Blok Padat dan Lapisan Transisi. Blok Padat, yang dibangun dari beberapa Lapisan Hambatan, berfungsi sebagai modul utama jaringan model. Mode koneksi padat dalam Blok Padat menghubungkan informasi dari setiap lapisan, memastikan bahwa ukuran keluaran tetap konsisten. DenseNet mengatur jumlah saluran melalui Bottleneck Layers, Transition Layers, and Growth Rate. Hal ini tidak hanya membantu mengurangi jumlah parameter dan mengatasi overfitting tetapi juga secara signifikan mengurangi beban komputasi. Akibatnya, terbukti sangat cocok untuk mengklasifikasikan dan mengenali data dari ukuran sampel kecil. Dapat dilihat pada Gambar 2.12 (Zhou dkk., 2024).

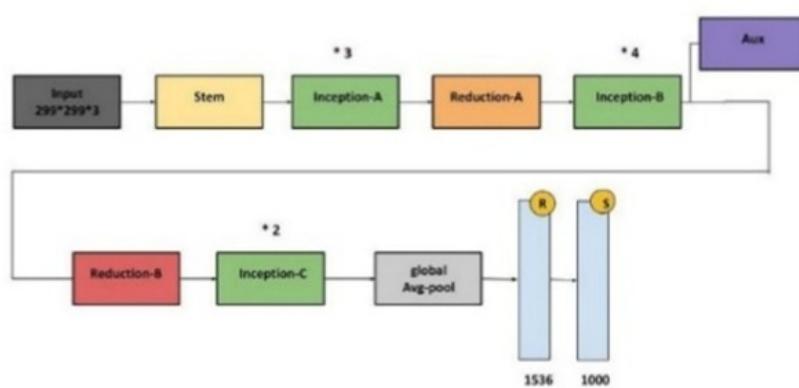


**Gambar 2.12.** Jaringan Arsitektur DenseNet201

Fitur-fitur tersebut digabungkan alih-alih dijumlahkan, yang memungkinkan jaringan memiliki koneksi  $L(L+1)/2$  dalam jaringan lapisan  $L$ . DenseNet menggunakan tingkat pertumbuhan lebih besar dari 1 untuk memungkinkan koneksi padat antar lapisan, yang memberikan setiap lapisan akses langsung ke serangkaian fitur dari lapisan sebelumnya.

### 2.6.2 Arsitektur InceptionV3

InceptionV3 adalah arsitektur Jaringan Syaraf Tiruan (CNN) yang dikembangkan oleh Google dan merupakan pengembangan lanjutan dari arsitektur Inception sebelumnya. InceptionV3 dirancang untuk meningkatkan efisiensi komputasi sekaligus mempertahankan atau bahkan meningkatkan akurasi dalam pengenalan gambar. Arsitektur ini memanfaatkan teknik factorization pada konvolusi, yaitu dengan memecah konvolusi berukuran besar seperti  $5 \times 5$  menjadi beberapa konvolusi lebih kecil seperti  $3 \times 3$  atau kombinasi  $1 \times 3$  dan  $3 \times 1$ . Pendekatan ini bertujuan untuk mengurangi jumlah parameter dan mempercepat proses pelatihan. InceptionV3 juga menggunakan beberapa jenis Inception module (seperti tipe A, B, dan C) yang berfungsi mengekstrak fitur pada berbagai skala secara paralel, serta modul reduction untuk mengecilkan dimensi spasial secara efisien. Arsitektur ini terdiri dari lebih dari 40 lapisan yang disusun secara modular dan menggunakan auxiliary classifier sebagai mekanisme regularisasi tambahan untuk mencegah overfitting. Selain itu, InceptionV3 memanfaatkan batch normalization secara luas untuk meningkatkan stabilitas dan mempercepat proses konvergensi. Dengan desain yang fleksibel dan modular, arsitektur InceptionV3 juga memudahkan penyesuaian parameter dan modifikasi struktur jaringan oleh penggunanya (Shanthappa, Bayari, Abhilash, Gokul, dan Ashish, 2025). Gambar Alur pemrosesan citra pada model Inception V3 ditunjukkan pada Gambar 2.13.

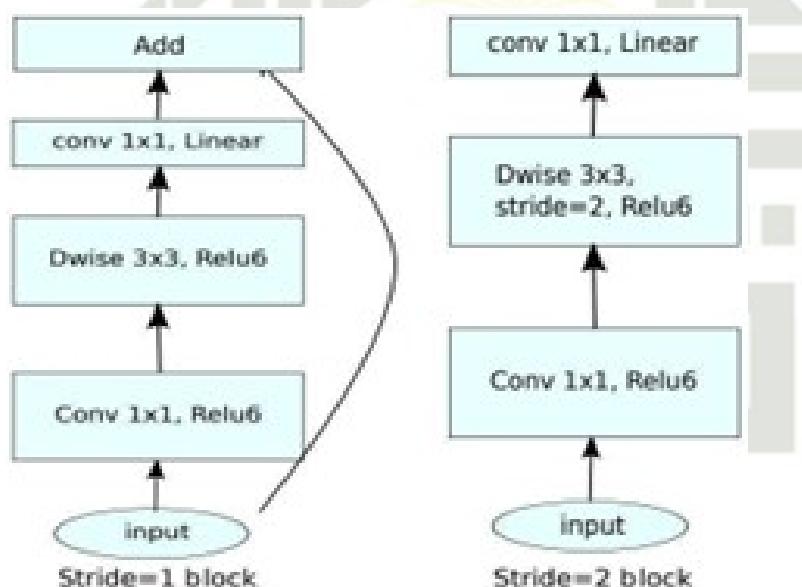


**Gambar 2.13.** Alur pemrosesan citra pada model Inception V3

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
  - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.
  - b. Pengutipan tidak mengutip sebagian kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

### 2.6.3 Arsitektur MobileNetV2

MobileNetV2 adalah arsitektur deep learning yang ringan dan efisien yang dikembangkan oleh Google. Arsitektur ini dirancang untuk berjalan pada perangkat seluler, sistem tertanam, dan lingkungan lain yang memiliki keterbatasan sumber daya, di mana daya komputasi dan memori terbatas. MobileNetV2 merupakan penyempurnaan dari MobileNetV1 asli, yang menawarkan kinerja yang lebih baik dengan tetap mempertahankan efisiensinya. MobileNetV2 terdiri dari dua bagian: ekstraktor fitur (lapisan dasar) dan pengklasifikasi (lapisan atas). Di sini, lapisan dasar MobileNetV2 yang telah dilatih sebelumnya telah dibekukan dan hanya lapisan atas yang dilatih. Lapisan klasifikasi asli dari model MobileNetV2 diganti dengan serangkaian lapisan baru yang sesuai dengan tugas khusus klasifikasi biner. MobileNetV2 merupakan desain jaringan saraf yang efisien yang menggunakan struktur residual terbalik untuk memproses gambar dengan presisi tertinggi dan penundaan minimal. Berikut adalah arsitektur dari MobileNetV2 dapat dilihat pada Gambar 2.14 (Kobiela, Groth, Hajdasz, dan Erezman, 2024).



Gambar 2.14. Arsitektur MobileNetV2

### 2.7 Augmentasi Data

Augmentasi data merupakan teknik penting dalam pembelajaran mesin yang digunakan untuk memperbanyak dan memperkaya variasi data pelatihan tanpa perlu mengumpulkan data baru secara ekstensif. Metode ini melibatkan modifikasi data asli, seperti rotasi, flipping, zoom, translasi, dan perubahan warna, yang bertujuan agar model dapat belajar dari berbagai variasi input sehingga menjadi lebih tangguh dan mampu menggeneralisasi pada data nyata yang beragam. Augmentasi data

sangat krusial terutama saat data asli terbatas, sehingga dapat mencegah overfitting dan meningkatkan performa model deep learning secara signifikan. Penerapan augmentasi secara dinamis selama proses pelatihan juga memungkinkan model mengejel data baru secara berkesinambungan, menjaga keberagaman input dan optimasi hasil pembelajaran (Al-Fahrezi, 2025).

Selain meningkatkan kuantitas data pelatihan, augmentasi data juga berkontribusi pada perbaikan kualitas model dengan memperkaya fitur yang dapat dikenali selama pelatihan. Dengan memperkenalkan variasi yang sistematis namun mempertahankan makna data, teknik ini membantu model memahami pola yang lebih luas dan kompleks, terutama dalam pengolahan citra dan pengenalan pola. Studi menunjukkan bahwa strategi augmentasi yang efisien dapat meningkatkan akurasi model, mempercepat konvergensi pelatihan, dan mengurangi ketergantungan pada dataset yang besar dan mahal. Oleh karena itu, augmentasi data menjadi praktik wajib dalam pengembangan aplikasi deep learning untuk menghasilkan model yang handal dan adaptif di berbagai kondisi (Sastra Mandala, Sari, dan Novrina, 2025).

## 2.8 Optimizer

Optimizer adalah algoritma yang digunakan untuk mengatur dan memperbarui bobot-bobot dalam jaringan saraf tiruan selama proses pelatihan agar fungsi kerugian (loss function) dapat diminimalkan secara efektif. Fungsi utama optimizer adalah untuk mencari nilai parameter yang paling optimal agar model deep learning dapat menghasilkan prediksi yang akurat. Beberapa jenis optimizer yang populer dan sering digunakan adalah Stochastic Gradient Descent (SGD), Adaptive Moment Estimation (Adam), dan RMSProp. SGD merupakan metode sederhana yang menggunakan subset data secara acak untuk memperbarui bobot, sehingga lebih efisien secara komputasi namun dapat menyebabkan fluktuasi selama pelatihan. Sedangkan Adam menggabungkan keuntungan metode adaptive gradient dan momentum untuk mempercepat konvergensi dan stabilitas pelatihan, membuatnya sangat populer untuk berbagai aplikasi deep learning (Kurniadi, Shidiq, dan Mulyani, 2025).

Pemilihan optimizer yang tepat sangat berpengaruh terhadap performa dan kecepatan pelatihan model. Optimizer yang mampu menyesuaikan laju pembelajaran (learning rate) secara dinamis, seperti Adam, biasanya menghasilkan stabilitas lebih baik dan konvergensi yang lebih cepat dibandingkan metode klasik. Selain itu, varian dari SGD yang dilengkapi dengan momentum atau teknik pengaturan learning rate adaptif semakin memperkuat efisiensi pelatihan dan daya generalisasi model. Perbandingan berbagai optimizer dalam berbagai penelitian menunjukkan bahwa Adam sering memberikan hasil akurasi yang lebih tinggi dengan waktu

pelatihan yang lebih singkat, namun dalam beberapa kasus tertentu, SGD tetap dipilih karena kesederhanaannya dan efek regularisasi yang membantu mencegah overfitting (Ardiansyah, 2025).

### 2.8.1 Optimizer Adam

Dynamically adjusts each parameter's learning rate for Adaptive Moment Estimation (Adam), yang merupakan RMSprop dengan suku momentum. Setiap laju pembelajaran iterasi memiliki rentang tertentu, yang menghasilkan parameter yang sangat stabil merupakan manfaat utama Adam. Ini adalah versi yang paling populer dari yang diusulkan. Adam menggabungkan rata-rata bergerak secara eksponensial pada momentum orde kedua dengan momentum orde pertama untuk menerapkan percepatan momentum adaptif dan laju pembelajaran. Algoritma ini secara efisien mengeksplorasi ruang parameter sambil juga mengoreksi bias, sekaligus menghemat sumber daya komputasi dengan menyediakan tingkat pembelajaran adaptif yang berbeda untuk berbagai parameter (Kang, Zhu, Shen, dan Li, 2024). Berikut perhitungan matematika dari Adam:

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t \quad (2.2)$$

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2 \quad (2.3)$$

#### Keterangan:

$m_t$  = rata-rata eksponensial dari gradien pada iterasi ke- $t$ .

$v_t$  = rata-rata eksponensial dari kuadrat gradien pada iterasi ke- $t$ .

$g_t$  = nilai gradien pada iterasi ke- $t$ .

$\beta_1$  = parameter peluruhan untuk momen pertama (biasanya mendekati satu, misalnya 0,9).

$\beta_2$  = parameter peluruhan untuk momen kedua (biasanya mendekati satu, misalnya 0,999).

$t$  = indeks iterasi atau langkah pelatihan ke- $t$ .

### 2.8.2 Optimizer RMSprop

RMSProp (Root Mean Square Propagation) adalah algoritma pengoptimalan laju pembelajaran adaptif yang dirancang untuk meningkatkan kinerja dan kecepatan pelatihan model pembelajaran mendalam. Ini adalah varian dari algoritma

penurunan gradien yang menyesuaikan laju pembelajaran untuk setiap parameter secara individual dengan mempertimbangkan besarnya gradien terkini untuk parameter tersebut. Sifat adaptif ini membantu dalam menangani tantangan tujuan yang tidak stasioner dan gradien jarang yang umum ditemui dalam tugas pembelajaran mendalam. RMSProp menyimpan rata-rata bergerak dari gradien kuadrat untuk menormalkan pembaruan gradien. Dengan demikian, RMSProp mencegah laju pembelajaran menjadi terlalu kecil, yang merupakan kekurangan dalam AdaGrad, dan memastikan bahwa pembaruan diskalakan dengan tepat untuk setiap parameter. Mekanisme ini memungkinkan RMSProp untuk bekerja dengan baik bahkan saat ada tujuan yang tidak stasioner, sehingga cocok untuk melatih model pembelajaran mendalam (Elshamy, Abu-Elnasr, Elhoseny, dan Elmougy, 2023).

$$v_t = \rho v_{t-1} + (1 - \rho) g_t^2 \quad (2.4)$$

$$\Delta w_t = -\frac{\eta}{\sqrt{v_t + \epsilon}} g_t \quad (2.5)$$

### Keterangan:

$v_t$  = rata-rata eksponensial dari kuadrat gradien pada iterasi ke- $t$ .

$\rho$  = faktor peluruhan (*decay rate*) untuk rata-rata kuadrat gradien.

$g_t$  = nilai gradien pada iterasi ke- $t$ .

$\Delta w_t$  = perubahan bobot (parameter) pada iterasi ke- $t$ .

$\eta$  = laju pembelajaran (*learning rate*).

$\epsilon$  = konstanta kecil untuk mencegah pembagian dengan nol.

$t$  = indeks iterasi pelatihan ke- $t$ .

## 29 Penyetelan Hyperparameter

Selain memilih algoritma pelatihan yang tepat, penyetelan hyperparameter juga penting untuk mendapatkan hasil yang optimal dalam deep learning. Hyperparameter adalah parameter yang tidak dapat dipelajari oleh jaringan dan harus ditentukan oleh pengguna sebelum pelatihan (Mada Sanjaya, 2023). Beberapa hyperparameter yang penting dalam algoritma pelatihan deep learning adalah:

**Learning Rate:** Laju pembelajaran adalah hyperparameter yang menentukan seberapa besar perubahan bobot dan bias pada setiap iterasi. Learning rate yang ter-

lalu besar dapat mengakibatkan konvergensi yang tidak stabil, sedangkan learning rate yang terlalu kecil dapat menghambat konvergensi dan memperlambat pelatihan.

Jumlah Epochs: Epoch adalah satu kali penyelesaian melalui seluruh dataset pelatihan. Jumlah epochs adalah hyperparameter yang menentukan berapa kali jaringan akan melalui dataset pelatihan. Jumlah epochs yang terlalu kecil dapat menyebabkan jaringan belum benar-benar belajar, sementara jumlah epochs yang terlalu besar dapat mengakibatkan overfitting pada data pelatihan.

Batch Size: Batch size adalah jumlah sampel yang digunakan untuk mengestimasi gradien pada setiap iterasi. Batch size yang terlalu kecil dapat menghasilkan perkiraan gradien yang tidak stabil, sedangkan batch size yang terlalu besar dapat memakan banyak memori dan menyebabkan konvergensi yang lebih lambat.

Regularization: Regularization adalah teknik untuk mencegah overfitting dengan menambahkan komponen tambahan ke dalam fungsi objektif yang digunakan untuk melatih jaringan. L1 dan L2 regularization adalah dua teknik regularisasi yang umum digunakan dalam deep learning.

Dalam memilih algoritma pelatihan dan menyetel hyperparameter, eksperimen dan evaluasi yang cermat pada dataset yang relevan sangat penting. Pemilihan yang tepat dan penyetelan yang hati-hati dapat membantu meningkatkan kecepatan dan kualitas pelatihan jaringan dalam analisis citra medis.

## 2.10 Confusion Matrix

Confusion matrix adalah alat evaluasi yang umum digunakan dalam machine learning untuk mengukur kinerja model klasifikasi dengan membandingkan hasil prediksi model dengan data aktual. Confusion matrix berbentuk tabel 2x2 untuk klasifikasi biner yang terdiri dari empat komponen utama, yaitu True Positive (TP) yaitu prediksi positif yang benar, True Negative (TN) yaitu prediksi negatif yang benar, False Positive (FP) yaitu prediksi positif yang salah, dan False Negative (FN) yaitu prediksi negatif yang salah (Pinem dan Putra, 2025). Confusion matrix memberikan gambaran mendalam tentang kesalahan yang dilakukan model dan membantu dalam peningkatan model melalui pemahaman kesalahan klasifikasi. Ilustrasi confusion matrix dapat dilihat pada Gambar 2.15.

- Hak Cipta Dilindungi Undang-Undang**
1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
    - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
    - b. Pengutipan tidak menghargai kepentingan yang wajar UIN Suska Riau.
  2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

		1 (Positive)	0 (Negative)
Predicated Value	1 (Positive)	<b>TP</b> (True Positive)	<b>FP</b> (False Positive)
	0 (Negative)	<b>FN</b> (False Negative)	<b>TN</b> (True Negative)

**Gambar 2.15.** Confusion Matrix

Struktur Confusion matrix terdiri dari empat elemen utama yang masing-masing mewakili jenis hasil yang bisa terjadi dalam proses klasifikasi. Elemen-elemen tersebut adalah:

1. True Positive (TP): Ini adalah jumlah kasus yang benar-benar positif dan diprediksi sebagai positif oleh model. Misalnya, dalam deteksi penyakit, ini berarti pasien yang benar-benar sakit dan terdeteksi oleh model sebagai sakit.
2. False Positive (FP): Ini adalah jumlah kasus yang sebenarnya negatif (tidak sakit) tetapi diprediksi positif (terdeteksi sakit) oleh model. Kesalahan ini sering disebut sebagai Type I Error
3. False Negative (FN): Ini adalah jumlah kasus yang sebenarnya positif (sakit) tetapi diprediksi negatif (tidak sakit) oleh model. Kesalahan ini disebut sebagai Type II Error.
4. True Negative (TN): Ini adalah jumlah kasus yang benar-benar negatif dan diprediksi sebagai negatif oleh model. Misalnya, pasien yang sehat dan terdeteksi oleh model sebagai sehat.

Visualisasi ini memudahkan analisis jenis kesalahan yang terjadi, serta optimisasi model berdasarkan tujuan aplikasi. Misalnya, dalam deteksi penyakit, recall yang tinggi sangat penting agar kasus positif tidak terlewatkan. Oleh karena itu, confusion matrix menjadi alat evaluasi yang sangat penting dan sering digunakan dalam penelitian dan aplikasi machine learning maupun deep learning (Hakim, Sobri, Sunardi, dan Nurdiansyah, 2024).

## 2.11 Penelitian Terdahulu

Penelitian terdahulu yang relevan dengan klasifikasi penyakit daun tomat menggunakan metode deep learning, khususnya Convolutional Neural Networks (CNN), telah menunjukkan berbagai pendekatan dan hasil yang signifikan.

Tabel 2.1 merangkum beberapa penelitian penting dalam bidang ini, mencakup peneliti, judul penelitian, metode atau arsitektur yang digunakan, dataset yang dipakai, serta hasil utama yang diperoleh.

**Tabel 2.1.** Penelitian Terdahulu

No	Peneliti & Tahun	Judul	Metode / Arsitektur	Dataset	Hasil Utama
1	Andi Nurdin, Dhian Satria, Yudha Kartika, Abdul Rezha Efrat Najaf (2024)	Klasifikasi Penyakit Daun Tomat Dengan Metode Convolutional Neural Network Menggunakan Arsitektur Inception-V3	CNN (Transfer Learning), Inception-V3, optimizer Adam, SGD, RMSProp	Dataset citra daun tomat Kaggle (Kaustubh), 10 kelas, 11.000 train, 1.000 test	Akurasi 93,8%, precision 93,9%, recall 93,8%, F1-score 93,7% (Adam terbaik)
2	Suryatna Sacadibrata, Taufiqur Rahman, Sa-jarwo Anggai (2025)	Perbandingan CNN dan Vision Transformer (ViT) untuk Klasifikasi Penyakit Daun Tomat	ResNet-152 vs Vision Transformer (ViT)	10.000 citra daun tomat, 10 kelas	ViT akurasi 98,60%, loss 0,0568; ResNet-152 akurasi 96,09%, loss 0,1683
3	Wakhyu Dwiono, Muhammad Iqbal Fathur Rozi, dkk. (2023)	Identifikasi Kinerja Arsitektur Transfer Learning VGG16, ResNet-50, dan Inception-V3	CNN VGG16, ResNet-50, Inception-V3	TL: Kaggle “Tomato Leaf Disease Detection”, 9 kelas	VGG16 97,54% (val 97,78%); ResNet-50 95,78%; Inception-V3 95,51%
	Wahyuni Fithratul Zalmi, Pujo Hari Saputro, Jonathan Sitang-gang, Kevin Leatemia (2025)	Penerapan CNN untuk Klasifikasi Penyakit Daun Tomat	CNN tom (conv, pooling, dense)	Dataset citra daun tomat augmented, 10 kelas	Akurasi 95,84%, performa stabil, salah klasifikasi pada kelas mirip

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
  - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
  - b. Pengutipan tidak menghargai kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

Tabel 2.1 Penelitian Terdahulu (Lanjutan)						
No	Peneliti & Tahun	Judul	Metode / Arsitektur	Dataset	Hasil Utama	
1	Masri Wahyuni (2024)	Klasifikasi Penyakit Daun Tomat dengan Perbandingan Fungsi Aktivasi MLP	VGG16 + (Sigmoid, Tanh, ReLU)	1.000 citra daun tomat, 10 kelas	Tahs terbaik (akurasi 79,7%); ReLU 78%; Sigmoid 72,1%	
2	Rendra Soekarta dkk. (2023)	Klasifikasi Penyakit Tanaman Tomat Menggunakan CNN	CNN (VGG16)	10.519 train + 1.100 validasi, 10 kelas	Train acc 98%, validasi 82% → indikasi overfitting	
3	Preeti Basera dkk. (2023)	TomConv: An Improved CNN Model for Diagnosis of Diseases in Tomato Plant Leaves	TomConv (CNN layer)	PlantVillage (16.000 citra, 10 kelas)	Akurasi 98,19% (input 150×150), unggul dari model lain	
4	Kuwat Setiyanto & Michael Bolang (2023)	Klasifikasi Penyakit Daun Tomat Menggunakan CNN dengan Optimasi Augmentasi Data	CNN custom + data augmentation	PlantVillage, 10 kelas	Akurasi 95,8% (augmentasi), tanpa augmentasi 86%	
5	Showmick Guha Paul dkk. (2023)	A Real-time CNN Approach for Tomato Leaf Disease Classification	Custom CNN + TL (VGG16, VGG19)	11 kelas (termasuk healthy)	Akurasi 95%, dibuat aplikasi Web & Android	
6	Roni Halim Saputra, Rito Cipta Sigitta Hariyono, Fathulloh (2023)	Deteksi Penyakit Tomat Melalui Citra Daun Menggunakan CNN	CNN LeNet-5 (standar & custom)	Dataset citra daun tomat	LeNet-5 standar 90%, custom 95%	

**Hak Cipta Dilindungi Undang-Undang**

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:

a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.

b. Pengutipan tidak meugikan kepentingan yang wajar UIN Suska Riau.

2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

**Tabel 2.1** Penelitian Terdahulu (Lanjutan)

Tabel 2.1 Penelitian Terdahulu (Lanjutkan)						
No	Peneliti & Tahun	Judul	Metode / Arsitektur	Dataset	Hasil Utama	
11	Armin Lawi, Naili Suri Intizhami, Rio Mukhtarom, Supri Amir (2022)	Klasifikasi Penyakit Citra Daun Tanaman Tomat dengan Ensemble CNN	Ensemble CNN (6 model)	Citra tomat	daun	Akurasi 90,83%, precision & recall $\geq 0,8$
12	Muhammad Islahfari Wahid, Armin Lawi, A. Muhammed Amil Siddik (2022)	Perbandingan Kinerja Model Ensemble Transfer Learning pada Klasifikasi Penyakit Daun Tomat	TL (InceptionV3, Xception, VGG16) + Stacking	700 citra daun tomat, 7 kelas	Akurasi train 99%, validasi 99%, unggul dari model tunggal	
13	Okamisar, Regiolina Hayami, Evans Fuad (2025)	Identifikasi Penyakit Tanaman Tomat Menggunakan DenseNet201	DenseNet201 (CNN TL)	PlantVillage (18.835 citra)	Akurasi 95,20%, F1-score 0,95; lebih baik dari VGG16 dkk	
14	Nani Awalia & Aji Prima-jaya (2022)	Identifikasi Penyakit Leaf Mold Daun Tomat Menggunakan DenseNet201	DenseNet121 (TL CNN)	2.283 citra (3 kelas)	Akurasi 92,6%, precision 93,3%, recall 93%	
15	Atam Rifa'i Sujiwanto dkk. (2023)	Analisis Perbandingan Performa Model Klasifikasi Kesehatan Daun Tomat	CNN (VGG, MobileNet, InceptionV3)	Plant Disease Classification Merged Dataset	InceptionV3 98%, VGG 93%, MobileNet 88%	
16	Aritra Das dkk. (2025)	Deep learning-based classification, detection, and segmentation of tomato leaf diseases: A review	Review (CNN, DL, Segmentation)	38 penelitian	DL unggul dibanding ML klasik (SVM, RF, NB)	

Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
    - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
    - b. Pengutipan tidak mengikuti kepentingan yang wajar UIN Suska Riau.
  2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

Tabel 2.1 Penelitian Terdahulu (Lanjutan)						
No	Peneliti & Tahun	Judul	Metode / Arsitektur	Dataset	Hasil Utama	
7	Sajeeb Kumar Ray dkk. (2025)	Enhanced Plant Health Monitoring with Dual-Head CNN	Dual-Head CNN	PlantVillage (13.576 citra)	Akurasi identifikasi penyakit 99,71%, 99,26%	
8	Harisu Abdullahi Shehu dkk. (2025)	Early Detection of Tomato Leaf Diseases using Transformers and Transfer Learning	ViT + TL	PlantVillage + TomatoEbola	ViT-Base (PV), 77,27% (farm)	
9	Mary Magala Mashamba dkk. (2024)	Detection of Bacterial Spot Disease on Tomato Leaves using CNN	CNN (VGG16)	5 kelas penyakit	Train acc 93,28%	
20	Felix dkk. (2019)	Implementasi CNN dan SVM untuk Identifikasi Penyakit Tomat via Daun	CNN + GLCM vs SVM	200 citra	CNN acc 97,5%; SVM acc 95%	
21	Adis Prima Aryaputra, Danang Wahyu Widodo, Ardi Sanjaya (2025)	Klasifikasi Penyakit Daun Tomat Menggunakan CNN MobileNetV2	CNN MobileNetV2	Kaggle, 6 kelas	Akurasi baik, evaluasi accuracy, precision, recall, F1-score	
22	Arif Rahman, Sri Wulandari, dkk. (2024)	Deteksi Penyakit Daun Tomat Menggunakan CNN InceptionResNetV2	CNN TL InceptionResNetV2	PlantVillage (Kaggle)	Akurasi 98,3%, precision 98,1%, recall 97,8%, F1-score 98,0%	

### 2.11.1 Sintesis Penelitian Terdahulu

Berdasarkan tinjauan dari berbagai penelitian sebelumnya, dapat disimpulkan bahwa Convolutional Neural Network (CNN) menjadi pendekatan utama

**Hak Cipta Dilindungi Undang-Undang**

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:

a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.

b. Pengutipan tidak meugikan kepentingan yang wajar UIN Suska Riau.

2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

dalam klasifikasi penyakit daun tomat. CNN dinilai unggul karena kemampuannya mengekstraksi fitur kompleks seperti tekstur, warna, dan pola dari citra daun tomat. Namun, performa CNN sangat dipengaruhi oleh arsitektur yang digunakan dan metode optimasi yang diterapkan selama pelatihan. Beberapa arsitektur populer yang sering dibandingkan antara lain DenseNet201, MobileNetV2, dan InceptionV3.

DenseNet201 memiliki keunggulan dalam efisiensi parameter dan koneksi antar layer yang padat (dense connection), sehingga mampu mempertahankan aliran gradien dan menghindari vanishing gradient problem. Penelitian oleh (Okamisar dkk., 2025) dan (Awalia, 2022a) menunjukkan bahwa DenseNet mampu memberikan akurasi tinggi (95–92%) dengan stabilitas baik dalam dataset besar seperti PlantVillage.

MobileNetV2, di sisi lain, dirancang lebih ringan dan efisien secara komputasi. Penelitian oleh (Aryaputra dkk., 2025) dan (Aryaputra dkk., 2025) membuktikan bahwa model ini tetap dapat mencapai akurasi tinggi (>90%) meskipun kompleksitas modelnya rendah, sehingga cocok untuk implementasi pada perangkat dengan sumber daya terbatas (mobile/edge device).

InceptionV3 dikenal karena penggunaan factorized convolutions dan auxiliary classifier, yang membuatnya unggul dalam mengatasi overfitting dan mendeteksi pola visual kompleks. Penelitian Wakhyu Dwiono dkk. (2023) serta Muhammad Islahfari Wahid dkk. (2022) menunjukkan bahwa InceptionV3 dapat mencapai akurasi hingga 95%, meskipun performanya sedikit lebih rendah dibandingkan VGG16 atau model ensemble.

Selain arsitektur, pemilihan optimizer juga berpengaruh signifikan terhadap kinerja model. Adam optimizer banyak digunakan karena mampu menyesuaikan learning rate secara adaptif dan mempercepat konvergensi. Sebagian besar penelitian yang menggunakan Adam misalnya (Wahyuni, 2024) dan (Okamisar dkk., 2025) memperoleh hasil akurasi yang stabil dan proses pelatihan yang cepat.

RMSProp optimizer juga sering dipilih pada model dengan dataset besar atau transfer learning, karena kemampuannya mempertahankan keseimbangan gradien dalam pembaruan bobot. Beberapa penelitian seperti (Soekarta, Nurdjan, dan Syah, 2023) Arif Rahman dkk. (2024) menunjukkan bahwa RMSProp membantu meningkatkan akurasi validasi dengan stabilitas loss yang lebih baik.

Secara umum, penelitian-penelitian terdahulu menunjukkan bahwa kombinasi arsitektur CNN modern (DenseNet201, MobileNetV2, InceptionV3) dengan optimizer adaptif (Adam dan RMSProp) memberikan hasil yang optimal untuk klasifikasi penyakit daun tomat. Namun, masih terdapat perbedaan performa ter-

gantung pada kompleksitas model, teknik augmentasi, dan jumlah data yang digunakan.

### 2.11.1.1 Gap Penelitian

Berdasarkan hasil sintesis di atas, dapat diidentifikasi beberapa research gap yang menjadi landasan penelitian ini:

1. Belum banyak penelitian yang membandingkan performa DenseNet201, MobileNetV2, dan InceptionV3 secara langsung dalam satu eksperimen. Mayoritas studi hanya berfokus pada satu arsitektur, sehingga belum diketahui model mana yang paling optimal untuk klasifikasi penyakit daun tomat dalam konteks dataset yang sama.
2. Optimalisasi model menggunakan Adam dan RMSprop belum dikaji secara mendalam pada ketiga arsitektur tersebut. Padahal kedua optimizer ini memiliki karakteristik konvergensi yang berbeda, sehingga hasil akhirnya bisa bervariasi tergantung arsitektur yang digunakan.
3. Sebagian penelitian masih berfokus pada akurasi tanpa mempertimbangkan efisiensi komputasi. Misalnya, DenseNet201 cenderung lebih berat dibanding MobileNetV2, namun belum banyak studi yang membandingkan trade-off antara akurasi dan kecepatan inferensi.
4. Belum ada penelitian yang menggabungkan analisis kinerja arsitektur CNN dan peran optimizer secara bersamaan. Kebanyakan penelitian hanya membahas satu faktor (model atau optimizer), bukan kombinasi keduanya secara sistematis.
5. Sebagian besar penelitian masih menggunakan dataset terstruktur seperti Tomato Leaf Disease, bukan data lapangan. Hal ini menyebabkan model belum teruji terhadap kondisi sebenarnya (cahaya tidak merata, latar belakang alami, atau daun rusak sebagian).

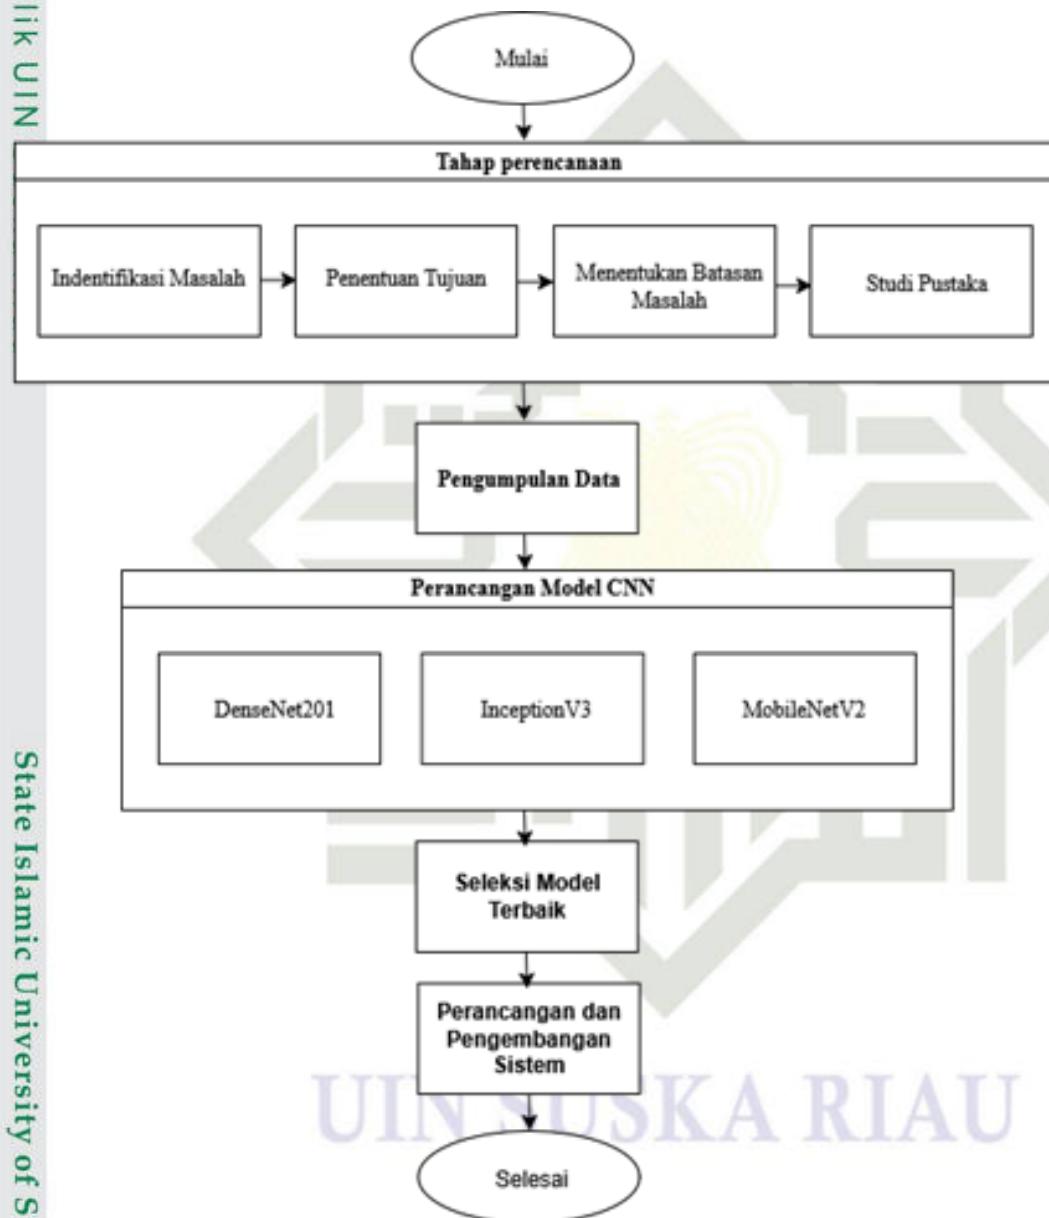
**Hak Cipta Dilindungi Undang-Undang**

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
  - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
  - b. Pengutipan tidak merugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

## BAB 3

### METODOLOGI PENELITIAN

Adapun proses penelitian adalah Tahap Perencanaan, Pengumpulan Data, Perancangan Model CNN, dan Evaluasi model terbaik. Alur metodologi untuk penelitian kali ini dapat dilihat pada Gambar 3.1.



**Gambar 3.1. Metodologi**

#### 3.1 Tahap Perencanaan

Tahap perencanaan merupakan langkah awal yang perlu dilakukan agar tujuan penelitian lebih jelas dan teratur.

**Hak Cipta Dilindungi Undang-Undang**

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
  - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
  - b. Pengutipan tidak mengurangi kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

**1. Identifikasi Masalah**

Pada tahap ini, peneliti mengidentifikasi permasalahan utama yang menjadi dasar penelitian. Permasalahan yang diangkat adalah kesulitan dalam mendeteksi penyakit pada daun tomat secara cepat dan akurat. Selama ini, identifikasi penyakit masih banyak dilakukan secara manual oleh petani atau tenaga ahli, yang memerlukan waktu, biaya, dan tenaga cukup besar serta berpotensi menimbulkan kesalahan diagnosis. Hal ini menjadi isu penting karena kesalahan dalam mengenali penyakit dapat berdampak pada menuurnya produktivitas tanaman tomat. Oleh karena itu, diperlukan sistem berbasis teknologi yang mampu membantu proses diagnosis secara lebih efisien.

**2. Penentuan Tujuan**

Berdasarkan masalah yang diidentifikasi, tujuan penelitian ditetapkan untuk membangun dan menguji model klasifikasi penyakit daun tomat menggunakan arsitektur *Convolutional Neural Network* (CNN). Model ini diharapkan mampu mengenali berbagai jenis penyakit daun tomat dengan akurasi tinggi. Selain itu, penelitian ini juga bertujuan untuk membandingkan performa beberapa arsitektur CNN populer (DenseNet201, InceptionV3, dan MobileNetV2) dengan penerapan optimizer berbeda, sehingga dapat diperoleh kombinasi model yang paling optimal. Dengan adanya tujuan yang jelas, penelitian dapat lebih terarah dan hasil yang dicapai dapat bermanfaat baik secara teoritis maupun praktis.

**3. Menentukan Batasan Masalah**

Agar penelitian tetap fokus, diperlukan adanya batasan masalah. Pada penelitian ini, batasan yang ditetapkan antara lain: (1) objek penelitian terbatas pada citra daun tomat, baik sehat maupun yang terinfeksi penyakit tertentu; (2) dataset yang digunakan berasal dari sumber terbuka (Kaggle); (3) arsitektur yang digunakan hanya terbatas pada DenseNet201, InceptionV3, dan MobileNetV2; (4) metode klasifikasi yang digunakan berbasis CNN dengan optimizer Adam dan RMSprop; serta (5) penelitian hanya berfokus pada tahap klasifikasi citra, tanpa membahas implementasi lebih lanjut ke aplikasi lapangan. Batasan ini ditetapkan agar penelitian lebih terarah dan sesuai dengan waktu serta sumber daya yang tersedia.

**4. Studi Pustaka**

Studi pustaka dilakukan untuk memperoleh landasan teori dan referensi yang mendukung penelitian. Peneliti mengkaji berbagai literatur yang berkaitan dengan CNN, pengolahan citra, klasifikasi penyakit tanaman,

**Hak Cipta Dilindungi Undang-Undang**

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
  - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
  - b. Pengutipan tidak mengikuti kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

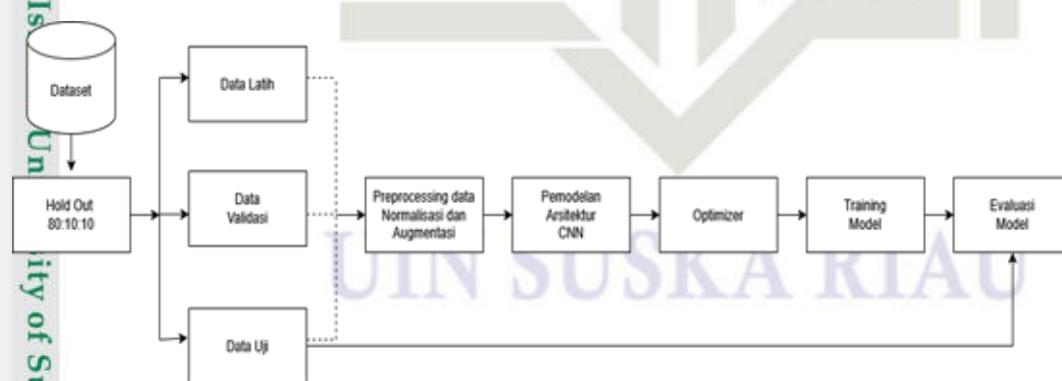
serta penelitian terdahulu yang membahas deteksi penyakit daun tomat atau tanaman lain menggunakan *deep learning*. Studi pustaka ini diperoleh dari buku, jurnal internasional, prosiding, serta artikel ilmiah terbaru. Dengan adanya studi pustaka, peneliti dapat memahami perkembangan penelitian sebelumnya, menemukan celah penelitian (*research gap*), serta memastikan bahwa penelitian yang dilakukan relevan dan memiliki kontribusi terhadap pengembangan ilmu pengetahuan.

### 3.2 Pengumpulan Data

Setelah studi literatur selesai dilaksanakan, penelitian berlanjut ke tahap akuisisi dataset. Pada fase ini, koleksi data yang diperlukan dihimpun dari sumber-sumber relevan, terutama dari platform repository data Kaggle. Dataset yang dikumpulkan diverifikasi untuk memastikan kesesuaiannya dengan kriteria yang telah ditetapkan berdasarkan hasil studi literatur, seperti variasi klasifikasi penyakit yang memadai dan kualitas citra yang optimal. Data citra penyakit daun tomat yang akan digunakan merupakan gambar daun. Dataset yang didapat dari Kaggle sebagai data training dan data validasi dan data testing. Dataset mencakup 10 kelas penyakit daun tomat, termasuk Tomato Mosaic Virus, Target Spot, Bacterial Spot, Tomato Yellow Leaf Curl Virus, Late Blight, Leaf Mold, Early Blight, Spider Mites, Tomato Healthy, dan Septoria Leaf Spot.

### 3.3 Perancangan Model CNN

Pada tahap ini dilakukan perancangan arsitektur CNN untuk klasifikasi citra penyakit daun tomat. Struktur umum CNN yang digunakan terdiri dari beberapa lapisan sebagai pada Gambar 3.2.



**Gambar 3.2.** Perancangan Model CNN

#### 3.3.1 Hold Out Data

Tahap selanjutnya adalah pembagian dataset ke dalam tiga bagian utama, yaitu data latih, data validasi, dan data uji. Proses ini merupakan langkah krusial

sebelum model diuji, karena memastikan bahwa setiap tahap pembelajaran memiliki peran yang jelas. Pembagian dilakukan menggunakan teknik Hold-Out dengan rasio 80:10:10, di mana 80% data digunakan untuk pelatihan, 10% untuk validasi, dan 10% sebagai data pengujian. Pembagian ini memastikan bahwa sebagian besar data digunakan untuk melatih model, sementara sebagian lainnya digunakan untuk mengevaluasi dan menguji performanya secara objektif. Setelah dibagi, dataset ditempatkan pada path yang berbeda untuk memudahkan pengelolaan dan pemrosesan.

Tujuan utama dari pembagian ini adalah agar model dapat dievaluasi secara objektif sekaligus memiliki kemampuan generalisasi yang baik ketika dihadapkan dengan data baru. Dengan demikian, performa model tidak hanya optimal pada data latih, tetapi juga tetap konsisten pada data yang belum pernah ditemui sebelumnya.

### 3.3.2 Data Latih, Validasi, dan Uji

Setelah dataset melalui tahap preprocessing, langkah berikutnya adalah melakukan pembagian data menjadi tiga kelompok utama, yaitu data latih (training set), data validasi (validation set), dan data uji (testing set) dengan rasio 80:10:10.

#### 1. Data Latih (Training Set)

Data latih berfungsi sebagai bahan utama untuk mengajarkan model mengenali berbagai pola pada citra daun tomat. Pada tahap ini, model CNN akan melakukan proses feature extraction terhadap gambar, mulai dari pola sederhana (tepi, tekstur) hingga pola kompleks yang berkaitan dengan gejala penyakit. Dengan porsi 80%, model memperoleh beragam variasi data sehingga semakin kaya pengetahuan yang didapatkan.

#### 2. Data Validasi (Validation Set)

Data validasi digunakan untuk memantau performa model selama proses pelatihan berlangsung. Setiap selesai satu epoch, model akan diuji menggunakan data validasi untuk melihat apakah performanya meningkat atau menurun. Melalui hasil validasi ini, peneliti dapat menyesuaikan parameter seperti learning rate, batch size, atau jumlah epoch. Dengan alokasi 10%, validasi berperan penting untuk mencegah overfitting, yaitu kondisi ketika model terlalu baik pada data latih tetapi buruk pada data baru.

#### 3. Data Uji (Testing Set)

Data uji berperan sebagai “penguji akhir” dari model. Dataset dengan porsi 10% ini tidak dilibatkan dalam proses pelatihan maupun validasi, sehingga benar-benar mewakili data baru yang belum pernah dilihat model. Evaluasi menggunakan data uji memberikan gambaran objektif mengenai kemampuan model dalam mengidentifikasi penyakit pada daun tomat.

**Hak Cipta Dilindungi Undang-Undang**

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
  - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
  - b. Pengutipan tidak mengujikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

puan model dalam melakukan generalisasi. Dengan kata lain, data uji menunjukkan seberapa baik model mampu mengklasifikasikan penyakit daun tomat di luar data pelatihan.

### 3.3.3 Pre-Processing Data

Tahap selanjutnya dalam penelitian ini adalah preprocessing data citra daun tomat, yang dilakukan melalui proses normalisasi dan augmentasi. Normalisasi berfungsi untuk menyamakan skala gambar sehingga seluruh data citra memiliki ukuran dan bentuk yang seragam. Dengan cara ini, model dapat memproses data lebih stabil serta mempercepat proses pelatihan. Hal ini penting mengingat data mungkin biasanya memiliki dimensi yang bervariasi, sehingga konsistensi perlu dijaga agar model dapat belajar dengan optimal.

Sementara itu, augmentasi data diterapkan untuk memperkaya variasi dataset sehingga model dapat mengenali pola dengan lebih baik dan meningkatkan akurasi diagnosis. Pada tahap pelatihan, augmentasi dilakukan menggunakan berbagai teknik. Misalnya, rotasi acak yang memutar citra pada sudut berbeda untuk memberikan variasi orientasi, sehingga model tetap mampu mengenali pola meski gambar terbalik atau miring. Selain itu, dilakukan pula skala ulang nilai piksel dengan membaginya pada angka tertentu agar distribusi nilai menjadi seragam dan mempermudah proses pembelajaran. Teknik flipping, baik secara horizontal maupun vertikal, juga ditambahkan untuk menghasilkan sudut pandang berbeda dari citra yang sama. Tak kalah penting, proses pengisian piksel kosong digunakan untuk menjaga keutuhan citra, di mana area yang hilang akibat pergeseran atau pemotongan digantikan dengan nilai piksel terdekat sehingga citra tetap informatif.

Berbeda dengan data pelatihan, pada data pengujian tidak dilakukan augmentasi. Hanya skala ulang piksel serta pembagian data untuk validasi yang diterapkan agar hasil pengujian tetap obyektif. Tahap akhir preprocessing adalah menentukan ukuran batch, yaitu jumlah citra yang diproses oleh generator setiap kali dijalankan. Pengaturan ini bertujuan untuk menjaga efisiensi sekaligus kestabilan pelatihan model. Melalui kombinasi teknik normalisasi dan augmentasi ini, model menjadi lebih adaptif dalam mengenali berbagai variasi citra daun tomat, yang pada akhirnya mampu meningkatkan akurasi dalam proses diagnosis.

### 3.3.4 Pemodelan Arsitektur CNN

Pada tahap ini dilakukan proses pengujian model dengan menerapkan arsitektur CNN untuk klasifikasi citra Daun Tomat. CNN bekerja melalui beberapa lapisan utama yang berfungsi secara bertahap dalam mengekstraksi hingga mengabstraksi fitur-fitur penting dari citra. Dalam penelitian ini digunakan beberapa ar-

sitektur populer, yaitu DenseNet201, Xception, dan MobileNetV2, sehingga dapat dilakukan perbandingan performa dari masing-masing model. Secara keseluruhan, CNN dirancang untuk secara efisien dan efektif mempelajari pola visual dari citra, kemudian mengklasifikasikannya dengan tingkat akurasi yang tinggi. Oleh karena itu, pendekatan ini menjadi salah satu metode yang paling andal dan banyak digunakan dalam penelitian klasifikasi citra medis.

### 1. **DenseNet201**

Memiliki 201 lapisan dengan koneksi padat antar layer. Setiap lapisan menerima input dari semua lapisan sebelumnya, sehingga informasi dapat mengalir dengan lebih baik. Keunggulan DenseNet201 adalah efisiensi parameter dan kemampuan mengatasi overfitting. Arsitektur ini cocok untuk dataset dengan jumlah terbatas seperti citra daun tomat.

### 2. **InceptionV3**

Dirancang untuk efisiensi komputasi, dengan teknik factorization yang memecah konvolusi besar (misalnya  $5 \times 5$ ) menjadi kombinasi konvolusi kecil ( $1 \times 3$  dan  $3 \times 1$ ). Arsitektur ini mampu mengekstraksi fitur pada berbagai skala secara paralel, sehingga efektif untuk mendeteksi variasi ukuran bercak atau kerusakan pada daun.

### 3. **MobileNetV2**

Merupakan arsitektur ringan yang sangat efisien, dirancang untuk perangkat dengan keterbatasan sumber daya. MobileNetV2 menggunakan inverted residual dan depthwise separable convolution untuk mengurangi jumlah parameter tanpa mengurangi akurasi secara signifikan. Arsitektur ini cocok untuk pengembangan aplikasi berbasis mobile dalam pertanian digital.

## 3.3.5 Optimizer

Optimizer merupakan komponen penting dalam proses pembelajaran mesin karena berfungsi mengarahkan model untuk belajar dari kesalahan yang terjadi selama pelatihan. Salah satu hyperparameter utama yang sangat berpengaruh terhadap akurasi model adalah learning rate, yaitu seberapa besar langkah yang diam-bil optimizer dalam memperbarui bobot jaringan. Setelah arsitektur CNN seperti DenseNet201, InceptionV3, dan MobileNetV2 dipilih untuk penelitian ini, penggunaan optimizer menjadi bagian yang tidak terpisahkan dalam proses pengujian.

Dalam penelitian ini digunakan dua jenis optimizer, yaitu Adam dan RMS prop, yang masing-masing memiliki karakteristik serta keunggulan tersendiri. Adam dikenal mampu mempercepat proses konvergensi dengan kestabilan tinggi, sedangkan Nadam mengombinasikan pendekatan Adam dengan Nesterov momen-

tum sehingga lebih adaptif terhadap perubahan gradien. Pemilihan optimizer yang tepat sangat krusial karena dapat meningkatkan performa model secara signifikan, baik dari segi kecepatan pelatihan maupun akurasi prediksi.

Dengan mengombinasikan keunggulan kedua optimizer tersebut, penelitian ini bertujuan menghasilkan model klasifikasi citra yang tidak hanya akurat, tetapi juga efisien dalam waktu komputasi. Hal ini menjadikan pengaturan optimizer sebagai salah satu aspek kunci dalam perancangan dan implementasi model deep learning untuk klasifikasi citra Daun.

### 3.3.6 Training Model

Pada penelitian ini, proses pelatihan dilakukan menggunakan data latih sebesar 80% dari keseluruhan dataset, sesuai dengan metode hold-out 80:10:10, di mana 10% data digunakan sebagai data validasi dan 10% lainnya sebagai data uji. Data latih digunakan untuk memperbarui bobot (weights) dan bias pada setiap lapisan CNN melalui proses forward propagation dan backpropagation.

Proses training dilakukan dengan memanfaatkan optimizer yang telah ditentukan sebelumnya untuk meminimalkan nilai loss function. Optimizer berperan dalam mempercepat konvergensi model menuju solusi optimal dengan menyesuaikan nilai bobot berdasarkan gradien kesalahan yang dihasilkan. Selama proses training, model akan melakukan iterasi berulang (epoch) terhadap data latih hingga mencapai jumlah epoch yang telah ditentukan atau hingga performa model menunjukkan hasil yang stabil.

Selain itu, data validasi digunakan pada setiap epoch untuk memantau kinerja model selama proses training. Hal ini bertujuan untuk mengidentifikasi potensi overfitting, yaitu kondisi ketika model terlalu menyesuaikan diri dengan data latih namun kurang mampu melakukan generalisasi terhadap data baru. Parameter kinerja yang diamati pada tahap ini meliputi nilai training accuracy, validation accuracy, serta nilai loss.

Hasil dari tahap training model berupa model CNN terlatih yang selanjutnya akan digunakan pada tahap evaluasi menggunakan data uji untuk mengukur performa akhir model secara objektif.

### 3.3.7 Evaluasi Model

Tahap evaluasi merupakan bagian penting dalam penelitian ini karena menentukan seberapa baik model CNN yang dibangun mampu mengenali dan mengklasifikasikan penyakit daun tomat. Evaluasi dilakukan menggunakan confusion matrix yang memperlihatkan perbandingan antara hasil prediksi model dengan label aktual pada data uji. Dari confusion matrix ini kemudian dihitung beberapa

metrik kinerja, yaitu akurasi, presisi, recall, dan F1-score.

1. Akurasi (Accuracy)

Mengukur proporsi prediksi yang benar dari keseluruhan data uji. Semakin tinggi akurasi, semakin baik model dalam mengklasifikasikan semua kelas penyakit.

$$\text{accuracy} = \left( \frac{TP + TN}{TP + FP + TN + FN} \right) \times 100\% \quad (3.1)$$

2. Presisi (Precision)

Menunjukkan seberapa tepat model dalam memprediksi kelas tertentu. Misalnya, jika model memprediksi daun tomat terkena bacterial spot, presisi akan mengukur seberapa banyak prediksi tersebut benar-benar sesuai dengan label sebenarnya. Presisi tinggi berarti model jarang salah mengklasifikasikan kelas lain sebagai penyakit tertentu.

$$\text{precision} = \left( \frac{TP}{TP + FP} \right) \times 100\% \quad (3.2)$$

3. Recall (Sensitivity)

Menilai kemampuan model dalam menemukan seluruh data yang benar pada suatu kelas. Dalam konteks penelitian ini, recall penting karena menunjukkan apakah model mampu mendeteksi semua citra daun yang benar-benar terkena penyakit tertentu, sehingga tidak ada kasus yang terlewat.

$$\text{recall} = \left( \frac{TP}{TP + FN} \right) \times 100\% \quad (3.3)$$

4. F1-Score

Merupakan kombinasi harmonis antara presisi dan recall. Nilai ini memberikan gambaran yang lebih seimbang mengenai performa model, terutama ketika ada ketidakseimbangan jumlah data antar kelas.

$$\text{f1-score} = \left( \frac{2 \times \text{precision} \times \text{recall}}{\text{precision} + \text{recall}} \right) \times 100\% \quad (3.4)$$

5. Analisis Error (Error Analysis)

Dengan memeriksa confusion matrix, peneliti dapat melihat kelas mana yang sering salah diprediksi. Misalnya, model mungkin sering keliru membedakan antara Early Blight dan Late Blight karena kemiripan gejala visual pada daun. Analisis ini membantu memahami kelemahan model dan menjadi dasar untuk perbaikan, seperti penyesuaian arsitektur, tuning hyperparameter, dan lainnya.

**Hak Cipta Dilindungi Undang-Undang**

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
  - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
  - b. Pengutipan tidak mengujikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

rameter, atau penambahan variasi data melalui augmentasi.

#### 6. Perbandingan Antar Arsitektur dan Optimizer

Evaluasi dilakukan pada tiga arsitektur CNN (DenseNet201, InceptionV3, MobileNetV2) dengan dua optimizer berbeda (Adam dan RMSprop). Hasilnya menunjukkan variasi performa, di mana DenseNet201 + RMSprop cenderung memberikan akurasi lebih tinggi dan prediksi lebih stabil dibanding kombinasi lainnya. Sementara itu, InceptionV3 meski akurasinya lebih rendah, masih menunjukkan kekuatan dalam mengenali kelas tertentu seperti Tomato Healthy dan Tomato Mosaic Virus dengan akurasi sempurna. MobileNetV2 relatif seimbang, namun masih menghadapi tantangan overfitting pada penggunaan optimizer tertentu.

#### 7. Implikasi Hasil Evaluasi

Evaluasi model bukan hanya sebatas angka akurasi, tetapi juga menilai kehandalan model dalam menghadapi data baru. Hasil confusion matrix membuktikan bahwa metode CNN dengan arsitektur tertentu lebih unggul dalam klasifikasi multiklas penyakit daun tomat. Hal ini memberikan dasar ilmiah bahwa pemilihan arsitektur dan optimizer sangat berpengaruh terhadap performa akhir, serta dapat menjadi rekomendasi bagi penelitian lanjutan untuk fokus pada kombinasi model yang paling menjanjikan.

### 3.4 Seleksi Model Terbaik

Hasil dari beberapa percobaan yang telah dilakukan maka dapat dilakukan evaluasi model yang merupakan tahap kritis dalam penelitian klasifikasi citra, yang bertujuan untuk menilai seberapa baik model yang telah dilatih dalam mengklasifikasikan citra baru. Salah satu alat utama yang digunakan untuk evaluasi ini adalah confusion matrix, yang memberikan detail tentang kinerja model.

Evaluasi model menggunakan confusion matrix juga membantu dalam melakukan analisis error yang mendalam. Dan dapat membantu dalam melihat pola kesalahan tertentu dan mungkin menyesuaikan arsitektur model, hyperparameter, atau strategi augmentasi data untuk meningkatkan kinerja. Hasil dari confusion matrix menampilkan Accuracy, Precision, Recall dan F1-score.

### 3.5 Perancangan dan pengembangan sistem

Bagian ini menjelaskan proses pengembangan sistem aplikasi web untuk prediksi penyakit daun tomat berbasis model Convolutional Neural Network (DenseNet201 + Adam). Sistem dikembangkan dengan arsitektur client-server menggunakan framework Flask (Python) pada sisi server untuk menangani request, memuat model, melakukan preprocessing, menjalankan inferensi, dan mengembangkan

ikan hasil prediksi kepada client (browser). Tujuan pengembangan adalah menyediakan antarmuka sederhana bagi pengguna (petani, peneliti, masyarakat umum) untuk mengunggah gambar daun tomat dan menerima hasil diagnosis otomatis dengan informasi label penyakit dan tingkat keyakinan (confidence).

### 3.5.1 Perencanaan Sistem

Tahap perencanaan dilakukan untuk menentukan kebutuhan dan fungsi yang harus disediakan oleh aplikasi. Sistem dirancang untuk menerima input berupa gambar daun tomat, memprosesnya dengan model CNN terbaik, dan memberikan hasil prediksi secara otomatis. Kebutuhan fungsional meliputi fitur upload gambar, validasi format file, preprocessing gambar, pemanggilan model CNN, dan menampilkan hasil prediksi kepada pengguna. Kebutuhan non-fungsional meliputi kemudahan penggunaan, waktu respons yang cepat, serta kemampuan sistem untuk berjalan pada perangkat lokal tanpa konfigurasi kompleks. Teknologi utama yang digunakan meliputi bahasa pemrograman Python, framework Flask sebagai backend, TensorFlow/Keras sebagai pemroses model, dan HTML/CSS sebagai antarmuka web.

### 3.5.2 Perancangan Sistem

Perancangan sistem mencakup penyusunan alur proses, arsitektur aplikasi, serta tampilan antarmuka pengguna. Alur proses dimulai dari pengguna mengunggah gambar daun, kemudian sistem memvalidasi format file agar hanya menerima JPG atau PNG. Jika valid, gambar diproses melalui tahapan resize dan normalisasi sebelum dikirim ke model CNN. Model menghasilkan probabilitas kelas yang kemudian diterjemahkan menjadi label penyakit. Hasil prediksi ditampilkan kembali pada halaman web. Arsitektur aplikasi menggunakan pendekatan client-server, di mana browser berfungsi sebagai client dan Flask sebagai server yang menangani logika pemrosesan. Antarmuka dibuat sederhana dengan dua halaman utama: halaman upload gambar dan halaman hasil prediksi. Desain ini bertujuan agar pengguna dapat melakukan prediksi dengan langkah yang jelas dan mudah.

### 3.5.3 Implementasi Sistem

Pengembangan sistem dilakukan dengan mengimplementasikan backend menggunakan Flask. File model hasil pelatihan (DenseNet201 + Adam) disimpan dalam format h5 dan dimuat saat server dijalankan sehingga proses prediksi dapat dilakukan secara langsung. Proses backend meliputi penerimaan file upload, validasi ekstensi file, penyimpanan file sementara, preprocessing gambar, pemanggilan model, hingga mengembalikan hasil prediksi dalam bentuk JSON atau di-

tampilkan melalui HTML. Preprocessing dilakukan dengan mengubah gambar ke RGB, mengubah ukuran menjadi  $224 \times 224$  piksel, mengonversinya ke array NumPy, serta melakukan normalisasi nilai piksel. Frontend dikembangkan menggunakan HTML sederhana untuk menampilkan form upload dan hasil prediksi. Struktur proyek menggunakan folder templates untuk halaman web, static untuk file pendukung, uploads untuk file sementara, dan model untuk menyimpan file model. Sistem diuji secara lokal menggunakan lingkungan Python dan dapat dijalankan melalui perintah flask run.

### 3.5.4 Pengujian Sistem

Pengujian sistem dilakukan untuk memastikan bahwa seluruh fungsi berjalan sesuai kebutuhan. Pengujian dilakukan menggunakan metode Blackbox Testing, yaitu dengan menguji sistem berdasarkan fungsi tanpa melihat kode program. Skenario yang diuji meliputi upload file valid, upload file tidak valid, prediksi gambar normal, prediksi gambar dengan kondisi buruk (buram atau gelap), serta respon sistem terhadap file berukuran besar. Selain itu dilakukan pengujian end-to-end dengan membandingkan hasil prediksi website terhadap hasil prediksi model di lingkungan training untuk memastikan konsistensi. Hasil pengujian menunjukkan bahwa sistem mampu memproses gambar, menghasilkan prediksi dengan benar, dan menampilkan hasil tanpa error. Validasi file bekerja sesuai yang diharapkan dan sistem mampu menolak input yang tidak sesuai. Dengan demikian, sistem siap digunakan oleh pengguna untuk melakukan prediksi penyakit daun tomat secara otomatis.

## BAB 5

### PENUTUP

#### 5.1 Kesimpulan

Berdasarkan hasil penelitian yang telah dilakukan mengenai klasifikasi penyakit daun tomat menggunakan metode Convolutional Neural Network (CNN) dengan arsitektur DenseNet201, InceptionV3, dan MobileNetV2 serta penerapan dua jenis optimizer Adam dan RMSProp, maka dapat diperoleh kesimpulan sebagai berikut:

1. Penelitian ini berhasil menerapkan dan mengevaluasi tiga arsitektur CNN, yaitu DenseNet201, MobileNetV2, dan InceptionV3, dalam mengklasifikasi penyakit daun tomat ke dalam 10 kelas. Hasil evaluasi menunjukkan bahwa DenseNet201 dengan optimizer Adam memberikan performa terbaik dibandingkan arsitektur lainnya, dengan akurasi rata-rata sebesar 94%, precision 94%, recall 93%, dan F1-score 94%.
2. Berdasarkan hasil perbandingan seluruh kombinasi arsitektur dan optimizer, DenseNet201 dengan optimizer RMSprop berada pada posisi kedua dengan akurasi 91–92%, sedangkan MobileNetV2 menghasilkan akurasi 88% (Adam) dan 85–87% (RMSprop). Sementara itu, InceptionV3 menunjukkan performa terendah dengan akurasi berkisar 81–82%, yang mengindikasikan bahwa arsitektur ini kurang optimal dalam menangkap pola visual kompleks pada citra penyakit daun tomat.
3. Hasil pengujian sistem menggunakan 10 citra daun tomat sebagai data primer menunjukkan bahwa sistem berhasil mengklasifikasikan 8 dari 10 citra dengan benar, sehingga diperoleh akurasi uji sistem sebesar 94,77%. Kesalahan klasifikasi terjadi pada kelas Tomato Mosaic Virus dan Tomato Yellow Leaf Curl Virus (TYLCV) yang memiliki kemiripan pola visual, sehingga berpotensi menimbulkan kesalahan prediksi.
4. Model CNN terbaik yang diperoleh telah berhasil diimplementasikan ke dalam bentuk prototipe website klasifikasi penyakit daun tomat. Sistem memungkinkan pengguna untuk mengunggah citra daun tomat dan memperoleh hasil prediksi penyakit secara otomatis beserta tingkat kepercayaan prediksi. Hasil pengujian fungsional menunjukkan bahwa seluruh fitur utama sistem berjalan dengan baik sesuai dengan perancangan.
5. Secara keseluruhan, penelitian ini membuktikan bahwa penerapan algoritma CNN dengan pemilihan arsitektur dan optimizer yang tepat mampu memberikan hasil klasifikasi penyakit daun tomat dengan tingkat akurasi yang

**Hak Cipta Dilindungi Undang-Undang**

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
  - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
  - b. Pengutipan tidak meugikan kepentingan yang wajar UIN Suska Riau.
2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

tinggi. Dengan nilai akurasi di atas 94%, sistem yang dikembangkan dapat digunakan sebagai alat bantu identifikasi awal penyakit daun tomat, meskipun masih diperlukan pengujian lanjutan dengan data yang lebih beragam untuk meningkatkan keandalan sistem.

## 5.2 Saran

Penelitian ini masih memiliki ruang pengembangan, terutama dalam peningkatan kualitas data dan kemampuan generalisasi model. Disarankan untuk menambah variasi dataset melalui pengambilan citra langsung dari lapangan serta mengeksplorasi arsitektur deep learning lain seperti EfficientNet, ResNet, atau Vision Transformer, dan menggunakan metode validasi seperti K-fold cross validation agar hasil evaluasi lebih stabil. Pengembangan sistem dapat meliputi penambahan fitur pada website seperti penyimpanan riwayat prediksi, database penyakit, dan rekomendasi penanganan, serta pengembangan versi mobile atau integrasi dengan IoT pertanian untuk deteksi real-time. Selain itu, diperlukan analisis efisiensi model terkait penggunaan memori dan waktu inferensi agar sistem semakin siap diterapkan secara praktis di lapangan.

- Hak Cipta Dilindungi Undang-Undang**
1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
    - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
    - b. Pengutipan tidak meugikan kepentingan yang wajar UIN Suska Riau.
  2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.

## DAFTAR PUSTAKA

- Abdullahi, H., Ackley, A., Marvellous, M., dan Ebriba, O. (2025). Early detection of tomato leaf diseases using transformers and transfer learning. *European Journal of Agronomy*, 168, 127625. doi: 10.1016/j.eja.2025.127625
- Arshwarya, M. P., dan Reddy, P. (2023). Ensemble of cnn models for classification of groundnut plant leaf disease detection. *Smart Agricultural Technology*, 6, 100362. doi: 10.1016/j.atech.2023.100362
- Akmal, A. N., dan Maelasari, N. (2025). Pemahaman deep learning dalam pendidikan: Analisis literatur melalui metode systematic literature review (slr).
- Al-Fahrezi, M. A. (2025). Pengaruh augmentasi data terhadap akurasi pelatihan model cnn untuk klasifikasi jenis ikan. *JITSI: Jurnal Ilmiah Teknologi Sistem Informasi*, 6(2), 177–185. doi: 10.62527/jitsi.6.2.471
- Anam, M. K. (2023). Comparison of convolutional neural network architecture on detection of helmet use by humans. , 8(1), 44–54.
- Anton, A., Nissa, N. F., Janiati, A., Cahya, N., dan Astuti, P. (2021). Application of deep learning using convolutional neural network (cnn) method for womenâ€™s skin classification. *Scientific Journal of Informatics*, 8(1), 144–153.
- Ardiansyah, M. (2025). Optimizing deep learning models for limited data environments: A comparative study. , 11(1), 294–301.
- Ariawan, E. (2025). Perbandingan performa arsitektur convolutional neural network menggunakan transfer learning untuk model deteksi kesehatan daun. *Journal of Business and Audit Information System (JBASE)*, 8(1), 1–12. Retrieved from <http://journal.ubm.ac.id/index.php/jbase>
- Aryaputra, A. P., Widodo, D. W., dan Sanjaya, A. (2025). Klasifikasi penyakit daun tomat menggunakan algoritma cnn mobilenet v2. Dalam *Prosiding semnas inotek (seminar nasional inovasi teknologi)* (Vol. 9, hal. 102–108).
- Aulia, N. R., dan Puspita, F. (2023). Test some concentration of bacillus subtilis to increase the resistance of tomato plants to xanthomonas campestris pv. vesicatoria: Uji beberapa konsentrasi bacillus subtilis untuk meningkatkan ketahanan tanaman tomat terhadap xanthomonas campestris pv. vesicatoria. *Jurnal Online Pertanian Tropik*, 10(1), 54–60.
- Awalia, N. (2022a). Identifikasi penyakit leaf mold pada daun tomat menggunakan model densenet121 berbasis transfer learning. *Jurnal Ilmiah Ilmu Komputer*, 8(1), 49–52. doi: 10.35329/jiik.v8i1.212
- Awalia, N. (2022b). Identifikasi penyakit leaf mold pada daun tomat menggunakan

model densenet121 berbasis transfer learning. *Jurnal Ilmiah Ilmu Komputer*, 8(1), 49–52. doi: 10.35329/jiik.v8i1.212

Ayu Purnamasari, S., dan Alfassabiq Khairi, S. (2024). *Budidaya tanaman tomat dan pengendalian hama dan penyakit*. MEGA PRESS NUSANTARA.

Das, A., Pathan, F., Rahman, J., Kabir, M., dan Mridha, M. F. (2025). Deep learning-based classification, detection, and segmentation of tomato leaf diseases: A state-of-the-art review. *Artificial Intelligence in Agriculture*, 15(2), 192–220. doi: 10.1016/j.aiia.2025.02.006

Elshamy, R., Abu-Elnasr, O., Elhoseny, M., dan Elmougy, S. (2023). Improving the efficiency of rmsprop optimizer by utilizing nesterov in deep learning. *Scientific Reports*, 13(1), 1–16. doi: 10.1038/s41598-023-35663-x

Fitriani, A., dan Santiani. (2025). Analisis literatur: Pendekatan pembelajaran deep learning dalam pendidikan. *Jurnal Ilmiah Nusantara (JINU)*, 2(3), 50–57. doi: 10.61722/jinu.v2i3.4357

Gunaeni, N., dan Purwati, E. (2013). Uji ketahanan terhadap tomato yellow leaf curl virus pada beberapa galur tomat. *Jurnal Hortikultura*, 23(1), 65–71. doi: 10.21082/jhort.v23n1.2013.p65-71

Hakim, L., Sobri, A., Sunardi, L., dan Nurdiansyah, D. (2024). Prediksi penyakit jantung berbasis mesin learning dengan menggunakan metode k-nn. *Jurnal Digital Teknologi Informasi*, 7(2), 14–20.

Hal, V. N., Ulfah, M., Putra, T. A., Irawan, A., dan Rizki, K. N. (2024). Aktivitas Antibakteri Ekstrak Aseton Daun Tomat (Solanum lycopersicum L.) Terhadap Bakteri Staphylococcus aureus Dan Escherichia coli. , 7(1), 1073–1079.

Hossain, I., Jahan, S., Al, R., dan Ahmed, K. (2023). Detecting tomato leaf diseases by image processing through deep convolutional neural networks. *Smart Agricultural Technology*, 5, 100301. doi: 10.1016/j.atech.2023.100301

Humuntal, Silalahi, A. P., Sidauruk, L., dan Sinambela, M. (2022). Identifikasi penyakit tanaman tomat berdasarkan citra penyakit menggunakan metode glcm dan naïve bayes classifier. *METHODIKA: Jurnal Ilmiah Teknik Informatika*, 2(1), 22–28. Retrieved from <https://ejurnal.methodist.ac.id/index.php/methotika/article/view/2266>

Indolia, S., Kumar, A., Mishra, S. P., dan Asopa, P. (2018). Conceptual understanding of convolutional neural network: A deep learning approach. *Procedia Computer Science*, 132, 679–688. doi: 10.1016/j.procs.2018.05.069

Islam, M. P., Hatou, K., Aihara, T., Seno, S., Kirino, S., dan Okamoto, S. (2022). Performance prediction of tomato leaf disease by a series of parallel convo-

- © Hak cipta milik UIN Suska Riau
- Hak Cipta Dilindungi Undang-Undang**
1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:
    - a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.
    - b. Pengutipan tidak meugikan kepentingan yang wajar UIN Suska Riau.
  2. Dilarang mengumumkan dan memperbanyak sebagian atau seluruh karya tulis ini dalam bentuk apapun tanpa izin UIN Suska Riau.
- lutional neural networks. *Smart Agricultural Technology*, 2, 100054. doi: 10.1016/j.atech.2022.100054
- Istifadah, N., Monica, S., Widiantini, F., dan Hartati, S. (2021). Potensi mikrob asal air rendaman limbah jamur tiram untuk menghambat alternaria solani sorr. in vitro dan penyakit bercak cokelat pada tomat. *Agrikultura*, 31(3), 242–248. doi: 10.24198/agrikultura.v31i3.29198
- Jatinderkumar, R., dan Saini, R. (2023). Tomconv: An improved cnn model for diagnosis of diseases in tomato plant leaves. *Procedia Computer Science*, 218, 1825–1833. doi: 10.1016/j.procs.2023.01.160
- Joshi, K., Hooda, S., Sharma, A., Sonah, H., dan Deshmukh, R. (2025). Precision diagnosis of tomato diseases for sustainable agriculture through deep learning approach with hybrid data augmentation. *Current Plant Biology*, 41, 100437. doi: 10.1016/j.cpb.2025.100437
- Kanedi, M. (2020). Efektivitas ekstrak daun tomat (solanum lycopersicum l.) sebagai ovisida nyamuk aedes aegypti. *Jurnal Ilmu Kedokteran Dan Kesehatan*, 7(1), 368–374.
- Kang, J., Zhu, X., Shen, L., dan Li, M. (2024). Fault diagnosis of a wave energy converter gearbox based on an adam optimized cnn-lstm algorithm. *Renewable Energy*, 231, 121022. doi: 10.1016/j.renene.2024.121022
- Khan, I., Saquib, S., Dag, Ø., dan Kumar, B. (2024). Deep transfer learning for fine-grained maize leaf disease classification. *Journal of Agriculture and Food Research*, 16, 101148. doi: 10.1016/j.jafr.2024.101148
- Kobiela, D., Groth, J., Hajdasz, M., dan Erezman, M. (2024). Vehicle type recognition: A case study of mobilenetv2 for an image classification task. *Procedia Computer Science*, 246, 3947–3956. doi: 10.1016/j.procs.2024.09.169
- Kumar, N. S., Sony, J., Premkumar, A., Meenakshi, R., dan Nair, J. J. (2024). Transfer learning-based object detection models for improved diagnosis of tomato leaf disease. *Procedia Computer Science*, 235, 3025–3034. doi: 10.1016/j.procs.2024.04.286
- Kurniadi, D., Shidiq, R. M., dan Mulyani, A. (2025). Perbandingan penggunaan optimizer dalam klasifikasi sel darah putih menggunakan convolutional neural network. *Jurnal Nasional Teknik Elektro dan Teknologi Informasi*, 14(1), 77–86.
- Kurniawati, F., dan Suastika, G. (2015). Identifikasi tomato infectious chlorosis virus penyebab penyakit klorosis pada tanaman tomat di cipanas jawa barat melalui perunutan nukleotida gen protein selubung utama. *Jurnal Hama dan Penyakit Tumbuhan Tropika*, 15(1), 33–43. doi: 10.23960/j.hptt.11533-43

- Liu, J., Chafi, R., Legarrea, S., Alba, J. M., Meijer, T., Menken, S. B. J., dan Kant, M. R. (2020). Spider mites cause more damage to tomato in the dark when induced defenses are lower. *Journal of Chemical Ecology*, 46(7), 631–641. doi: 10.1007/s10886-020-01195-1
- Mada Sanjaya, W. (2023). *Deep learning citra medis berbasis pemrograman python-penerbit bolabot*. Bolabot.
- Mashamba, M. M., Telukdarie, A., Munien, I., Onkonkwo, U., dan Vermeulen, A. (2024). Detection of bacterial spot disease on tomato leaves using a convolutional neural network. *Procedia Computer Science*, 237, 602–609. doi: 10.1016/j.procs.2024.05.145
- Maulana, A. (2018). Konsep dasar data mining. *Konsep Data Mining*, 1, 1–16.
- Mo, H., dan Wei, L. (2025). Tomato yellow leaf curl virus detection based on cross-domain shared attention and enhanced bifpn. *Ecological Informatics*, 85, 102912. doi: 10.1016/j.ecoinf.2024.102912
- Muchtar, K., Nurdin, Y., Afdhal, A., dkk. (2021). Pendekripsi septoria pada tanaman tomat dengan metode deep learning berbasis raspberry pi. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 5(1), 107–113.
- Muhlis, A., dkk. (2025). *Deep learning dalam pendidikan dan artificial intelligence*. Yayasan Putra Adi Dharma.
- Nobel, S. N., Afroz, M., Kabir, M. M., dan Mridha, M. (2024). Development of a cutting-edge ensemble pipeline for rapid and accurate diagnosis of plant leaf diseases. *Artificial Intelligence in Agriculture*, 14, 56–72.
- Niviani, E. P. I., Martosudiro, M., dan Choliq, F. A. (2023, Jun.). Pengaruh beberapa fungisida terhadap alternaria solani penyebab penyakit bercak kering pada tanaman tomat (*lycopersicum esculentum mill.*) di lapangan. *Jurnal HPT (Hama Penyakit Tumbuhan)*, 11(2), 84–92. Retrieved from <https://jurnalhpt.ub.ac.id/index.php/jhpt/article/view/378> doi: 10.21776/ub.jurnalhpt.2023.011.2.4
- Okamisar, O., Hayami, R., dan Fuad, E. (2025). Identifikasi penyakit tanaman tomat melalui citra daun menggunakan densenet201. *Jurnal CoSciTech (Computer Science and Information Technology)*, 6(2), 166–174.
- Palupiningsih, P., Sujiwanto, A. R., dan Prawirodirjo, R. R. B. P. (2023). Analisis perbandingan performa model klasifikasi kesehatan daun tomat menggunakan arsitektur vgg, mobilenet, dan inception v3. *Jurnal Ilmu Komputer dan Agri-Informatika*, 10(1), 98–110.
- Pinem, T. H., dan Putra, Z. P. (2025). Evaluasi kinerja algoritma klasifikasi deep learning dalam prediksi diabetes. *Jurnal Ilmiah FIFO*, 17(1), 17–28.

- Putra, R. H., Ridwan, H. M., Abiansyan, I., dan Agustin, I. (2024). Klasifikasi daun tomat sehat dan terserang penyakit menggunakan metode convolutional neural network (cnn). Dalam *Prosiding seminar nasional amikom surakarta* (Vol. 2, hal. 201–213).

Qiu, J., Lu, X., Wang, X., Chen, C., dan Chen, Y. (2024). Image recognition of tomato leaf diseases based on improved alexnet. *Heliyon*, 10(13), e33555. doi: 10.1016/j.heliyon.2024.e33555

Rahmadhani, N. (2021). *Penyebaran penyakit layu bakteri (ralstonia syzygii subsp. indonesiensis) pada tanaman kentang di tiga desa di kecamatan silimakuta kabupaten simalungun* (Unpublished doctoral dissertation). Universitas Sumatera Utara.

Raksun, A., Merta, I. W., dan Mertha, I. G. (2021). Vegetative growth response of tomato (*solanum lycopersicum* l) due to different doses of horse manure bokashi. *Jurnal Biologi Tropis*, 21(2), 434–440.

Ramadhan, F., dan Hernadi, J. (2025). Evaluasi optimizer adam dan rmsprop pada arsitektur vgg-19 klasifikasi ekspresi wajah manusia. *JIPI (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)*, 10(2), 1414–1426.

Raza, A., Hammed, A., Shaikh, M. K., dan Ahmed, K. (2025a). Optimizing potato leaf disease recognition: Insights from densenet-121 and gaussian elimination filter fusion. *Heliyon*, 11(3), e42318. doi: 10.1016/j.heliyon.2025.e42318

Raza, A., Hammed, A., Shaikh, M. K., dan Ahmed, K. (2025b). Optimizing potato leaf disease recognition using densenet-121 and gaussian elimination filter fusion. *Heliyon*, 11(3), e42318. doi: 10.1016/j.heliyon.2025.e42318

Rozi, M. I. F., Adiwijaya, N. O., dan Swasono, D. I. (2023). Identifikasi kinerja arsitektur transfer learning vgg16, resnet-50, dan inception-v3 dalam pengklasifikasian citra penyakit daun tomat. *Jurnal Riset Rekayasa Elektro*, 5(2), 145–154.

Sastramandala, M. B., Sari, R. N., dan Novrina, N. (2025). Pemanfaatan deep learning menggunakan convolutional neural network terhadap penyakit tuberculosis melalui citra rontgen. *Jurnal Minfo Polgan*, 14(1), 631–642.

Shanthappa, P. M., Bayari, M., Abhilash, G., Gokul, K., dan Ashish, P. (2025). Parkinson’s disease detection using inceptionv3: A deep learning approach. *MethodsX*, 103333.

Shanthy, D., Vinutha, K., Ashwini, N., dkk. (2024). Tomato leaf disease detection using cnn. *Procedia Computer Science*, 235, 2975–2984.

Singh, V., Chug, A., dan Singh, A. P. (2023). Classification of beans leaf diseases

- using fine tuned cnn model. *Procedia Computer Science*, 218, 348–356.
- Soekarta, R., Nurdjan, N., dan Syah, A. (2023). Klasifikasi penyakit tanaman tomat menggunakan metode convolutional neural network (cnn). *Insect (Informatics and Security): Jurnal Teknik Informatika*, 8(2), 143–151.
- Solimani, F., Cardelluccio, A., Dimauro, G., Petrozza, A., Summerer, S., Cellini, F., dan Renò, V. (2024). Optimizing tomato plant phenotyping detection: Boosting yolov8 architecture to tackle data complexity. *Computers and Electronics in Agriculture*, 218, 108728.
- Wahid, M. I., Lawi, A., dan Siddik, A. M. A. (2022). Perbandingan kinerja model ensembled transfer learning pada klasifikasi penyakit daun tomat. Dalam *Seminar nasional teknik elektro dan informatika (sntei)* (Vol. 8, hal. 286–291).
- Wahyuni, M. (2024). Klasifikasi penyakit daun tomat dengan perbandingan fungsi aktivasi multi layer perceptron. *Jurnal Minfo Polgan*, 13(2), 1988–1998.
- Wales, S., Tulung, S. M., dan Mamarimbang, R. (2023). Growth and production of tomato (*solanum lycopersicum l.*) on several types of growing media. *Jurnal Agroekoteknologi Terapan*, 4(1), 84–93.
- Zhou, J., Gu, X., Gong, H., Yang, X., Sun, Q., Guo, L., dan Pan, Y. (2024). Intelligent classification of maize straw types from uav remote sensing images using densenet201 deep transfer learning algorithm. *Ecological Indicators*, 166, 112331.



## DAFTAR RIWAYAT HIDUP

### Hak Cipta Dilindungi Undang-Undang

1. Dilarang mengutip sebagian atau seluruh karya tulis ini tanpa mencantumkan dan menyebutkan sumber:

a. Pengutipan hanya untuk kepentingan pendidikan, penelitian, penulisan karya ilmiah, penyusunan laporan, penulisan kritik atau tinjauan suatu masalah.

b. Pengutipan tidak mengujikan kepentingan yang wajar UIN Suska Riau.

Nayla Husna Ryanda lahir di Medan, Provinsi Sumatera Utara pada 11 Desember 2003. Peneliti merupakan anak dari Bapak Al Harry Harlan (Alm) dan Ibu Emilda Syahyani. Peneliti merupakan anak kedua dari tiga bersaudara, yang terdiri dari abang Hafiz Azri Ryanda dan Adik Sulthan Fathurrahman Ryanda. Pada tahun 2009 Peneliti memulai pendidikan Sekolah Dasar (SD) di SD Kartika 1-9. Setelah menyelesaikan pendidikan Sekolah Dasar, Peneliti melanjutkan pendidikan tingkat SMP pada tahun 2015 di SMPN 5 Pekanbaru dan lulus pada tahun 2018. Peneliti melanjutkan pendidikan ke tingkat SMA di SMA Negeri 11 Pekanbaru dan Peneliti menyelesaikan pendidikan Sekolah Menengah Atas pada tahun 2021. Pada tahun 2021 Peneliti pernah keterima menjadi mahasiswa di Universitas Islam Negeri Bukittinggi program studi Pendidikan Teknik Informatika dan Komputer melalui jalur Span-Ptkin namun Peneliti merasa tidak cocok mengambil Jurusan Pendidikan. Pada tahun 2022 akhirnya Peneliti kembali tes UTBK dan diterima sebagai mahasiswa Program Studi Sistem Informasi Fakultas Sains dan Teknologi Universitas Islam Negeri Sultan Syarif Kasim. Pada Tahun 2024, Peneliti telah menyelesaikan Kerja Praktek yang bertempatkan di Inspektorat Kota Pekanbaru. Kemudian pada tahun 2025 Peneliti juga telah menyelesaikan Kuliah Kerja Nyata (KKN) di Desa Simpang Tanah Lapang, Kecamatan Kuantan Hilir Kabupaten Kuantan Singingi. Akhir kata, Peneliti Mengucapkan rasa syukur tak terhingga atas selesainya Tugas Akhir ini yang berjudul **"KLASIFIKASI CITRA PENYAKIT TOMAT BERDASARKAN CITRA DAUN MENGGUNAKAN ALGORITMA CONVOLUTIONAL NEURAL NETWORK"**.