

BAB II

TINJAUAN PUSTAKA

2.1 Penelitian Relevan

Penelitian relevan merujuk pada studi-studi terdahulu yang memiliki keterkaitan langsung dengan topik yang sedang dibahas, dan keberadaannya sangat penting karena berfungsi untuk memperkuat argumen teoritis dan metodologis dalam penelitian yang sedang dilakukan. Untuk mengetahui perbandingan penelitian yang dilakukan dengan penelitian yang sudah ada, maka perlu dilakukan studi sejenis. Berikut merupakan beberapa penelitian terdahulu:

Tabel 2. 1 Penelitian Relevan

No.	1
Nama Peneliti	Wahyuni Fithratul Zalmi, Pujo Hari Saputro, Jonathan Sitanggang, Kevin Leatemia
Tahun	2025
Judul	Penerapan <i>Convolutional Neural Network</i> (CNN) untuk Klasifikasi Penyakit Daun Tomat
Metodologi	CNN
Kesimpulan	Penelitian ini mengusulkan pendekatan modern berbasis kecerdasan buatan menggunakan arsitektur CNN untuk mengenali dan mengklasifikasikan penyakit pada daun tomat secara otomatis, krusial untuk mencegah kerugian ekonomi.
Perbedaan	Pada penelitian ini memiliki fokus kelas yang lebih terbatas (3 kelas spesifik, <i>Early Blight</i> , <i>Late Blight</i> dan <i>Septoria Leaf Spot</i>) sedangkan pada penelitian pembeda secara umum tidak disebutkan jumlah kelasnya.
No.	2
Nama Peneliti	Rendra Soekarta, Nirwana Nurdjan, Ardian Syah

Tahun	2023
Judul	Klasifikasi Penyakit Tanaman Tomat Menggunakan Metode <i>Convolutional Neural Network</i> (CNN)
Metodologi	CNN
Kesimpulan	Penelitian ini bertujuan membangun sistem klasifikasi penyakit tanaman tomat dan mendapatkan hasil akurasi sebesar 96,40% untuk klasifikasi 10 jenis penyakit, menunjukkan potensi CNN dalam meminimalisir kesalahan identifikasi.
Perbedaan	Jumlah kelas yang diklasifikasikan berbeda, penelitian ini berfokus pada 3 kelas spesifik (<i>Early Blight</i> , <i>Late Blight</i> dan <i>Septoria Leaf Spot</i>) berpotensi mendapatkan akurasi yang lebih tinggi karena rentang kelas yang lebih sempit, sedangkan penelitian pembeda menguji 10 jenis penyakit.
No.	3
Nama Peneliti	Roni Halim Saputra, Rito Cipta Sigitta Hariyono, Fathulloh
Tahun	2023
Judul	Deteksi Penyakit Tomat Melalui Citra Daun menggunakan Metode <i>Convolutional Neural Network</i>
Metodologi	CNN
Kesimpulan	Penelitian ini mencoba mengidentifikasi penyakit pada tanaman tomat melalui citra daun menggunakan <i>deep learning</i> dengan metode CNN, yang diharapkan dapat mengatasi kendala dalam membedakan gejala penyakit yang hampir mirip.

Perbedaan	Pada penelitian ini mempersempit fokus pada klasifikasi 3 penyakit spesifik (yang gejalanya mirip) melalui analisis komparatif, sementara penelitian terdahulu memiliki fokus yang lebih luas (10 kelas) dengan arsitektur yang lebih sederhana.
No.	4
Nama Peneliti	Nining Putri Ningsih, Emi Suryadi, Lalu Darmawan Bakti, Bahtiar Imran
Tahun	2022
Judul	Klasifikasi Penyakit <i>Early Blight</i> dan <i>Late Blight</i> pada Tanaman Tomat Berdasarkan Citra Daun Menggunakan Metode CNN Berbasis <i>Website</i>
Metodologi	CNN
Kesimpulan	Penelitian ini menunjukkan bahwa penggunaan algoritma CNN mendapatkan hasil akurasi dan <i>recall</i> yang tinggi, serta <i>loss</i> yang kecil pada <i>epoch</i> 100, dan sistem klasifikasi penyakit tersebut berhasil diimplementasikan ke dalam aplikasi berbasis <i>website</i> .
Perbedaan	Penelitian terdahulu berfokus pada implementasi berbasis <i>website</i> , sementara penelitian ini berfokus pada analisis metrik mendalam model yang optimal dan akurat.
No.	5
Nama Peneliti	Abdul Haseeb Wajid, Najia Saher, Syed Ali Nawaz, Mohammad Arshad, Mohammad Nasir
Tahun	2024
Judul	<i>Tomato Leaf Disease Detection and Classification Using Convolution Neural Network and Machine Learning</i>

Metodologi	CNN
Kesimpulan	Penelitian ini telah membuat perbandingan yang rumit antara pembelajaran mesin konvensional dan <i>deep learning</i> untuk klasifikasi citra daun tomat, menekankan pentingnya identifikasi penyakit yang cepat dan tepat untuk pengelolaan tanaman yang efisien.
Perbedaan	Penelitian ini memberikan solusi yang lebih fokus dan teruji untuk kasus klasifikasi 3 penyakit daun tomat yang spesifik, termasuk <i>Septoria Leaf Spot</i> yang merupakan <i>overlap</i> dengan penelitian terdahulu.
No.	6
Nama Peneliti	Adhitya Jamalludin Bastari, Anis Cherid
Tahun	2023
Judul	Klasifikasi Penyakit Tanaman Tomat Menggunakan <i>Convolutional Neural Network</i> dan Implementasi Model H5 pada Aplikasi Desktop
Metodologi	CNN
Kesimpulan	Penelitian ini berhasil mencapai akurasi 99% dalam mengklasifikasikan citra daun tomat sehat serta penyakit jamur <i>septoria</i> , jamur <i>fulva</i> , dan target spot menggunakan model <i>Inception V3</i> .
Perbedaan	Meskipun menggunakan arsitektur serupa (<i>Inception V3</i>), kelas penyakit yang diuji berbeda. Penelitian terdahulu menggunakan Jamur <i>Fulva</i> & Target Spot, sementara penelitian ini menggunakan <i>Early Blight</i> , <i>Late Blight</i> dan <i>Septoria Leaf Spot</i> .

No.	7
Nama Peneliti	Jinzhu Lu, Lijuan Tan, Huanyu Jiang
Tahun	2021
Judul	<i>Review on Convolutional Neural Network (CNN) Applied to Plant Leaf Disease Classification</i>
Metodologi	CNN
Kesimpulan	Penelitian ini merupakan tinjauan yang menganalisis studi-studi terdahulu, memberikan pemahaman menyeluruh tentang peran <i>Convolutional Neural Network</i> (CNN) sebagai metode diagnostik penyakit daun pada berbagai jenis tanaman.
Perbedaan	Penelitian terdahulu berfokus pada tinjauan literatur (review) untuk merangkum penelitian CNN yang sudah ada, sedangkan penelitian ini merupakan penelitian eksperimental yang mengisi gap yang diidentifikasi dari tinjauan tersebut, yaitu dengan mengimplementasikan dan membandingkan secara empiris dua arsitektur <i>Transfer Learning</i> (<i>Inception V3</i> dan <i>VGG-19</i>) pada kasus klasifikasi tiga kelas citra daun tomat yang spesifik.
No.	8
Nama Peneliti	Clairine A. Sanjaya, Minto Waluyo
Tahun	2025
Judul	Analisis Perbandingan <i>Transfer Learning Densenet201</i> dan <i>VGG-19</i> Terhadap Performa Klasifikasi Kualitas Buah Tomat
Metodologi	<i>Transfer Learning</i>

Kesimpulan	Penelitian ini membandingkan metode <i>transfer learning</i> DenseNet201 dan VGG19 untuk analisis kualitas buah tomat, bertujuan untuk mendapatkan hasil yang lebih baik dalam klasifikasi kualitas buah tomat.
Perbedaan	Objek penelitian berbeda secara fundamental. Penelitian terdahulu berfokus pada buah Tomat, sedangkan penelitian ini berfokus pada daun tanaman Tomat yang berpenyakit.

2.2 Landasan Teori

Sebagai landasan melakukan penelitian yang akan dilakukan maka dibahas teori yang berkaitan. Berikut ini penulis uraikan landasan teori dari penelitian ini.

2.1.1 Tanaman Tomat dan Penyakit Daun

Tomat adalah komoditas pertanian yang rentan terhadap infeksi patogen seperti jamur, bakteri, dan virus. Beberapa penyakit daun tomat yang umum dan menjadi fokus utama dalam penelitian klasifikasi citra meliputi:

1. *Early Blight* (Hawal Dini)

Early blight adalah penyakit umum pada tanaman tomat yang disebabkan oleh infeksi jamur. Penyakit ini sangat sering ditemukan di daerah dengan kelembaban tinggi dan suhu hangat. Meskipun namanya "*early*" (awal), penyakit ini dapat menyerang tanaman di semua tahap pertumbuhan, tetapi gejala paling sering muncul saat tanaman mulai berbuah. Penyakit umum pada tanaman tomat yang disebabkan oleh infeksi jamur. Penyakit ini sangat sering ditemukan di daerah dengan kelembaban tinggi dan suhu hangat. Ditandai dengan bintik-bintik cokelat kehitaman pada daun yang memiliki pola lingkaran konsentris seperti target, di mana jaringan sekitar bercak menguning dan daun yang terserang parah akan mengering serta gugur dari bawah ke atas, dan pada serangan lanjut dapat muncul bercak serupa pada batang serta bercak hitam kering pada pangkal buah (Dhaval, et al., 2021).



Gambar 2. 1 Early Blight

2. *Late Blight* (Hawal Daun)

Late blight adalah penyakit paling merusak dan cepat menyebar pada tanaman tomat. Penyakit ini sangat ditakuti karena dapat memusnahkan seluruh tanaman dalam hitungan hari jika kondisi cuaca mendukung (lembab dan sejuk). Berbeda dengan *early blight*, *late blight* disebabkan oleh mikroorganisme mirip jamur (*oomycete*) bernama *Phytophthora infestans*. Patogen ini sangat agresif dan sporanya mudah terbawa angin dalam jarak jauh. Ditandai dengan bercak basah hijau keabu-abuan pada daun yang meluas sangat cepat sehingga daun menjadi coklat hitam, layu, dan membusuk, dengan ciri khas munculnya lapisan jamur putih seperti kapas di permukaan bawah daun saat lembab, serta serangan pada batang berupa bercak coklat memanjang dan pada buah muncul bercak besar kasar yang dengan cepat membusukkan seluruh buah (Jehani, et al., 2025)



Gambar 2. 2 Late Blight

3. *Septoria Leaf Spot* (Bercak daun septoria)



Gambar 2. 3 *Septoria Leaf Spot*

Septoria leaf spot adalah penyakit daun yang sangat umum dan sering menimbulkan kerusakan signifikan pada tanaman tomat. Penyakit ini biasanya menyerang setelah tanaman mulai berbuah dan dimulai dari daun-daun bagian bawah, kemudian menyebar ke atas. Penyakit ini disebabkan oleh jamur patogen bernama *Septoria lycopersici*. Jamur ini bertahan hidup pada sisa-sisa tanaman tomat yang sakit di tanah dan pada gulma inang. Penyebarannya terutama melalui percikan air hujan atau air siraman. Ditandai dengan bercak-bercak kecil (1,5-6 mm) yang tersebar di permukaan daun, memiliki ciri khas pinggiran coklat gelap atau kehitaman dengan bagian tengah lebih terang (abu-abu atau kecoklatan pucat), serta di tengah bercak terdapat titik-titik hitam kecil (*piknidia*) penghasil spora, yang menyebabkan daun menguning, mengering, dan gugur dari bawah ke atas (Pandey, A, et al., 2024).

2.1.2 Pengolahan Citra Digital

Pengolahan Citra Digital adalah bidang ilmu yang berfokus pada pemrosesan dan analisis citra dua dimensi (gambar digital yang tersusun dari piksel) menggunakan algoritma dan komputer, dengan tujuan utama untuk meningkatkan kualitas visual citra (misalnya, mengurangi noise dan meningkatkan kontras), mengekstrak fitur atau informasi yang relevan (misalnya, deteksi tepi dan segmentasi objek), atau mengubahnya menjadi bentuk yang lebih mudah dipahami oleh manusia atau sistem cerdas, yang penerapannya sangat luas mulai dari pencitraan medis (*CT-scan*), pengenalan wajah, hingga analisis citra satelit.

2.1.3 Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) adalah jenis utama jaringan saraf tiruan (*Deep Learning*) yang dirancang khusus untuk menganalisis dan memproses data visual (gambar dan citra) dengan tingkat akurasi tinggi (Arvio et al, 2023). Arsitektur CNN terdiri dari beberapa lapisan utama: *Convolutional Neural Network* (CNN) adalah jenis utama jaringan saraf tiruan (*Deep Learning*) yang dirancang khusus untuk menganalisis dan memproses data visual (gambar dan citra) dengan tingkat akurasi tinggi. Keunggulan utamanya terletak pada kemampuannya untuk secara otomatis mempelajari dan mengekstrak fitur hierarkis dari gambar (mulai dari tepi, sudut, hingga bentuk kompleks) melalui struktur arsitektur yang khas. Arsitektur dasar CNN terdiri dari dua bagian: Lapisan Ekstraksi Fitur (yang mencakup Lapisan Konvolusi yang menggunakan filter untuk menghasilkan peta fitur, diikuti oleh fungsi aktivasi dan Lapisan Pooling untuk mereduksi dimensi), dan Lapisan Klasifikasi (Lapisan *Fully Connected* dan *Output Softmax*) yang berfungsi untuk menentukan probabilitas kelas akhir. CNN telah merevolusi bidang *Computer Vision* dan digunakan secara luas dalam pengenalan objek, pengenalan wajah, dan diagnosis citra medis (Palupiningsih et al, 2024).

2.1.4 Python

Python adalah bahasa pemrograman tingkat tinggi (*high-level*), interpretatif, dan bersifat *open-source* yang dirancang untuk tujuan umum (*general-purpose*) dan mendukung berbagai paradigma pemrograman, termasuk berorientasi objek (*object-oriented*), fungsional, dan prosedural. *Python* dicirikan sebagai bahasa pemrograman tingkat tinggi yang sangat serbaguna, dengan karakteristik utamanya meliputi sintaks yang sederhana dan mudah dipahami yang menyerupai bahasa Inggris untuk meningkatkan keterbacaan dan memungkinkan penulisan kode yang ringkas; sifat interpretatif-nya memungkinkan eksekusi kode langsung baris per baris tanpa kompilasi, sehingga mempercepat proses *debugging* dan pengembangan; dinamis (*dynamic typing*) yang berarti *Python* secara otomatis menentukan tipe data variabel saat runtime tanpa perlu deklarasi eksplisit; dan yang paling penting, didukung oleh ekosistem pustaka yang sangat luas (seperti *NumPy*, *Pandas*, *TensorFlow*, dan *PyTorch*) yang menjadikannya pilihan dominan untuk analisis data, komputasi numerik, dan pengembangan Kecerdasan Buatan.

2.1.5 Anaconda

Anaconda adalah sebuah distribusi *open-source* yang berfungsi sebagai platform komprehensif untuk bahasa pemrograman *Python* (dan *R*), yang secara khusus ditargetkan untuk bidang Ilmu Data (*Data Science*), *Machine Learning*, dan komputasi ilmiah. Fungsi utama *Anaconda* sebagai distribusi *open-source* untuk komputasi ilmiah adalah menyediakan solusi terintegrasi yang menyederhanakan alur kerja ilmu data: pertama, ia memfasilitasi Penyederhanaan Manajemen Paket dengan menyediakan *installer* tunggal yang sudah membundel *Python* dan lebih dari 720 paket esensial (*library*) untuk ilmu data (seperti *NumPy*, *Pandas*, dan *TensorFlow*), menghilangkan kebutuhan untuk instalasi komponen terpisah; kedua, melalui sistem manajemen paket *Conda*, ia memungkinkan Pengelolaan Lingkungan (*Environment*) yang efisien, di mana pengguna dapat membuat lingkungan virtual terpisah untuk memastikan proyek yang berbeda dapat berjalan dengan versi *Python* atau pustaka spesifik tanpa konflik; dan ketiga, ia menawarkan Antarmuka Pengguna grafis yang ramah (*Anaconda Navigator*) yang memudahkan pengguna mengelola paket dan meluncurkan *Integrated Development Environment* (IDE) penting seperti *Jupyter Notebook* atau *Spyder*.

2.1.5 Jupyter Notebook

Jupyter Notebook adalah sebuah aplikasi *web open-source* yang berfungsi sebagai lingkungan komputasi interaktif, yang esensial bagi data scientist karena memungkinkan pembuatan dan pembagian dokumen *notebook* interaktif berformat *.ipynb* yang secara unik menggabungkan kode hidup (*live code*) (utamanya *Python*), *output* eksekusi, visualisasi data, dan teks naratif dalam bentuk *Markdown* secara bersamaan; cara kerjanya yang berbasis sel (*cell*) memungkinkan eksekusi kode secara bertahap, menjadikannya alat yang sangat kuat untuk eksplorasi data, *prototyping model*, dan menghasilkan dokumentasi proyek yang transparan dan dapat direproduksi (*reproducible*).

2.1.6 Computer Vision

Computer Vision adalah bidang ilmiah dan teknologi antardisiplin di bawah Kecerdasan Buatan (AI) yang berfokus pada pengembangan kemampuan komputer untuk "melihat," memproses, menganalisis, dan memperoleh pemahaman tingkat tinggi dari data visual seperti gambar digital atau video, dengan tujuan utama mengotomatisasi tugas-tugas visual yang biasanya dilakukan manusia. Untuk mencapai hal ini, teknologi ini mengintegrasikan pemrosesan citra dengan algoritma *Deep Learning* (terutama

Convolutional Neural Networks) untuk melakukan tugas-tugas seperti klasifikasi gambar, deteksi dan pelacakan objek, serta segmentasi gambar, menjadikannya fondasi bagi aplikasi revolusioner seperti kendaraan otonom, diagnosis medis otomatis, dan sistem pengenalan wajah (Nazalia et al, 2023).

2.1.7 Machine Learning

Machine Learning (Pembelajaran Mesin) adalah disiplin inti dari Kecerdasan Buatan (AI) yang berfokus pada perancangan algoritma dan model statistik yang memungkinkan sistem komputer untuk secara otomatis belajar dan meningkatkan kinerjanya dari pengalaman (data) tanpa secara eksplisit diprogram; prinsipnya melibatkan proses pelatihan di mana model akan mengidentifikasi pola tersembunyi dalam dataset besar, yang kemudian dibagi menjadi tiga kategori utama yaitu Pembelajaran Terawasi (*Supervised Learning*) yang menggunakan data berlabel untuk tugas prediksi seperti klasifikasi, Pembelajaran Tak Terawasi (*Unsupervised Learning*) yang mencari struktur dan pola dalam data tak berlabel (misalnya *clustering*), serta Pembelajaran Penguatan (*Reinforcement Learning*) di mana agen belajar membuat keputusan melalui sistem *reward* dan *penalty* sehingga memungkinkan sistem untuk membuat prediksi dan keputusan yang cerdas ketika dihadapkan pada data baru.

2.1.9 Arsitektur Neural Network MobileNetV2

Arsitektur *Neural Network MobileNetV2* adalah salah satu arsitektur *Convolutional Neural Network* (CNN) terdepan yang dirancang secara khusus untuk aplikasi visi komputer pada perangkat mobile dan sistem *embedded* (tertanam) dengan sumber daya komputasi yang terbatas. Tujuan utama *MobileNetV2* (dirilis pada tahun 2018) adalah untuk mencapai akurasi yang tinggi selagi mempertahankan efisiensi komputasi yang sangat tinggi, menghasilkan model yang berukuran kecil dan cepat.

Fitur kunci yang membuat arsitektur *MobileNetV2* sangat efisien untuk perangkat terbatas adalah penggabungan dua konsep utama dalam blok dasarnya: pertama, *Inverted Residuals* yang membalikkan desain residual block konvensional dengan memulai dari dimensi rendah, melakukan ekspansi dimensi yang besar, memproses fitur spasial yang kaya menggunakan *Depthwise Convolution* yang efisien, dan diakhiri dengan kompresi kembali ke dimensi rendah, yang secara signifikan meningkatkan daya representasi model sambil mempertahankan *shortcut connection*; dan kedua, *Linear Bottlenecks*, di mana lapisan *bottleneck* (kompresi) di akhir blok menggunakan fungsi

aktivasi *linear* alih-alih *non-linear* seperti ReLU, untuk memastikan bahwa informasi penting yang dienkode dalam ruang berdimensi rendah tidak hilang secara permanen selama proses kompresi, yang merupakan kunci untuk menjaga akurasi tinggi pada model yang sangat kompak.

2.1.10 Deep Learning


Deep Learning adalah sub-bidang dari *Machine Learning* yang merepresentasikan terobosan terbesar dalam Kecerdasan Buatan modern, di mana sistem memanfaatkan Jaringan Saraf Tiruan (*Artificial Neural Networks*) yang memiliki banyak lapisan (*layers*) tersembunyi (*deep*) untuk secara otomatis belajar fitur dan representasi data dari data mentah dalam jumlah besar. Berbeda dengan *Machine Learning* tradisional yang memerlukan *feature engineering manual*, *Deep Learning* mampu mengenali hierarki fitur secara progresif mulai dari fitur sederhana (seperti tepi dan sudut pada gambar) pada lapisan awal hingga fitur yang sangat kompleks (seperti wajah atau konsep semantik) pada lapisan akhir. Model *Deep Learning* didominasi oleh arsitektur spesifik seperti *Convolutional Neural Network* (CNN) untuk *Computer Vision*, *Recurrent Neural Network* (RNN) dan turunannya (LSTM) untuk data *sekuensial* (teks dan suara), serta arsitektur *Transformer* yang menjadi dasar Model Bahasa Besar (LLMs), sehingga memungkinkan aplikasi-aplikasi mutakhir seperti pengenalan gambar, penerjemahan bahasa *real-time*, dan mobil otonom (Haris et al, 2023). Dalam sektor pertanian, deep learning juga membuka peluang baru untuk monitoring tanaman secara *real-time*.

2.2.11 Algoritma Convolutional Neural Network (CNN)

Untuk membantu petani dalam mengatasi dan memberikan pengendalian yang cepat dan tepat terhadap penyakit daun tanaman tomat, pemanfaatan teknologi *Computational Intelligent System* sangat relevan, khususnya melalui model pengenalan objek menggunakan *Deep Learning* bernama *Convolutional Neural Network* (CNN). CNN adalah jenis *Neural Network* yang secara khusus dirancang untuk memproses data citra (*image data*). CNN dikategorikan sebagai *Deep Neural Network* karena memiliki kedalaman jaringan yang tinggi dan merupakan peningkatan dari *Multilayer Perceptron* (MLP) yang dibuat untuk memproses data dua dimensi. Berbeda dengan MLP yang dianggap kurang sesuai untuk klasifikasi citra karena mengabaikan informasi spasial dan memperlakukan setiap piksel sebagai fitur independen, arsitektur CNN lebih unggul

karena memiliki lapisan khusus yang secara otomatis melakukan ekstraksi fitur langsung dari data input mentah, menghasilkan akurasi yang lebih baik dalam pengenalan objek dan deteksi. Arsitektur CNN adalah *feed-forward* dan memiliki kemampuan generalisasi yang lebih baik karena menggunakan konsep pembagian bobot (*weight sharing*), yang secara signifikan mengurangi jumlah parameter yang harus dilatih. Pengurangan parameter ini mencegah *overfitting* dan memungkinkan model dilatih dengan lancar.

Secara umum, arsitektur CNN terbagi menjadi dua bagian besar: *Feature Extraction Layer* (terdiri dari lapisan konvolusi, fungsi aktivasi ReLU, dan pooling) dan *Fully- Connected Layer* (terdiri dari *lapisan fully-connected* dan fungsi aktivasi *Softmax* yang menghasilkan output klasifikasi). Tahap ekstraksi ciri dan tahap klasifikasi dalam CNN terintegrasi dan sama-sama menggunakan proses pembelajaran, sering kali dalam kerangka *Supervised Learning* di mana model dilatih untuk mengelompokkan data berdasarkan variabel target yang telah ditentukan.



Gambar 2. 4 Lapisan CNN

Pada gambar 2.4 di atas menunjukkan layer yang termasuk dalam CNN,

A. *Featured Learning*

Feature learning adalah tahap di mana lapisan-lapisan dalam CNN bekerja untuk mengubah *input* (yang direpresentasikan sebagai angka dalam vektor) menjadi fitur-fitur yang dapat dikenali. Proses ekstraksi fitur ini dilakukan oleh dua lapisan utama, yaitu *convolutional layer* dan *pooling layer* (Goumiri, et al., 2023).

1. *Convolutional Layer*

Lapisan ini terhubung ke area lokal pada input. Tugasnya adalah menghitung output dengan cara mengalikan bobot (*weight*) dengan area kecil yang menjadi target dalam volume *input* (Goumiri, et al., 2023).

2. *Reactified Linear Unit (ReLU)*

ReLU adalah fungsi aktivasi yang berperan sebagai *threshold*. Fungsinya didefinisikan sebagai $f(x) = \max(0, x)$, yang berarti jika nilai piksel pada input kurang dari nol, maka nilainya akan diubah menjadi 0 (Goumiri, et al., 2023).

3. *Pooling Layer*

Pooling layer berfungsi untuk memperkecil ukuran feature map (subsampling) guna mempercepat komputasi. Lapisan ini bekerja pada setiap tumpukan feature map dengan filter umum berukuran 2x2 yang digeser setiap 2 langkah (stride 2) (Goumiri, et al., 2023).

B. Klasifikasi

Pada tahap klasifikasi, setiap neuron akan diproses berdasarkan fitur yang telah diekstraksi sebelumnya. Tahapan ini terdiri dari flatten, fully connected, dan aktivasi softmax.

1. *Flatten*

Lapisan ini berfungsi untuk mengubah (reshape) feature map menjadi bentuk vektor satu dimensi agar dapat digunakan sebagai input pada fully connected layer (Goumiri, et al., 2023).

2. *Fully Connected*

Lapisan ini mirip dengan implementasi pada MLP (Multi-Layer Perceptron) yang berfungsi mengubah dimensi data agar dapat dikelompokkan secara linear. Sebelum masuk ke lapisan ini, data satu dimensi dari convolutional layer harus diubah terlebih dahulu. Meskipun proses ini bersifat irreversible (tidak dapat dikembalikan) dan berisiko menghilangkan informasi aktual, fully connected layer umumnya hanya ditempatkan di akhir jaringan (Goumiri, et al., 2023).

3. *Softmax*

Fungsi softmax digunakan untuk menghitung probabilitas setiap kelas target dari semua kemungkinan kelas. Keunggulan utama softmax adalah outputnya berkisar antara 0 hingga 1 dengan jumlah total probabilitas seluruh kelas adalah satu. Fungsi ini bekerja

dengan mengambil nilai eksponensial dari setiap input, kemudian membaginya dengan jumlah total eksponensial dari seluruh nilai input. Dalam klasifikasi multi-kelas, kelas target akan memiliki nilai probabilitas tertinggi (Goumiri, et al., 2023).

2.2.12 CRISP-DM (*Cross Industry Standard Process For Data Mining*)

Proses Standar Lintas Industri untuk Penambangan Data (CRISP-DM) adalah metodologi pemrosesan model dari penambangan data yang dikembangkan oleh DaimlerChrysler, SPSS, NCR dan industri lainnya sejak tahun 1996. Metodologi Tujuan CRISP-DM adalah untuk menyediakan cetak biru sebagai tahapan proses pengumpulan data, yang dikenal sebagai proses standar industri untuk pengolahan data. Pemahaman Bisnis, Pemahaman Data, Persiapan Data, Pemodelan, Evaluasi, dan Penerapan adalah enam langkah dalam proses ini. Cross Industry Standard Process for Data Mining (CRISP-DM) yang terbagi menjadi enam tahapan sebagai berikut business understanding, data understanding, data preparation, modeling, evaluation dan deployment.



Gambar 2. 5 CRISP-DM

1. *Business Understanding*

Pada tahap pertama ini, fokus pada pemahaman bisnis. Tujuan atau goals terkait bisnis secara keseluruhan dicari, dan kemudian tujuan tersebut diterapkan pada

permasalahan data mining. Penerapan ini membantu dalam persiapan awal strategi untuk mencapai selanjutnya.

2. *Data Understanding*

Tahap ini mencakup pengumpulan data yang akan digunakan dan pemahaman terhadap data tersebut melalui eksplorasi data. Identifikasi dan evaluasi kualitas data dilakukan dengan pemeriksaan data yang tidak valid serta pembersihan data. Jika diperlukan, subset data yang berpotensi mengandung pola akan dipilih untuk diproses pada tahap selanjutnya.

3. *Data Preparation*

Pada tahap ini, persiapan dilakukan untuk mengolah data yang telah dikumpul menjadi dataset yang dapat digunakan pada tahapan berikutnya. Analisis dataset dilakukan berdasarkan kasus dan variable yang dipilih untuk analisis. Jika diperlukan, data dapat mengalami transformasi pada variable tertentu. Selanjutnya, dataset diberikan untuk persiapan penggunaan pada tahap modelling.

4. *Modelling*

Tahap ini melibatkan pemilihan dan penerapan teknik *modelling* yang sesuai. Kalibrasi model diperlukan untuk mendapatkan hasil optimal, dan perlu diperhatikan bahwa beberapa teknik dapat digunakan untuk permasalahan data mining yang sama. Jika diperlukan, dapat kembali ke tahap sebelumnya untuk menyesuaikan bentuk datanya.

5. *Evaluation*


Pada tahap evaluasi, dilakukan pengevaluasian terhadap kualitas dan efektivitas satu atau lebih model yang telah dibuat pada tahap *modelling*. Evaluasi ini membantu menentukan apakah model mencapai tujuan yang diharapkan, dengan merujuk pada pemahaman bisnis. Aspek penting yang mungkin belum diperhitungkan juga dievaluasi. Keputusan terkait hasil data mining diambil jika semua sesuai.

6. *Deployment*

Tahap terakhir, *deployment* melibatkan pemanfaatan model yang telah dibuat. Ini dapat dilakukan dengan pembuatan laporan sederhana atau implementasi proses data mining yang lebih kompleks.

2.2 Kerangka Pemikiran

Kerangka pemikiran menggambarkan bagaimana tahapan-tahapan dalam melakukan penelitian ini. Kerangka pemikiran mendiskripsikan keterkaitan antara satu komponen dengan komponen lainnya. Kerangka pemikiran juga bisa di sebut sebagai visualisasi atau diagram yang menggambarkan secara umum proses logika dari sebuah penelitian.



Gambar 2. 6 Kerangka Pemikiran

1. *Indicators*

Indicators adalah parameter yang akan diuji pada penelitian ini. Masukan atau input indicator yang akan diolah pada tahap selanjutnya untuk menentukan parameter penelitian yang akan diuji. Dalam penelitian ini, indikator yang digunakan adalah citra daun tanaman tomat.

2. *Proposed Method*

Proposed Method adalah tentang metode yang diterapkan untuk menyelesaikan masalah berdasarkan *indicator* yang telah diperoleh. Adapun dalam penelitian ini, bertujuan untuk menghasilkan algoritma CNN untuk mendeteksi penyakit daun tanaman tomat melalui pemodelan yang dilakukan.

3. *Objective*

Objective adalah tujuan yang ingin dicapai dalam sebuah penelitian. Adapun tujuan dari penelitian ini adalah mendapatkan hasil model yang dapat digunakan untuk mendeteksi serta mengklasifikasi penyakit dari percobaan yang akan dilakukan.

4. *Measurement*

Measurement adalah sebuah proses untuk mengetahui hasil dari suatu penelitian. Setelah melalui proses dari pengolahan data hingga penerapan algoritma, didapatkan *confusion matrix* sebagai representasi hasil dari evaluasi atau pengujian yang dilakukan.