

**IMPLEMENTASI MODEL *HYBRID CONVOLUTIONAL NEURAL NETWORK*
DAN *LONG SHORT-TERM MEMORY* UNTUK IDENTIFIKASI
KERUSAKAN DAUN KEDELAI AKIBAT SERANGAN
LARVA *LEPIDOPTERA* DAN *DIABROTICA***

(Skripsi)

**Oleh
NANDA EVITARINA**



**JURUSAN MATEMATIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
2024**

ABSTRACT

IMPLEMENTATION OF HYBRID CONVOLUTIONAL NEURAL NETWORK AND LONG SHORT-TERM MEMORY MODEL FOR IDENTIFICATION SOYBEAN LEAVES DAMAGE DUE TO LEPIDOPTERA AND DIABROTICA LARVAE ATTACK

By

NANDA EVITARINA

The identification of soybean leaf damage is an interesting case to be studied in connection with the increase in the demand for soybean commodities in Indonesia. Soybean production and yields are affected by pest attacks that cause loss of agricultural yields each year. One of these pests is insects. Caterpillar (insect larvae of the order Lepidoptera) and *Diabrotica speciosa* insects are types of pests that often attack the soybean leaves, damaging the quality and quantity of soybean production. Therefore, this study aims to assist farmers in an effort to provide the right treatment for soybean leaf damage. This identification requires good machine learning algorithms such as deep learning. Deep learning is recommended for identification or classification because it can learn features from images of soybean leaves damage automatically. In this research, the deep learning model used to identify soybean leaves damage is a combination of Convolutional Neural Network (CNN) and Long Short-Term Memory (LSTM) where CNN can solve the problem of spatial characteristics and LSTM can understand the temporal context of image data. The model is developed through image processing stages such as data augmentation using the roboflow platform. The dataset used comes from the Mendeley Data platform with a total dataset of 6410. The combined CNN-LSTM hybrid model performed well in identifying soybean leaves damage with an accuracy of 93%, precision of 93%, recall of 93%, and f1-score of 93%.

Keywords : Soybean, Caterpillar, *Diabrotica Speciosa*, Deep Learning, CNN, LSTM, CNN-LSTM

ABSTRAK

IMPLEMENTASI MODEL *HYBRID CONVOLUTIONAL NEURAL NETWORK* DAN *LONG SHORT-TERM MEMORY* UNTUK IDENTIFIKASI KERUSAKAN DAUN KEDELAI AKIBAT SERANGAN LARVA *LEPIDOPTERA* DAN *DIABROTICA*

Oleh

NANDA EVITARINA

Identifikasi kerusakan daun kedelai menjadi kasus yang menarik untuk diteliti sehubungan dengan terjadinya peningkatan kebutuhan komoditas kedelai di Indonesia. Produksi dan hasil panen kedelai dipengaruhi oleh serangan hama yang menyebabkan hilangnya hasil pertanian tiap tahun. Salah satu hama tersebut adalah serangga *Caterpillar* (larva serangga Ordo *Lepidoptera*) dan serangga *Diabrotica speciosa* adalah jenis hama yang sering menyerang daun kedelai sehingga merusak kualitas dan kuantitas produksi kedelai. Oleh karena itu, penelitian ini bertujuan untuk membantu petani dalam upaya memberi penanganan yang tepat pada kerusakan daun kedelai. Identifikasi ini membutuhkan algoritma pembelajaran mesin yang baik seperti *deep learning*. *Deep learning* disarankan untuk melakukan identifikasi atau klasifikasi karena dapat mempelajari fitur dari gambar kerusakan daun kedelai secara otomatis. Pada penelitian ini model *deep learning* yang digunakan untuk mengidentifikasi kerusakan daun kedelai adalah penggabungan *Convolutional Neural Network* (CNN) dan *Long Short-Term Memory* (LSTM) di mana CNN dapat memecahkan masalah karakteristik spasial dan LSTM dapat memahami konteks temporal pada data gambar. Model tersebut dikembangkan melalui tahap pemrosesan gambar seperti augmentasi data menggunakan platform *roboflow*. *Dataset* yang digunakan berasal dari platform *Mendeley Data* dengan jumlah dataset sebanyak 6410. Model *hybrid* CNN-LSTM yang digabungkan berkinerja baik dalam mengidentifikasi kerusakan daun kedelai dengan capaian akurasi sebesar 93%, presisi sebesar 93%, *recall* sebesar 93%, dan *f1-score* sebesar 93%.

Kata Kunci : Kedelai, *Caterpillar*, *Diabrotica Speciosa*, *Deep Learning*, CNN, LSTM, CNN-LSTM

**IMPLEMENTASI MODEL *HYBRID CONVOLUTIONAL NEURAL NETWORK*
DAN *LONG SHORT-TERM MEMORY* UNTUK IDENTIFIKASI
KERUSAKAN DAUN KEDELAI AKIBAT SERANGAN
LARVA *LEPIDOPTERA* DAN *DIABROTICA***

Oleh

**NANDA EVITARINA
2017031069**

Skripsi

Sebagai Salah Satu Syarat untuk Mencapai Gelar
SARJANA MATEMATIKA

Pada

Jurusan Matematika
Fakultas Matematika dan Ilmu Pengetahuan Alam
Universitas Lampung



**JURUSAN MATEMATIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
2024**

Judul Skripsi

: **IMPLEMENTASI MODEL *HYBRID CONVOLUTIONAL NEURAL NETWORK* DAN *LONG SHORT-TERM MEMORY* UNTUK IDENTIFIKASI KERUSAKAN DAUN KEDELAI AKIBAT SERANGAN LARVA *LEPIDOPTERA* DAN *DIABROTICA***

Nama Mahasiswa

: **Nanda Evitarina**

Nomor Pokok Mahasiswa

: **2017031069**

Jurusan

: **Matematika**

Fakultas

: **Matematika dan Ilmu Pengetahuan Alam**



Dr. Dian Kurniasari, S.Si., M.Sc.
NIP. 19690305 199603 2 001

Prof. Dr. Ir. Hamim Sudarsono, M.Sc.
NIP. 19600119 198403 1 003

2. Ketua Jurusan Matematika

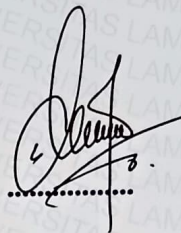
Dr. Aang Nuryaman, S.Si., M.Si.
NIP. 19740316 200501 1 001

MENGESAHKAN

1. Tim Penguji

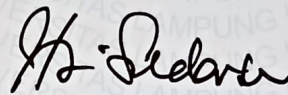
Ketua

: **Dr. Dian Kurniasari, S.Si., M.Sc.**



Sekretaris

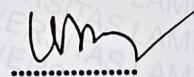
: **Prof. Dr. Ir. Hamim Sudarsono,
M.Sc.**



Penguji

Bukan Pembimbing

: **Ir. Warsono, M.S., Ph.D.**



2. Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam
Universitas Lampung



Dr. Eng. Heri Satria, S.Si., M.Si.

NIP. 19711001 200501 1 002

Tanggal Lulus Ujian Skripsi: **28 Agustus 2024**

PERNYATAAN SKRIPSI MAHASISWA

Saya yang bertanda tangan di bawah ini:

Nama : **Nanda Evitarina**
Nomor Pokok Mahasiswa : **2017031069**
Jurusan : **Matematika**
Judul Skripsi : **Implementasi Model *Hybrid Convolutional Neural Network* dan *Long Short-Term Memory* Untuk Identifikasi Kerusakan Daun Kedelai Akibat Serangan Larva *Lepidoptera* dan *Diabrotica***

Dengan ini menyatakan bahwa skripsi ini adalah hasil pekerjaan saya sendiri dan apabila di kemudian hari terbukti bahwa skripsi ini merupakan hasil salinan atau dibuat oleh orang lain, maka saya bersedia menerima sanksi sesuai dengan ketentuan akademik yang berlaku.

Bandar Lampung, 28 Agustus 2024

Penulis



Nanda Evitarina
NPM. 2017031069

RIWAYAT HIDUP

Penulis bernama lengkap Nanda Evitarina lahir di Bandar Lampung pada tanggal 22 Januari 2002. Penulis merupakan anak kedua dari pasangan Bapak Jamil dan Almarhumah Ibu Sama'ah.

Penulis memulai perjalanan pendidikannya dari sekolah dasar di SD Negeri 1 Waylaga pada tahun 2008-2014. Lalu penulis melanjutkan pendidikan sekolah menengah pertama di SMP Tiara Bhakti pada tahun 2014-2017. Pada tahun 2017-2020, penulis melanjutkan pendidikan sekolah menengah atas di SMA Negeri 6 Bandar Lampung. Tidak berhenti disitu, penulis melanjutkan pendidikan Strata Satu (S1) di Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam (FMIPA) Universitas Lampung pada tahun 2020 melalui jalur SBMPTN.

Selama perkuliahan, penulis pernah menjadi pengurus HIMATIKA Unila dan menjabat sebagai anggota Bidang Keilmuan pada tahun 2021. Selain itu, penulis pernah menjadi asisten dosen mata kuliah fungsi kompleks pada tahun 2023 selama 1 semester. Penulis melaksanakan Kerja Praktik (KP) di Badan Pusat Statistik Kabupaten Mesuji pada bulan Januari-Februari 2023. Lalu penulis juga melaksanakan Kuiah Kerja Nyata (KKN) pada bulan Juni-Agustus 2023 di Pekon Kota Batu, Kecamatan Kota Agung Pusat, Kabupaten Tanggamus.

KATA INSPIRASI

“Dan bersabarlah. Sesungguhnya Allah beserta orang-orang yang sabar .”
(Q.S Al-Anfal: 46)

”Dan dia bersama kamu di mana saja kamu berada. Dan Allah Maha Melihat apa yang kamu kerjakan.”
(Q.S Al-Hadid: 4)

“Barang siapa yang bertakwa kepada Allah, niscaya Dia akan memberi jalan keluar.”
(Q.S At-Talaq: 2)

“Sukses bukanlah sesuatu yang kebetulan. Itu adalah kerja keras, ketekunan, dan belajar dari kegagalan.”
(Colin Powell)

PERSEMBAHAN

Alhamdulillahirobbil'alamin

Puji syukur kepada Allah SWT karena atas nikmat dan karunia-Nya, Shalawat serta salam selalu tercurah kepada baginda Nabi Muhammad SAW yang telah memberikan kabar gembira kepada umat manusia.

Dengan tulus hati, ku persembahkan karya sederhana penuh perjuangan dan kesabaran ini untuk:

Ayahanda Jamil, Almarhumah Ibunda Sama'ah dan Kakakku Andi Saputra

Terima kasih atas limpahan kasih sayang, pengorbanan, dukungan, serta selalu mendoakanku. Karena atas doa dan ridho kalian, Allah SWT memudahkan setiap langkah perjalanan hidupku. Terima kasih kepada ayahanda yang selalu menguatkan di setiap cobaan hidup yang menghampiriku. Terimalah kado kecil ini dariku untuk membalas semua pengorbanan dan kerja keras yang selama ini kalian lakukan.

Dosen Pembimbing dan Pembahas

Terima kasih kepada dosen pembimbing dan pembahas yang telah membantu, memberikan motivasi, arahan serta ilmu yang berharga kepada penulis. Semoga Allah SWT senantiasa melimpahkan rahmat keberkahan, serta membalas semua kebaikan dosen pembimbing dan pembahas dengan paha yang berlimpah.

Almamater Tercinta Universitas Lampung

SANWACANA

Puji syukur kehadirat Allah SWT atas limpahan Rahmat dan hidayah-Nya, sehingga penulis dapat menyelesaikan skripsi yang berjudul “Implementasi Model *Hybrid Convolutional Neural Network* dan *Long Short-Term Memory* Untuk Identifikasi Kerusakan Daun Kedelai Akibat Serangan Larva *Lepidoptera* dan *Diabrotica*”. Dalam proses penyusunan skripsi ini, banyak pihak yang telah memberikan bimbingan, motivasi, bantuan, dan saran sehingga skripsi ini dapat terselesaikan. Untuk itu penulis ingin mengucapkan terima kasih kepada:

1. Ibu Dr. Dian Kurniasari, S.Si., M.Sc. selaku dosen Pembimbing I dan Pembimbing Akademik yang selalu berkenan memberikan arahan, bimbingan, saran, serta dukungan kepada penulis dalam penyusunan skripsi ini.
2. Bapak Prof. Dr. Ir. Hamim Sudarsono, M.Sc. selaku dosen Pembimbing II yang telah memberikan arahan, bimbingan, dan dukungan kepada penulis.
3. Bapak Ir. Warsono, M.S., Ph.D. selaku dosen Penguji yang telah memberikan kritik dan saran, serta evaluasi kepada penulis sehingga skripsi ini dapat lebih baik lagi.
4. Bapak Dr. Aang Nuryaman, S.Si., M.Si. selaku Ketua Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.
5. Bapak Dr. Eng. Heri Satria, S.Si., M.Si. selaku Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam.
6. Seluruh dosen, staff, dan karyawan Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam.
7. Orang tua tercinta serta seluruh keluarga besar yang selalu memberikan motivasi dan dukungan serta selalu mendoakan untuk kesuksesan penulis.
8. Sahabat-sahabat penulis Aulia Diah, Defina, Harum, Intan, Nunung, dan

Yazid yang telah memberikan semangat, motivasi dan dukungan kepada penulis.

9. Melin Nur Hazizah, dan Alvandi Wijaya yang selalu setia menemani penulis dalam menyelesaikan penyusunan skripsi ini.
10. Teman-teman satu bimbingan yang telah memberikan semangat, saran, dan bantuan kepada penulis.
11. Teman-teman mahasiswa Jurusan Matematika angkatan 2020.
12. Semua pihak yang terlibat dalam menyelesaikan skripsi ini tidak dapat disebutkan satu persatu.
13. Almamater tercinta Universitas Lampung.

Semoga skripsi ini dapat memberikan banyak manfaat untuk kita semua. Penulis juga menyadari bahwa skripsi ini masih jauh dari kata sempurna, sehingga penulis mengharapkan kritik dan saran yang membangun untuk menyempurnakan skripsi ini.

Bandar Lampung, 28 Agustus 2024

Penulis

Nanda Evitarina

NPM. 2017031069

DAFTAR ISI

	Halaman
DAFTAR TABEL	xv
DAFTAR GAMBAR.....	xvi
I. PENDAHULUAN.....	1
1.1 Latar Belakang dan Masalah	1
1.2 Rumusan Masalah	3
1.3 Tujuan Penelitian.....	4
1.4 Manfaat Penelitian.....	4
II. TINJAUAN PUSTAKA	5
2.1 Penelitian Terkait.....	5
2.2 Klasifikasi Gambar.....	8
2.3 Citra Digital.....	9
2.4 <i>Preprocessing</i> Data	9
2.5 <i>Machine Learning</i>	11
2.6 <i>Deep Learning</i>	12
2.7 <i>Splitting</i> Data.....	13
2.8 <i>Recurrent Neural Network</i> (RNN)	13
2.9 <i>Convolutional Neural Network</i> (CNN).....	14
2.9.1 Lapisan Konvolusi	14
2.9.2 Fungsi Aktivasi	15
2.9.3 Lapisan <i>Pooling</i>	17
2.9.4 Lapisan <i>Fully-Connected</i>	18
2.10 <i>Long Short-Term Memory</i> (LSTM).....	18
2.11 <i>Hybrid CNN-LSTM</i>	21
2.12 Evaluasi Kinerja Model.....	22
III. METODOLOGI PENELITIAN.....	25
3.1 Tempat dan Waktu Penelitian	25
3.2 Data dan Alat Penelitian	26
3.3 Metode Penelitian.....	28
IV. HASIL DAN PEMBAHASAN.....	30

4.1	<i>Input Data</i>	30
4.2	Citra Digital	31
4.3	<i>Preprocessing Data</i>	32
4.4	<i>Splitting Data</i>	34
4.5	Membangun Model <i>Hybrid CNN-LSTM</i>	34
4.6	Validasi Data	38
4.6.1	Hasil Model CNN	38
4.6.2	Hasil Model Hybrid CNN-LSTM	40
4.6.3	Perbandingan Hasil Model CNN dan Model <i>Hybrid CNN-LSTM</i>	41
4.7	Evaluasi Kinerja Model	43
4.8	<i>Benchmarking</i> dengan Penelitian Terdahulu	49
V.	PENUTUP	52
5.1	Kesimpulan.....	52
5.2	Saran	52
	DAFTAR PUSTAKA	53
	LAMPIRAN	

DAFTAR TABEL

Tabel	Halaman
1. Penelitian Terkait	5
2. Sampel Data Penelitian	26
3. <i>Splitting</i> Data.....	33
4. Hasil Akurasi Model CNN dan Model <i>Hybrid</i> CNN-LSTM.....	42
5. <i>Classification Report</i> Model CNN.....	42
6. <i>Classification Report</i> Model <i>Hybrid</i> CNN-LSTM	42
7. <i>Benchmarking</i> dengan Penelitian Terdahulu	46

DAFTAR GAMBAR

Gambar	Halaman
1. Arsitektur RNN	14
2. Contoh <i>Max Pooling</i>	17
3. Arsitektur CNN	18
4. Arsitektur LSTM	19
5. Arsitektur CNN-LSTM	21
6. <i>Confusion Matrix Multiclass</i>	22
7. <i>Flowchart</i>	29
8. Sampel Data Model	30
9. Sampel Matriks Nilai Piksel Data Berlabel <i>Caterpillar</i>	31
10. Hasil <i>Preprocessing</i> Data	33
11. Arsitektur Model <i>Hybrid</i> CNN-LSTM	35
12. <i>Loss</i> dan <i>Validation Loss</i> Model CNN	39
13. <i>Accuracy</i> dan <i>Validation Accuracy</i> Model CNN	39
14. <i>Loss</i> dan <i>Validation Loss</i> Model CNN-LSTM	40
15. <i>Accuracy</i> dan <i>Validation Accuracy</i> Model CNN-LSTM	31
16. Perbandingan grafik <i>loss</i> dan <i>validation loss</i> pada model CNN dan model <i>hybrid</i> CNN-LSTM	42
17. Perbandingan grafik <i>accuracy</i> dan <i>validation accuracy</i> pada model CNN dan model <i>hybrid</i> CNN-LSTM	42
18. <i>Confusion Matrix</i> Model CNN	43
19. <i>Confusion Matrix</i> Model CNN-LSTM	44

I. PENDAHULUAN

1.1 Latar Belakang dan Masalah

Kemajuan teknologi telah membawa transformasi signifikan dalam berbagai aspek kehidupan salah satunya dalam bidang pengolahan citra. Pengolahan citra menyediakan teknik untuk meningkatkan kualitas gambar dan mengestrak fitur-fitur penting, seperti tepi, tekstur, dan warna yang diperlukan untuk melakukan analisis seperti klasifikasi gambar. Terdapat berbagai macam aplikasi klasifikasi gambar memerlukan algoritma pembelajaran yang baik dan model yang dapat menghasilkan akurasi yang tinggi. Penggunaan algoritma *machine learning* dan model yang berbeda telah mengalami kemajuan yang cukup pesat. *Machine learning* adalah cabang dari kecerdasan buatan yang memungkinkan komputer untuk belajar dan beradaptasi menggunakan model matematika berdasarkan data dan pengalaman. Sistem dilatih dengan bantuan *machine learning* dan tidak memerlukan pembelajaran eksplisit. Beberapa tahun terakhir, para peneliti telah menemukan algoritma lain yang lebih efisien untuk pemrosesan gambar dan analisis data dengan hasil akurasi tinggi yang dikenal dengan *Deep Learning* (Bansal dkk., 2023). Berbeda dengan *machine learning* yang memproses data dengan algoritma yang sederhana, sedangkan *deep learning* memproses data dengan jaringan saraf buatan yang kompleks.

Banyak metode *deep learning* yang dapat digunakan untuk memproses data gambar salah satunya yaitu *Convolutional Neural Network* (CNN), dan *Long Short-Term Memory* (LSTM). Menurut Vasumathi dan Kamarasan (2021), CNN adalah sebuah jenis arsitektur *neural network* yang efisien dalam melakukan

klasifikasi data dan sangat ideal untuk memproses gambar 2D. Fungsi utama dari CNN adalah untuk melakukan klasifikasi, deteksi objek, segmentasi, dan pengenalan wajah pada gambar. Kemudian, LSTM merupakan salah satu jenis dari *Recurrent Neural Network* (RNN) dimana dilakukan modifikasi pada RNN dengan menambahkan *memory cell* yang dapat menyimpan informasi untuk jangka waktu yang lama (Manaswi, 2018). Model LSTM telah digunakan dalam berbagai algoritma *deep learning*, termasuk pemrosesan bahasa alami, pengenalan suara, keterangan gambar, dan analisis video.

Metode *deep learning* juga dapat diterapkan dalam bidang pertanian seperti meningkatkan efisiensi untuk analisis gambar tanaman, deteksi kerusakan tanaman, dan prediksi hasil panen secara akurat dan otomatis. Salah satu kasus yang menarik untuk diteliti yaitu melakukan identifikasi kerusakan pada tanaman kedelai. Topik ini diambil karena kebutuhan komoditas kedelai terus meningkat dari tahun ke tahun baik sebagai bahan pangan utama maupun sebagai bahan pangan pendukung (Asnunun dan Kartika, 2020). Namun demikian, menurut Badan Pusat Statistik (2021), proyeksi kedelai yang dihasilkan dari dalam negeri pada tahun 2021 hanya mencapai 613,3 ribu ton. Capaian ini, turun 3,01% dari produksi tahun 2020 yang mencapai 632,3 ribu ton dan akan terus mengalami penurunan hingga tahun 2024. Hal ini disebabkan oleh persaingan ketat penggunaan lahan dengan komoditas lain seperti jagung dan cabai serta dipengaruhi oleh serangan hama dan penyakit yang merusak tanaman kedelai. Diperkirakan terdapat sekitar 380 spesies serangga hama yang berasosiasi dengan tanaman kedelai di berbagai belahan dunia (Patel dan Rahul, 2020). Oleh karena itu, para petani mengalami kesulitan dalam mengenali jenis kerusakan pada daun tanaman kedelai yang diakibatkan oleh serangan hama.

Penelitian sebelumnya yang menjadi acuan penelitian ini adalah penelitian yang dilakukan oleh Khattak dkk., pada tahun 2021 tentang keefektifan klasifikasi penyakit pada buah dan daun jeruk menggunakan model CNN mendapatkan nilai akurasi sebesar 94% yang berarti bahwa hasil deteksi tersebut baik. Selain itu, penelitian lainnya yaitu penelitian yang dilakukan oleh Belay dkk., pada tahun

2022 tentang klasifikasi penyakit buncis menggunakan metode *hybrid* CNN-LSTM dengan hasil akhir akurasi sebesar 92%.

Berdasarkan uraian di atas, penelitian ini mengimplementasikan model CNN dan LSTM untuk identifikasi kerusakan daun kedelai akibat serangan larva serangga hama. Sesuai dengan referensi yang digunakan dalam penelitian ini, gambar-gambar kerusakan daun atau tanaman kedelai yang digunakan dalam penelitian ini adalah foto-foto lapangan dari dari tanaman kedelai yang dikelompokkan dalam tiga kategori, yaitu: (1) tanaman kedelai yang terserang *caterpillar* (larva serangga Ordo Lepidoptera), (2) tanaman kedelai yang terserang oleh serangga *Diabrotica speciosa* (spesies serangga dari Famili Chrysomelidae, Ordo Coleoptera), dan (3) tanaman sehat atau terbebas dari serangan hama. Foto-foto referensi dalam penelitian ini bersumber dari <https://data.mendeley.com/datasets/bycbh73438/1>. Gambar-gambar di dalam link ini diambil dengan menggunakan smartphone dan drone. Dijelaskan bahwa ketinggian pengambilan foto bervariasi dan dilakukan pada waktu, hari, dan lingkungan alam yang berbeda-beda (Mignoni, 2021).

1.2 Rumusan Masalah

Berdasarkan uraian dari latar belakang di atas, rumusan masalah dalam penelitian ini adalah:

1. Bagaimanakah pemodelan klasifikasi dengan menggunakan model *hybrid* CNN-LSTM dalam pengidentifikasian kerusakan daun kedelai akibat serangan larva *Lepidoptera* dan *Diabrotica speciosa*?
2. Bagaimanakah tingkat keakuratan penggunaan model *hybrid* CNN-LSTM pada identifikasi kerusakan daun kedelai akibat serangan larva *Lepidoptera* dan *Diabrotica speciosa*?

1.3 Tujuan Penelitian

Tujuan dari penelitian ini adalah sebagai berikut:

1. Membangun model *hybrid* CNN-LSTM pada identifikasi kerusakan daun kedelai akibat serangan larva *Lepidoptera* dan *Diabrotica speciosa*.
2. Mengetahui tingkat keakuratan penggunaan model *hybrid* CNN-LSTM pada identifikasi kerusakan daun kedelai akibat serangan larva *Lepidoptera* dan *Diabrotica speciosa*.

1.4 Manfaat Penelitian

Manfaat dari penelitian ini adalah sebagai berikut:

1. Membantu masyarakat dalam upaya mengurangi kesalahan dalam mengenali kerusakan daun kedelai akibat serangan larva *Lepidoptera* dan *Diabrotica speciosa* sehingga dapat memberi penanganan yang tepat.
2. Menambah wawasan dan pemahaman peneliti tentang klasifikasi melalui akurasi yang didapatkan dari penggunaan model *hybrid* CNN-LSTM pada identifikasi kerusakan daun kedelai akibat serangan larva *Lepidoptera* dan *Diabrotica speciosa*.

II. TINJAUAN PUSTAKA

2.1 Penelitian Terkait

Penelitian terdahulu yang berkaitan dengan penelitian ini digunakan sebagai acuan dan perbandingan untuk hasil klasifikasi. Topik penelitian yang menjadi *benchmarking* adalah klasifikasi dengan model *hybrid* CNN-LSTM dan hasil evaluasi model seperti nilai *accuracy* (*acc*), *precision* (*prec*), *recall* (*rec*), dan *F1-score* (*F1*). Berikut ini merupakan rangkuman mengenai penelitian terdahulu yang digunakan sebagai acuan dalam penelitian ini yang disajikan pada Tabel 1.

Tabel 1. Penelitian Terkait

No	Penelitian	Data	Metode	Hasil			
				<i>Acc</i>	<i>Prec</i>	<i>Rec</i>	<i>F1</i>
1.	<i>Automatic Detection of Citrus Fruit and Leaves Diseases Using Deep Neural Network Model</i> (Khattak dkk., 2021).	<i>Citrus Fruit and Leaves Images</i> Jumlah: 2293 <i>Black spot</i> : 632 <i>Greening</i> : 454 <i>Canker</i> : 446 <i>Melanose</i> : 140 <i>Scab</i> : 321 <i>Healthy</i> : 300 Sumber: <i>Benchmark repository (Citrus and PlantVillage Dataset)</i>	Metode Klasifikasi: CNN	94%	-	-	-

2.	<i>Implementation of CNN for Plant Leaf Disease Classification</i> (Paryadi dkk., 2020).	Face94 Dataset Jumlah: 500 <i>Javanese</i> <i>Ginseng</i> : 100 Urang-Aring: 100 Moringa: 100 <i>Spinach Duri</i> : 100 Dadap Serep: 100 Sumber: <i>Dr. Libor Spacek</i>	Metode Klasifikasi: CNN	86%	-	-	-
3.	<i>Development of a chickpea disease detection and classification model using deep learning</i> (Belay dkk., 2022)	Chickpea disease and healthy images Jumlah: 1399 <i>Ascochyta Blight</i> : 494 <i>Fusarium wilt</i> : 468 <i>Healthy</i> : 437 Sumber: Observations at the Gondar Agricultural Research Center Bureau	Metode Klasifikasi: CNN-LSTM	92%	92%	92%	92%

Uraian tentang penelitian terdahulu dalam Tabel 1 sebagai berikut :

a. Penelitian Pertama (Khattak dkk., 2021)

Penelitian ini dilakukan oleh Khattak dkk., pada tahun 2021 dengan menerapkan model CNN untuk klasifikasi penyakit pada buah dan daun jeruk. Data yang digunakan pada penelitian ini adalah data gambar buah dan daun jeruk yang diperoleh dari *benchmark repository (Citrus and PlantVillage Dataset)*. Data tersebut memiliki jumlah total 2293 data gambar buah dan daun jeruk dengan

rincian 632 gambar terserang penyakit *black spot*, 454 gambar terserang penyakit *greening*, 446 gambar terserang penyakit *canker*, 140 gambar terserang penyakit *melanose*, 321 gambar terserang penyakit *scab*, dan 300 gambar tidak terserang penyakit apapun (*healthy*).

Langkah awal, terlebih dahulu dilakukan *preprocessing* pada data dengan melakukan normalisasi data dan penskalaan piksel menggunakan *API*. Sebelum membangun model, kumpulan data gambar tersebut dibagi menjadi 80% data *training* dan 20% data *testing*. Selanjutnya dibangun model CNN dan diperoleh nilai *accuracy* sebesar 94%.

b. Penelitian Kedua (Paryadi dkk., 2020)

Penelitian ini dilakukan oleh Paryadi dkk., pada tahun 2020 dengan menerapkan model CNN untuk klasifikasi penyakit pada 4 jenis daun yang berbeda. Data yang digunakan pada penelitian ini adalah data gambar daun Javanese Ginseng, Urang-Aring, Moringa, Spinach Duri, dan Dadap Serep yang diperoleh langsung dari Dr. Libor Spacek. Data tersebut memiliki jumlah total 500 data gambar.

Langkah awal, terlebih dahulu dilakukan *preprocessing* pada data dengan melakukan konversi gambar *grayscale* menjadi data geometris diterapkan untuk mengoptimalkan kontras dan intensitas gambar. Kemudian, proses ambang batas membuat gambar biner dari gambar berskala abu-abu untuk menerjemahkan nilai gambar ke ambang batas terdekatnya, sehingga memiliki salah satu dari dua kemungkinan nilai untuk setiap piksel. Sebelum membangun model, kumpulan data gambar tersebut dibagi menjadi 80% data *training* dan 20% data *testing*. Selanjutnya dibangun model CNN dan diperoleh nilai *accuracy* sebesar 86%.

c. Penelitian Ketiga (Belay dkk., 2022)

Penelitian ini dilakukan oleh Belay dkk., pada tahun 2022 dengan menerapkan model CNN-LSTM untuk klasifikasi penyakit pada tanaman buncis. Data yang digunakan pada penelitian ini adalah data gambar tanaman buncis yang diperoleh melalui observasi langsung ke Biro Pusat Penelitian Pertanian Gondar. Data

tersebut memiliki jumlah total 1399 data gambar tanaman buncis dengan rincian 494 gambar terserang penyakit *ascochyta blight*, 468 gambar terserang penyakit *fusarium wilt*, dan 437 gambar tidak terserang penyakit apapun (*healthy*).

Langkah awal, terlebih dahulu dilakukan *preprocessing* pada data dengan melakukan perubahan ukuran gambar, normalisasi data, dan *noise filtering*. Sebelum membangun model, kumpulan data gambar tersebut dibagi menjadi 80% data *training* dan 20% data *testing*. Selanjutnya dibangun model CNN-LSTM dan diperoleh nilai *accuracy* sebesar 92%, *precision* sebesar 92%, *recall* sebesar 92%, dan *F1-score* sebesar 92%.

2.2 Klasifikasi Gambar

Klasifikasi gambar merupakan tugas untuk mengklasifikasikan gambar ke dalam kelas tertentu berdasarkan fitur-fitur yang terdapat pada gambar tersebut. Hal ini melibatkan ekstraksi informasi dari gambar dan kemudian mengaitkan informasi yang diekstraksi ke satu atau lebih label kelas. Dalam pengklasifikasian gambar, terdapat dua metode yang sering digunakan yaitu *multi-label classification* dan *multi-class classification* (Anhar dan Putra, 2023). Untuk menyelesaikan masalah klasifikasi *multi-class*, algoritma akan memprediksi kelas suatu sampel berdasarkan fitur-fitur yang terdapat pada sampel tersebut, kemudian mengklasifikasikannya ke dalam satu kelas yang telah ditentukan sebelumnya. Sedangkan untuk menyelesaikan masalah klasifikasi *multi-label*, algoritma akan memprediksi kelas-kelas suatu sampel berdasarkan fitur-fitur yang terdapat pada sampel tersebut, kemudian mengklasifikasikannya ke dalam lebih dari satu kelas yang telah ditentukan sebelumnya. Pada *machine learning*, klasifikasi gambar dapat didekati sebagai tugas *supervised learning*. Biasanya klasifikasi gambar dicapai dengan menggunakan jenis jaringan saraf khusus yang disebut jaringan saraf konvolusional (CNN).

2.3 Citra Digital

Citra digital merupakan sekumpulan piksel di mana setiap pikselnya memiliki nilai intensitas yang merepresentasikan warna atau kecerahan pada posisi tertentu dalam citra. Pada sebuah citra terkandung informasi yang diperlukan oleh manusia selain teks, suara, dan video (Ratna, 2020). Informasi tersebut diinterpretasikan berbeda oleh manusia satu dengan yang lain. Pada citra digital terdapat metode yang dapat digunakan untuk perhitungan matematis ataupun geometris. Objek citra tersebut memiliki perbedaan seperti warna, tekstur, ataupun bentuk yang dapat menjadi ciri antara objek satu dengan yang lain (Jumadi dkk., 2021)

Secara matematis, citra adalah fungsi kontinu $f(x, y)$ dari intensitas cahaya pada bidang dua dimensi dengan x dan y adalah koordinat spasial (bidang) dan amplitudo f pada pasangan koordinat (x, y) yang didefinisikan sebagai intensitas atau derajat keabuan citra pada titik tersebut. Jika variabel x, y dan f semuanya bernilai diskrit dan berhingga, maka citra tersebut merupakan citra digital (Gonzalez dan Woods, 2018). Citra digital mencakup barisan bilangan riil maupun kompleks yang diwakili oleh bit-bit tertentu. Bit adalah unit terkecil dari data digital yang berisi angka biner (0 dan 1). Sedangkan itu, kumpulan dari 8 bit data adalah sebuah unit yang disebut *byte* dengan rentang nilai dari 0 hingga 225.

2.4 *Preprocessing Data*

Teknik *preprocessing* data digunakan untuk menghilangkan *noise* yang tidak diinginkan dan memperbaiki gambar dengan teknik penskalaan, transformasi, memperbesar atau memperkecil gambar, dan mengonversi gambar menjadi skala abu-abu. Banyak teknik *preprocessing* data yang bisa digunakan, diantaranya sebagai berikut :

1. *Grayscale Image*

Grayscale image adalah gambar-gambar di mana informasi warna hilang dan diubah menjadi format skala abu-abu. *Grayscale image* menjadi bagian penting dari pemrosesan gambar karena RGB atau informasi warna memiliki properti 3 dimensi yang membuat pemrosesan gambar begitu besar dan berat. *Grayscale image* cenderung memberikan representasi yang lebih halus dan lebih sederhana dari RGB karena hanya fokus pada kecerahan atau intensitas pixel tanpa memperhitungkan warna (Abdiansyah dkk., 2021)..

2. Augmentasi Data

Efektivitas augmentasi data berasal dari transformasi sederhana seperti *horizontal flipping*, augmentasi ruang warna, *random cropping*, dan *rotation* (Connor dan Taghi, 2019)

- *Horizontal flipping* merupakan salah satu augmentasi yang paling mudah diterapkan dan lebih umum daripada *vertical flipping*. Teknik ini mengambil baris dan kolom dari matriks dan membaliknya secara horizontal.
- Augmentasi ruang warna adalah strategi yang praktis dan sederhana seperti mengubah saluran warna tunggal R, G, atau B. Sebuah gambar dapat dengan cepat diubah menjadi representasinya dalam satu saluran warna dengan menambahkan dua matriks nol dari saluran warna lainnya. Selain itu, nilai RGB dapat dimanipulasi dengan operasi matriks sederhana untuk menambah atau mengurangi kecerahan gambar.
- *Random cropping* dapat digunakan sebagai langkah pemrosesan untuk data gambar yang terdiri dari dimensi tinggi dan lebar dengan memotong *patch* pusat setiap gambar. Selain itu, *random cropping* juga dapat digunakan untuk memberikan efek yang sangat mirip dengan gambar aslinya.
- *Rotation* merupakan augmentasi yang dilakukan dengan memutar gambar ke kanan atau ke kiri pada sumbu antara 1° dan 359° .

2.5 *Machine Learning*

Machine Learning merupakan serangkaian teknik yang dapat membantu dalam mengotomatisasi proses pembuatan model analisis data yang sangat besar dengan cara mempresentasikan data-data tersebut dengan algoritma pembelajaran (Jeniesch dkk., 2021). *Machine learning* memungkinkan komputer atau suatu program dapat menemukan pengetahuan tanpa diprogram secara eksplisit. Situs web, program, aplikasi dan perangkat modern yang ada saat ini berisi berbagai macam program *machine learning*. Model tersebut digunakan untuk mengklasifikasikan atau memprediksi data baru yang memungkinkan dalam membuat atau mendukung pengambilan keputusan.

Menurut Makovskaja (2018), *machine learning* memiliki empat metode pembelajaran, antara lain :

1. *Supervised Learning* atau pembelajaran dengan pengawasan merupakan metode dalam *machine learning* yang menggunakan kumpulan data berlabel. Data tersebut berfungsi melatih algoritma dalam mengklasifikasikan data atau memprediksi hasil secara akurat. Dengan menggunakan *input* dan *output* yang sudah berlabel, model mampu mengukur keakuratannya dan terus belajar dari waktu ke waktu.
2. *Unsupervised Learning* atau pembelajaran tanpa pengawasan merupakan metode dalam *machine learning* dengan cara model diajarkan untuk mengidentifikasi pola dalam kumpulan data tanpa adanya label atau panduan sebelumnya. Dalam konteks pekerjaan seorang *data analyst*, teknik ini seperti mencoba memahami pola di dalam data tanpa pengetahuan sebelumnya tentang hasil yang diharapkan. *Unsupervised learning* menyediakan kerangka kerja dapat menerapkan *clustering* dan teknik lainnya untuk mengekstrak informasi berharga dari data. *Clustering* merupakan salah satu pendekatan dalam *unsupervised learning* yang digunakan sebagai alat untuk membantu mengidentifikasi masalah lebih cepat sekaligus memahami pola dan tren yang dapat membantu merancang solusi terbaik bagi perusahaan.

3. *Semi-Supervised Learning* atau pembelajaran semi-diawasi merupakan teknik yang menggabungkan antara *supervised* dan *unsupervised learning* menggunakan data berlabel dan tidak berlabel untuk melatih model klasifikasi dan regresi. Metode pembelajaran semi-diawasi ini sangat relevan dalam situasi sulit dan mahal dalam memperoleh data berlabel dalam jumlah yang banyak, namun data tidak berlabel dalam jumlah besar relatif mudah diperoleh.
4. *Reinforcement Learning* merupakan metode *machine learning* yang memungkinkan untuk belajar berperilaku di lingkungan dengan melakukan tindakan dan memperhatikan hasil tindakan. *Reinforcement learning* memecahkan jenis masalah tertentu, yaitu pengambilan keputusan berurutan, dan tujuannya adalah jangka panjang, seperti bermain *game*, robotika, dll.

2.6 *Deep Learning*

Deep Learning merupakan salah satu pengembangan dari *machine learning* yang memanfaatkan jaringan saraf tiruan untuk implementasi permasalahan kumpulan data yang besar dan dikembangkan pada kasus pengenalan citra dalam perkembangan teknologi *Graphic Processing Unit (GPU)* (Alwanda dkk., 2020). *Deep Learning* memungkinkan mesin untuk mempelajari representasi data secara hierarkis dan otomatis dari fitur yang sederhana hingga kompleks. Oleh karena itu, *deep learning* dapat digunakan untuk mengatasi masalah kompleks seperti pengenalan suara dan gambar, deteksi objek, dan pemrosesan bahasa alami.

Pada *deep learning*, data diproses melalui serangkaian lapisan yang terdiri dari node-node atau *artificial neuron*. Setiap lapisan akan mempelajari representasi data yang semakin kompleks. Lapisan pertama akan mempelajari representasi fitur-fitur sederhana seperti *edge* dan garis. Sedangkan lapisan terakhir akan mempelajari representasi fitur-fitur yang kompleks dan abstrak. *Deep learning* membutuhkan banyak data dan waktu untuk melatih jaringan saraf agar akurasi tinggi (Alwanda dkk., 2020). Namun, hasil dari *deep learning* sangat

powerful dan dapat digunakan untuk memecahkan masalah yang sangat kompleks dalam berbagai bidang, seperti *computer vision*, *speech recognition*, *natural language processing*, dan lain-lain. Ada berbagai jenis jaringan saraf *deep learning* yang dikembangkan untuk menangani masalah atau *dataset* tertentu, seperti CNN untuk aplikasi *computer vision* dan klasifikasi gambar, serta RNN untuk pemrosesan bahasa alami dan pengenalan ucapan.


2.7 *Splitting Data*

Splitting data merupakan proses yang digunakan untuk membagi kumpulan data menjadi tiga bagian yang terpisah yakni data pelatihan (*data training*), data pengujian (*data testing*), dan data validasi. *Splitting data* ini sangat penting untuk menghindari terjadinya *overfitting*, yaitu kondisi dimana model sangat baik dalam mengenali pola data *training* tetapi tidak dapat melakukan prediksi dengan baik pada data baru. Data *training* digunakan untuk melatih model, data *testing* untuk memeriksa akurasi model akhir, dan data validasi untuk memahami kinerja model dengan baik (Joseph, 2022).

2.8 *Recurrent Neural Network (RNN)*

Recurrent Neural Network merupakan jenis jaringan saraf yang menerapkan data *sequential* pada arsitekturnya (Farhah dkk., 2021). Model RNN mempunyai kelebihan dalam memproses data yang masuk secara berulang-ulang membentuk sebuah *time series*. Pada RNN setiap *output* dari lapisan tersembunyi akan mengalami *looping* ke dirinya sendiri, begitu seterusnya sehingga memperoleh hasil *output* yang paling akurat. Namun demikian, RNN memiliki kelemahan yaitu adanya permasalahan *vanishing gradient* atau hilangnya nilai gradien saat pembaruan bobot (Cahyani, 2023). Permasalahan *vanishing gradient* ini mengakibatkan RNN gagal dalam menangkap *long term dependencies* sehingga

mengurangi akurasi dari suatu prediksi pada RNN (Chung, 2018). Arsitektur RNN diilustrasikan pada Gambar 1 sebagai berikut :



Gambar 1. Arsitektur RNN (Adiputra dkk., 2023)

2.9 Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) termasuk dalam jenis deep learning karena kedalaman jaringannya. Model CNN merupakan operasi konvolusi yang menggabungkan beberapa lapisan pemrosesan, menggunakan beberapa elemen yang beroperasi secara paralel dan terinspirasi oleh sistem saraf biologis (Romario dkk., 2020). Pada CNN setiap neuron dipresentasikan dalam bentuk 2 dimensi, sehingga metode ini cocok untuk pemrosesan dengan *input* berupa citra. Menurut Susanto dkk. (2022) pada CNN terdapat tiga lapisan utama diantaranya sebagai berikut:

2.9.1 Lapisan Konvolusi

Pada lapisan ini dilakukan operasi konvolusi antara matriks citra *input* dengan matriks-matriks filter. Filter-filter ini akan digeser ke seluruh permukaan citra sehingga akan menghasilkan *output* matriks *feature map*. Adapun rumus operasi konvolusi diformulasikan pada Persamaan (2.1) sebagai berikut :

$$FM[i]_{j,k} = \left(\sum_m \sum_n N_{[j-m,k-n]} F_{[m,n]} \right) + bF \quad (2.1)$$

dimana,

$FM[i]$: Matriks Feature Map ke- i

N : Matriks Citra *Input*

F : Matriks Filter Konvolusi

bF : Nilai bias pada filter

j, k : Posisi piksel pada matriks citra *input*

m, n : Posisi piksel pada matriks filter konvolusi

2.9.2 Fungsi Aktivasi

Fungsi aktivasi merupakan fungsi *non-linear* yang memungkinkan sebuah jaringan saraf tiruan untuk menyelesaikan permasalahan *non-trivial* (Alwanda dkk., 2020). Setiap fungsi aktivasi mengambil sebuah nilai dan melakukan operasi matematika. Fungsi aktivasi yang sering digunakan yaitu *Rectified Linear Unit* (ReLU), *sigmoid*, *Tangen Hiperbolik* (*TanH*), dan *softmax*.

1. *Rectified Linear Unit* (ReLU)

Fungsi aktivasi ReLU merupakan fungsi *non-linear* dimana pengaktifan *neuron* tidak dilakukan secara bersamaan, dan hanya ketika *output* dari transformasi linear bernilai nol (Firmansyah dkk., 2022). Fungsi ReLU dituliskan dalam Persamaan (2.2) sebagai berikut:

$$f(x) = \max(0, x) \quad (2.2)$$

dimana,

x : Nilai data *input*

$f(x)$: Hasil *output* fungsi ReLU berupa nilai dalam bentuk 0 dan 1

2. *Sigmoid*

Fungsi aktivasi *sigmoid* merupakan fungsi yang memetakan nilai *input* ke antara nilai 0 dan 1, sehingga nilai *input* berikutnya berada dalam kisaran yang tetap dan bobotnya lebih stabil. Fungsi *sigmoid* dituliskan dalam Persamaan (2.3) sebagai berikut:

$$f(x) = \frac{1}{1 + e^{-x}} \quad (2.3)$$

dimana,

e^{-x} : Nilai eksponensial negatif dari nilai data *input*

$f(x)$: Hasil *output* fungsi *sigmoid* berupa nilai dalam rentang 0 sampai 1

3. *Tangen Hiperbolik (TanH)*

Fungsi aktivasi tanh merupakan fungsi simetris yang berbentuk s (*sigmoid*), dimana *output* nya terletak pada rentang nilai -1 sampai 1 (Firmansyah dkk., 2022). Fungsi tanh dituliskan dalam Persamaan (2.4) sebagai berikut:

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.4)$$

dimana,

e^x : Nilai eksponensial positif dari nilai data *input*

e^{-x} : Nilai eksponensial negatif dari nilai data *input*

$f(x)$: Hasil *output* fungsi tanh berupa nilai dalam rentang -1 sampai 1

4. *Softmax*

Softmax merupakan fungsi aktivasi yang digunakan untuk mengklasifikasi objek yang memiliki jumlah kelas lebih dari dua. *Softmax* dapat menghitung peluang untuk setiap label kelas yang diklasifikasikan dengan cara mengambil vektor yang bernilai riil dari semua label kelas yang ada (Magdalena dkk., 2021). Fungsi *softmax* dituliskan dalam Persamaan (2.5)

sebagai berikut:

$$S(y)_i = \frac{e^{y_i}}{\sum_{i=1}^m e^{y_i}} \quad (2.5)$$

dimana,


$S(y)_i$: Nilai probabilitas prediksi *output layer*

y_i : Sinyal *output* pada *output layer*

m : Jumlah kelas pada *output layer*

2.9.3 Lapisan *Pooling*

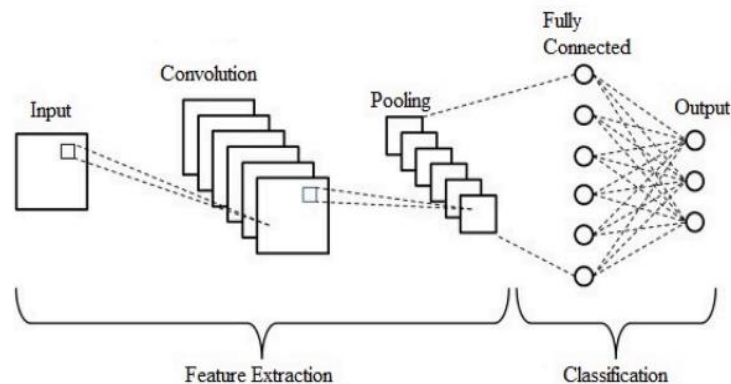
Lapisan *Pooling* digunakan untuk mengurangi ukuran dari *feature map* dengan melakukan penerapan kernel pada lapisan ini. Lapisan *pooling* juga dapat digunakan untuk mengambil nilai rata-rata *pooling* dan nilai maksimal *pooling* yang diperoleh dari bagian piksel pada sebuah citra. Lapisan *pooling* pada arsitektur model CNN yang dimasukkan antara lapisan konvolusi secara berturut-turut dapat secara progresif mengurangi ukuran volume *output* pada *feature map*, sehingga jumlah parameter dan perhitungan pada jaringan akan berkurang, serta dapat digunakan untuk mengendalikan *overfitting* (Susanto dkk., 2022). Proses ini akan menghasilkan *output* berupa matriks *feature map* yang berisi nilai-nilai maksimum yang terpilih. Contoh *max pooling* diilustrasikan pada Gambar 2 sebagai berikut :



Gambar 2. Contoh *Max Pooling* (Chen dkk., 2021)

2.9.4 Lapisan *Fully-Connected*

Lapisan *Fully-Connected* adalah sebuah lapisan yang menghubungkan semua neuron aktivasi dari lapisan sebelumnya pada semua neuron di lapisan selanjutnya sama seperti halnya dengan jaringan saraf biasa. Pada dasarnya lapisan ini biasanya digunakan pada *Multi Layer Perceptron* (MLP) yang mempunyai tujuan untuk melakukan transformasi pada dimensi data agar data dapat diklasifikasikan secara linier. Perbedaan antara lapisan *fully-connected* dan lapisan konvolusi adalah neuron pada lapisan konvolusi terhubung hanya ke daerah tertentu pada *input*, sementara lapisan *fully-connected* memiliki neuron yang secara keseluruhan terhubung. Namun, kedua lapisan tersebut masih mengoperasikan produk dot, sehingga fungsinya tidak begitu berbeda. Arsitektur CNN diilustrasikan pada Gambar 3 sebagai berikut :




Gambar 3. Arsitektur CNN (Islam dkk., 2020)

2.10 *Long Short-Term Memory* (LSTM)

Long Short-Term Memory merupakan salah satu jenis arsitektur dari RNN dengan melakukan dilakukan modifikasi pada RNN, yaitu menambahkan *memory cell* yang dapat menyimpan informasi untuk jangka waktu yang lama (Manaswi, 2018). Model LSTM dijadikan sebagai solusi untuk mengatasi terjadinya

vanishing gradient pada RNN saat memproses data *sequential* yang panjang. Arsitektur LSTM terdiri dari lapisan *input*, lapisan *output*, dan lapisan tersembunyi yang disajikan pada Gambar 4 sebagai berikut :



Gambar 4. Arsitektur LSTM (Wiranda dan Sadikin, 2019)

Lapisan tersembunyi terdiri dari sel memori, setiap sel memori memiliki tiga gerbang yaitu gerbang *input*, gerbang *forget*, gerbang *output*.

a. Gerbang *Forget* (f_t)

Gerbang *forget* adalah tempat untuk menentukan informasi mana yang akan dihapus menggunakan fungsi aktivasi *sigmoid*. Jika *output* nya 1 maka semua data disimpan dan jika *output* nya 0 maka semua data dibuang (Khaira, dkk., 2020). Adapun rumus gerbang *forget* dituliskan pada Persamaan (2.6) sebagai berikut:

$$f_t = \sigma(W_f[h_{t-1}, X_t] + b_f) \quad (2.6)$$

dimana,

W_f : bobot dari gerbang *forget*

h_{t-1}, X_t : keadaan sebelumnya atau keadaan pada waktu t-1

b_f : bias dari gerbang *forget*

σ : fungsi aktivasi *sigmoid*

b. Gerbang *Input* (i_t)

Pada gerbang *input* terdapat dua fungsi aktivasi yang akan dilaksanakan yaitu fungsi *sigmoid* memutuskan nilai mana yang akan melewati 0 hingga 1 dan

fungsi *tanh* memberi bobot pada nilai-nilai yang diteruskan untuk menentukan tingkat kepentingannya mulai dari -1 hingga 1. Adapun rumus gerbang *input* dituliskan pada Persamaan (2.7) dan (2.8) sebagai berikut:

$$i_t = \sigma(W_i[h_{t-1}, X_t] + b_i) \quad (2.7)$$

$$C_t = \tanh(W_C[h_{t-1}, X_t] + b_C) \quad (2.8)$$

dimana,

W_i : bobot dari gerbang *input*

W_C : bobot pada *cell state*

h_{t-1}, X_t : keadaan sebelumnya atau keadaan pada waktu t-1

b_i : bias dari gerbang *input*

b_C : bias pada *cell state*

σ : fungsi aktivasi *sigmoid*

c. Gerbang *Output* (o_t)

Menurut Nurashila dkk., (2023) mengatakan bahwa gerbang *output* memiliki dua alur yang diimplementasikan, yaitu memutuskan bagian mana dari sel memori yang diberikan fungsi aktivasi *sigmoid* dan bagian mana yang akan diberikan fungsi aktivasi *tanh*. Fungsi *sigmoid* memutuskan nilai mana yang akan melewati 0 hingga 1. dan fungsi *tanh* memberi bobot pada nilai-nilai yang dilewatkan menentukan tingkat kepentingannya mulai dari -1 hingga 1 dan dikalikan dengan *output sigmoid*. Adapun rumus gerbang *output* dituliskan pada Persamaan (2.9) dan (2.10) sebagai berikut:

$$o_t = \sigma(W_o[h_{t-1}, X_t] + b_o) \quad (2.9)$$

$$h_t = o_t \times \tanh(C_t) \quad (2.10)$$

dimana,

W_o : bobot dari gerbang *output*

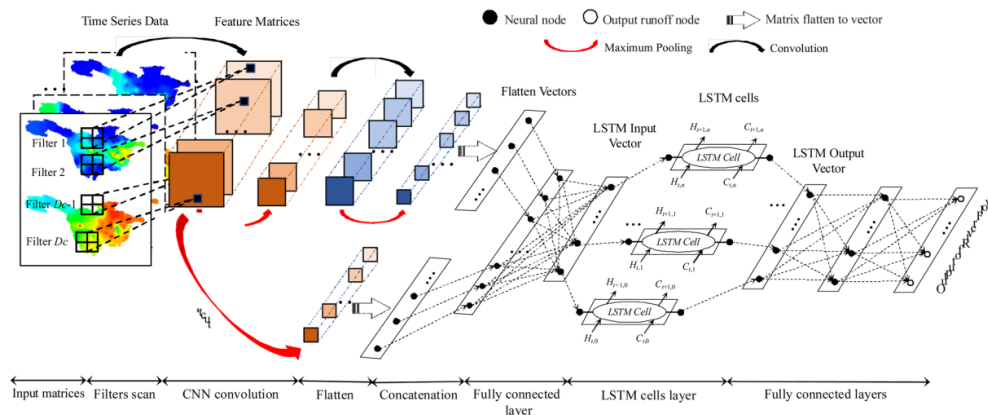
h_{t-1}, X_t : keadaan sebelumnya atau keadaan pada waktu t-1

b_o : bias dari gerbang *output*

σ : fungsi aktivasi *sigmoid*

2.11 Hybrid CNN-LSTM

Pada penelitian ini dikembangkan gabungan model CNN dan LSTM, di mana CNN dapat memecahkan masalah karakteristik spasial dan LSTM dapat memahami konteks temporal pada data gambar (Al-Dulaimi dan Kurnaz, 2024). Menurut Alhussein dkk. (2020), model *hybrid* CNN-LSTM dibangun secara paralel, dan fitur diekstraksi oleh CNN dan LSTM dan digabungkan dengan meratakan komponen statistik. Arsitektur model *hybrid* CNN-LSTM disajikan pada Gambar 5 sebagai berikut :



Gambar 5. Arsitektur CNN-LSTM (Li dkk., 2022)

Berdasarkan Gambar 5, arsitektur CNN-LSTM terdiri dari beberapa komponen utama yaitu matriks input, konvolusi CNN, *shortcut layer*, *flatten*, *concatenation*, lapisan *fully-connected*, dan sel LSTM. Data gambar sebagai matriks input terhubung oleh filter untuk menghasilkan matriks fitur. Matriks fitur tersebut nantinya akan disatukan menggunakan metode *max-pooling* untuk mengekstrak informasi yang berguna. Kemudian, lapisan *shortcut* digunakan sebagai saluran untuk mengekstrak informasi input sebagai proses *pooling* dan dapat meningkatkan keragaman informasi yang diekstraksi. Matriks fitur diratakan menjadi dua vektor

yang digabungkan dan ditransfer melalui lapisan yang terhubung sepenuhnya ke sel LSTM sebagai vektor input. Sehingga *output* sel LSTM dikirimkan oleh lapisan *fully-connected* ke vektor output (Li dkk., 2022).

2.12 Evaluasi Kinerja Model

Evaluasi kinerja model digunakan untuk mengetahui sejauh mana hasil kinerja model yang telah dilatih (Maulana, 2023). Terdapat berbagai parameter yang dapat digunakan untuk menguji model salah satunya yaitu *confusion matrix* yang digunakan untuk mengetahui sebaran data *testing* dengan nilai *true* (benar) dan data *testing* dengan nilai *false* (salah). *Confusion matrix* terdiri dari dua jenis, yaitu *confusion matrix binary classification* dan *confusion matrix multiclass classification*.

Confusion matrix binary classification merupakan tabel berdimensi 2x2 yang terdiri dari empat kombinasi berbeda dari nilai prediksi dan nilai aktual. Ada empat istilah yang merupakan representasi hasil proses klasifikasi biner pada *confusion matrix* yaitu *True Positif* (TP), *True Negatif* (TN), *False Positif* (FP), dan *False Negatif* (FN). Namun, metrik-metrik tersebut tidak sepenuhnya berlaku pada klasifikasi *multiclass*. *Confusion matrix multiclass classification* merupakan tabel berdimensi $N \times N$, dimana N adalah banyaknya jenis kelas yang berbeda (Markoulidakis dkk., 2021).

Terdapat beberapa metrik yang dapat digunakan pada klasifikasi *multiclass*, diantaranya yaitu *accuracy*, *precision*, *recall*, dan *F1-score*. Berikut ini merupakan ilustrasi *confusion matrix multiclass classification* yang disajikan pada Gambar 6.

		Predicted Class			
		C ₁	C ₂	...	C _N
Actual Class	C ₁	C _{1,1}	FP	...	C _{1,N}
	C ₂	FN	TP	...	FN

	C _N	C _{N,1}	FP	...	C _{N,N}

Gambar 6. *Confusion Matrix Multiclass* (Markoulidakis dkk., 2021)

Berikut ini diuraikan definisi dari metrik kinerja untuk klasifikasi *multiclass* yang meliputi:

a. *Accuracy*

Accuracy adalah proporsi dari total jumlah prediksi yang benar dari hasil klasifikasi (Markoulidakis dkk., 2021). Adapun rumus matematis dari *accuracy* adalah sebagai berikut:

$$Accuracy = \frac{\sum_{i=1}^N TP(C_i)}{\sum_{i=1}^N \sum_{j=1}^N C_{i,j}} \times 100\% \quad (2.11)$$

b. *Precision*

Precision atau nilai prediksi positif adalah proporsi dari prediksi positif yang tepat dari semua data yang diprediksi positif dari hasil klasifikasi (Mughal dkk., 2022). Adapun rumus matematis dari *precision* adalah sebagai berikut:

$$Precision = \frac{TP}{TP + FP} \times 100\% \quad (2.12)$$

c. *Recall*

Recall atau sensitivitas adalah proporsi dari semua data aktual positif yang diprediksi dengan benar sebagai positif dari hasil klasifikasi (Mughal dkk., 2022). Adapun rumus matematis dari *recall* adalah sebagai berikut:

$$Recall = \frac{TP}{TP + FN} \times 100\% \quad (2.13)$$

d. *F1-score*

F1-score adalah rata-rata *harmonic* antara *presicion* dan *recall* untuk model klasifikasi tertentu (Mughal dkk., 2022). Adapun rumus matematis dari *F1-score* adalah sebagai berikut:

$$F1 - score = \frac{2 \times recall \times precision}{(recall + precision)} \times 100\% \quad (2.14)$$

III. METODOLOGI PENELITIAN

3.1 Tempat dan Waktu Penelitian

Tempat dan Waktu Penelitian diuraikan sebagai berikut:

a. Tempat Penelitian

Penelitian ini dilaksanakan secara studi literature di Jurusan Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Lampung. Lokasi bertempat di Jalan Prof. Dr. Soemantri Brojonegoro No.1, Gedung Meneng, Bandar Lampung.

b. Waktu Penelitian

Penelitian ini dilakukan pada semester ganjil tahun akademik 2023/2024, tepatnya pada bulan November 2023. Penelitian ini dibagi menjadi tiga tahap, tahap pertama dilakukan studi literatur baik dalam bentuk jurnal maupun buku yang sesuai dengan topik penelitian sebagai referensi penyusunan proposal. Setelah itu, dilakukan pengumpulan data yang akan digunakan sebagai objek penelitian dan penyusunan draf proposal penelitian. Tahap kedua yaitu tahap pengerjaan program mulai dari *exploratory data analysis*, *preprocessing data*, augmentasi dan normalisasi data, pemodelan klasifikasi *hybrid CNN-LSTM*, dan evaluasi kinerja dari model yang telah dibuat. Tahap terakhir yaitu penyusunan hasil dan kesimpulan atas penelitian yang telah dilakukan untuk disampaikan pada saat seminar hasil dan selanjutnya akan dilaksanakan sidang komprehensif.




3.2 Data dan Alat Penelitian

Data dan Alat yang digunakan pada penelitian ini sebagai berikut:

a. Data

Data yang digunakan dalam penelitian ini adalah data gambar yang berasal dari situs *Mendeley Data* yakni <https://data.mendeley.com/datasets/bycbh73438/1> yang diterbitkan pada tanggal 02 Desember 2021. Data gambar tersebut merupakan kumpulan data kerusakan pada tanaman kedelai yang dideteksi melalui daun. Kumpulan data ini terdiri dari 3 kelas yaitu *Caterpillar*, *Diabrotica Speciosa*, dan *Healthy*. Total jumlah kumpulan data ini yaitu 6410 gambar dengan rincian: kelas *Caterpillar* terdiri dari 3309 gambar, *Diabrotica Speciosa* terdiri dari 2205 gambar, dan *Healthy* terdiri dari 896 gambar. Agar mempermudah pengolahan data, kumpulan data tersebut diekstraksi dengan melakukan pemecahan data melalui program *python* menjadi data model dan data *testing* dengan rasio 90% untuk data model dan 10% untuk data *testing*. Setelah melakukan pemecahan data, didapatkan data model sebanyak 5768 gambar dengan masing-masing kelas yaitu *Caterpillar* terdiri dari 2978 gambar, *Diabrotica Speciosa* terdiri dari 1984 gambar, dan *Healthy* terdiri dari 806 gambar. Sedangkan data *testing* sebanyak 642 gambar dengan masing-masing kelas *Caterpillar* terdiri dari 331 gambar, *Diabrotica Speciosa* terdiri dari 221 gambar, dan *Healthy* terdiri dari 90 gambar. Data validasi diperoleh saat menjalankan pelatihan model dengan mengambil rasio 20% dari data model. Sampel dari kumpulan data yang akan digunakan disajikan dalam Tabel 2 sebagai berikut:

Tabel 2. Sampel Data Penelitian

Jenis Data	<i>Caterpillar</i>	<i>Diabrotica Speciosa</i>	<i>Healthy</i>
Data Model			



b. Alat

Adapun alat yang digunakan dalam penelitian ini adalah sebagai berikut:

1. Perangkat Keras (*Hardware*)

Perangkat keras yang digunakan dalam penelitian ini adalah sebagai berikut:

- Processor AMD Dual Core A4-9125, up to 2.6 GHz
- Installed RAM 4,00 GB

2. Perangkat Lunak (*Software*)

Perangkat lunak yang digunakan dalam penelitian ini adalah sbagai berikut:

- Sistem operasi *Windows 10*
- *Jupyter Notebook 6.4.5*

Adapun *packages* yang digunakan dalam penelitian ini adalah sebagai berikut:

- *Numpy* versi 1.26.0
- *Pandas* versi 1.3.4
- *Matplotlib* versi 3.4.3
- *Path* versi 16.0.0
- *opencv-python* versi 4.8.1.78
- *Scikit-learn* versi 1.1.1
- *Tensorflow* versi 2.14.0

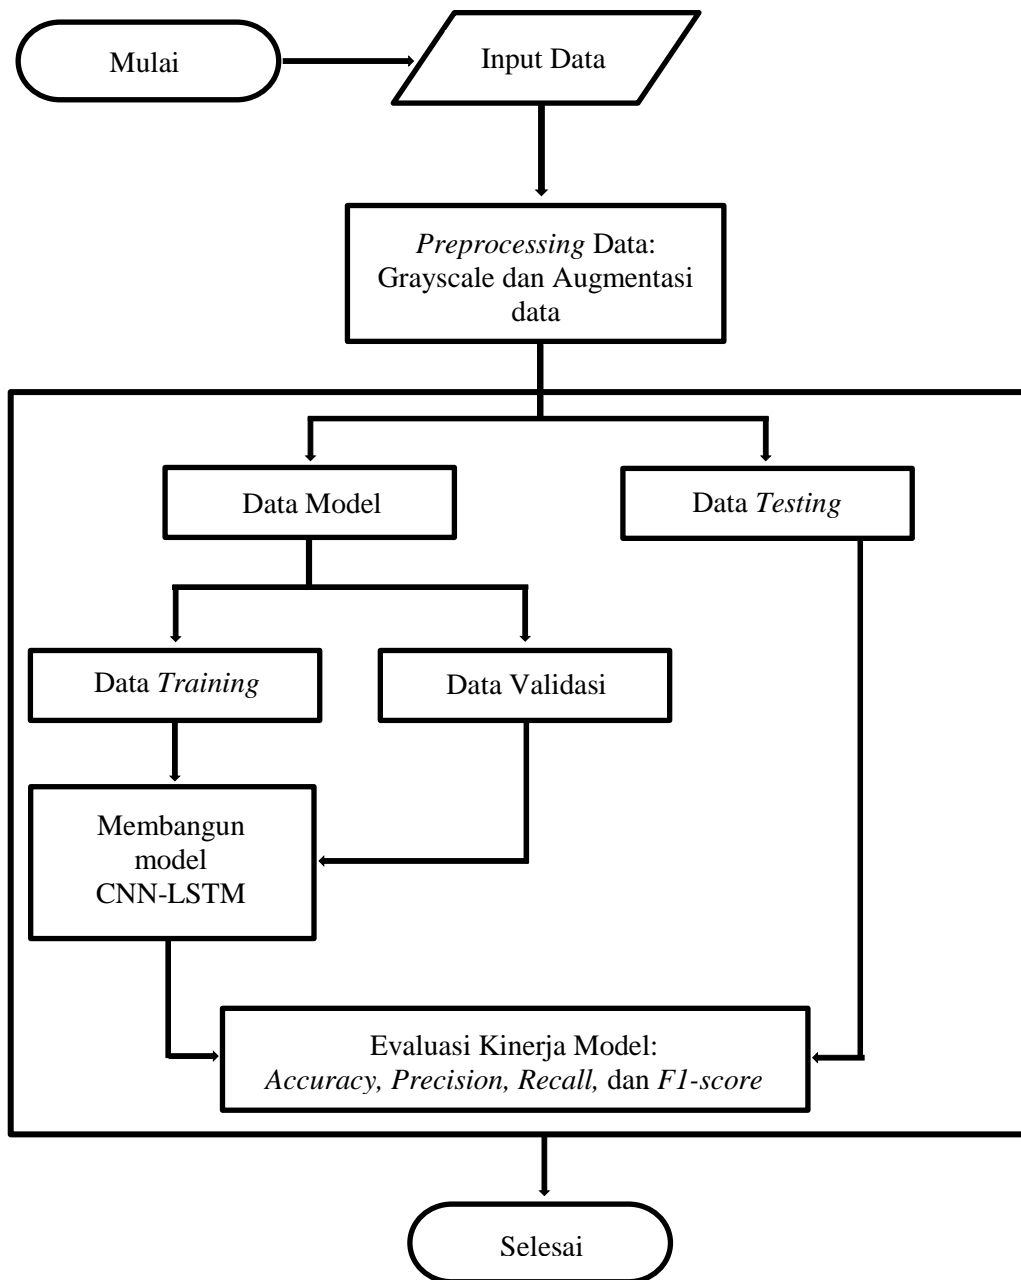
3.3 Metode Penelitian

Penelitian ini menggunakan model *hybrid* CNN-LSTM untuk melakukan klasifikasi kerusakan daun kedelai akibat serangan larva *Lepidoptera* dan *Diabrotica* sebagaimana didokumentasikan oleh Mignoni (2021). Perangkat lunak yang digunakan dalam penelitian ini adalah *Jupyter Notebook* dan *Kaggle Notebook*.

Langkah-langkah yang dilakukan pada penelitian ini sebagai berikut :

1. Melakukan studi literatur tentang metode klasifikasi CNN, LSTM, dan *hybrid* CNN-LSTM.
2. Mengumpulkan data kerusakan daun kedelai akibat serangan larva *Lepidoptera* dan *Diabrotica* yang akan digunakan untuk klasifikasi menggunakan metode *hybrid* CNN-LSTM.
3. Melakukan *input* data kerusakan daun kedelai akibat serangan larva *Lepidoptera* dan *Diabrotica* yang telah dibagi menjadi data model dan data *testing* pada situs *Kaggle Notebook*. Setelah itu, kelas-kelas yang ada pada data tersebut otomatis terlabelkan menggunakan skala nominal yang selalu dimulai dari angka 0 dimana kelas 0 menunjukkan kelas *caterpillar*, kelas 1 menunjukkan kelas *diabrotica speciosa*, dan kelas 2 menunjukkan kelas *healthy*.
4. Melakukan *preprocessing* dan augmentasi pada data model seperti *rescale* untuk memperbesar dan memperkecil gambar, *vertical flip* untuk membalik gambar secara vertikal, menambahkan fungsi *noise*, *blur*, dan *grayscale* ke dalam gambar..
5. Membangun model *hybrid* CNN-LSTM dari data *training* dan data *validation* dengan menentukan parameter terbaik.
6. Melakukan evaluasi kinerja model terbaik dengan melihat nilai akurasi, *precision*, *recall*, dan *F1-score*.

Berikut ini merupakan *flowchart* yang disajikan pada Gambar 7:



Gambar 7. *Flowchart*

V. PENUTUP

5.1 Kesimpulan

Berdasarkan hasil dan pembahasan yang telah dipaparkan pada bab sebelumnya, maka dapat diambil kesimpulan sebagai berikut :

1. Penerapan model *hybrid* CNN-LSTM pada identifikasi kerusakan daun pada tanaman kedelai terbukti cukup efektif dan memuaskan. Model ini mampu memproses data gambar kerusakan daun kedelai dengan cukup baik.
2. Model klasifikasi yang dibangun mencapai keakuratan yang cukup signifikan dengan nilai akurasi sebesar 93%. Hasil ini menunjukkan bahwa model *hybrid* CNN-LSTM mampu mengolah dan mengklasifikasi kerusakan daun kedelai secara efektif.

5.2 Saran

Saran untuk penelitian berikutnya yaitu lebih teliti dalam memilih dan mengidentifikasi data yang akan digunakan dalam penelitian. Hal tersebut bertujuan untuk mempermudah proses *preprocessing* dan membangun model agar *output* yang dihasilkan lebih akurat. Pemilihan parameter yang sesuai juga menjadi hal yang penting untuk mendapatkan model dan hasil yang lebih baik. Selain itu, penelitian berikutnya dapat menggunakan kumpulan data yang berbeda untuk menguji keberhasilan model klasifikasi pada berbagai jenis kasus kerusakan tanaman.

DAFTAR PUSTAKA

- Abdiansyah, F., Santoso, K. A., dan Kamsyakawuni, A. 2021. Perbandingan Image RGB dan Grayscale pada Pengkodean Image dengan Algoritma 3D Playfair. *PRISMA, Prosiding Seminar Nasional Matematika* 4, 524-533.
- Adiputra, I. M. E. D., Prasad, K. K. S., Fauzi, I., Winata, A., dan Widhiada, I. W. 2023. Evaluasi Model Machine Learning Klasifikasi Gerak Tangan Untuk Sistem Kontrol Prototipe Protesis Tangan. *Jurnal Ilmiah Teknologi Elektro*. **22**(1) : 141-146.
- Al-Dulaimi, O. A. H. H., dan Kurnaz, S. 2024. A Hybrid CNN-LSTM Approach for Precision Deepfake Image Detection Based on Transfer Learning. *Electronics* 2024. **13** : 1-22.
- Alhussein, M., Aurangzeb, K., dan Haider, S. I. 2020. Hybrid CNN-LSTM Model for Short-Term Individual Household Load Forecasting. *IEEE Journal*. **8** : 180544-180557.
- Alwanda, M. R., Ramadhan, R. P. K., dan Alamsyah, D. 2020. Implementasi Metode Convolutional Neural Network Menggunakan Arsitektur LeNet-5 untuk Pengenalan *Doodle*. *Jurnal Algoritme*. **1**(1) : 45-56.
- Anhar, A., dan Putra, R. A. 2023. Perancangan dan Implementasi Self-Checkout System pada Toko Ritel menggunakan Convolutional Neural Network (CNN). *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*. **11**(2) : 466-478.
- Asnunun, S., dan Kartika, K. P. 2020. Sistem Pakar Diagnosa Hama Dan Penyakit Pada Tanaman Kedelai Berbasis Website Menggunakan Metode Certain Factor. *Jurnal Informatika Polinema*. **7**(1) : 61-72.
- Badan Pusat Statistik (BPS). 2021. Analisis Produktivitas Jagung dan Kedelai di Indonesia. <https://www.bps.go.id/>. Diakses pada tanggal 24 Desember 2023.
- Bansal, P., Ranvijay., dan Yadav, M. 2023. Automatic Detection of Plant Leaf Diseases Using Deep Learning. *International Journal of Computing and Digital Systems*. **13**(1) : 901-910.

- Belay, A. J., Salau, A. O., Ashagrie, M., dan Haile, M. B. 2022. Development of a chickpea disease detection and classification model using deep learning. *Informatics in Medicine Unlocked*. **31** : 100970.
- Cahyani, J., Mujahidin, S., dan Fiqar, T. P. 2023. Implementasi Metodel Long Short Term Memory (LSTM) untuk Memprediksi Harga Bahan Pokok Nasional. *Jurnal Sistem dan Teknologi Informasi*. **11**(2) : 346-357.
- Chung, H., dan Shin, K. S. 2018. Genetic algorithm-optimized long short-term memory network for stock market prediction. *Sustainability*. **10**(10) : 3765.
- Connor, S., dan Taghi, M. K. 2019. A survey on image data augmentation for deep learning. *Journal of Big Data*. **6**(60) : 1-48.
- Farhah, A., Prasasti, A. L., dan Paryasto, M. W. 2021. Implementasi Recurrent Neural Network dalam Memprediksi Kepadatan Restoran Berbasis LSTM. *Jurnal Media Informatika Budidarma*. **5**(2) : 524-531.
- Firmansyah, I., dan Hayadi, B. H. 2022. Komparasi Fungsi Aktivasi Relu dan Tanh pada Multilayer Perceptron. *Jurnal Informatika dan Komputer*. **6**(2) : 200-206.
- Gonzalez, R. C., dan Woods, R. E. 2018. *Digital Image Preprocessing*. 4th Edition. New York.
- Hamami, F., dan Dahlan, I. A. 2022. Klasifikasi Cuaca Provinsi Jakarta Menggunakan Algoritma Random Forest dengan Teknik Oversampling. *Jurnal TEKNOINFO*. **16**(1) : 87-92.
- Islam, M. Z., Islam, M. M., dan Asraf, A. 2020. A combined deep CNN-LSTM network for the detection of novel coronavirus (COVID-19) using X-ray images. *Informatics in Medicine Unlocked*. **20** : 100412.
- Janiesch, C., Zschech, P., dan Heinrich, K. 2021. Machine Learning and Deep Learning. *Springer Journal*. **31** : 685-695.
- Jumadi, J., Yupianti., dan Sartika, D. 2021. Pengolahan Citra Digital untuk Identifikasi Objek Menggunakan Metode Hierarchical Agglomerative Clustering. *Jurnal Sains dan Teknologi*. **10**(2) : 148-156.
- Joseph, V. R. 2022. Optimal ratio for data splitting. *The ASA Data Sci Journal*. **15** : 531-538.
- Khaira, U., Alfalah, M., Gulo, P. C. S., dan Purnomo, R. 2020. Prediksi Kemunculan Titik Panas Di Lahan Gambut Provinsi Riau Menggunakan Long Short Term Memory. *Jurnal Pengembangan IT*. **5**(3) : 77-82.

- Khattak, A., Asghar, M. U., Batool, U., Asghar, M. Z., Ullah, H., Al-Rakhami, M., dan Gumaei, A. 2021. Automatic Detection of Citrus Fruit and Leaves Diseases Using Deep Neural Network Model. *IEEE Access*. **9** : 112942–112954.
- Kurniawan, W. A., Putra, N. P., Pradana, R. P., Ulum, M., dan Almais, A. T. W. 2019. Sistem Pendukung Keputusan Pencarian Universitas di Malang Menggunakan Weight Product dengan Pembobotan Weighted Sum Model. *Jurnal Ilmiah Informatika*. **4**(2) : 103-110.
- Li, X., Xu, W., Ren, M., Jiang, Y., dan Fu, G. 2022. Hybrid CNN-LSTM Models for River Flow Prediction. *IWA Publishing Journal*. **22**(5) : 4902-4920.
- Magdalena, R., Saidah, S., Pratiwi, N. K. C., dan Putra, A. T. 2021. Klasifikasi Tutupan Lahan Melalui Citra Satelit SPOT-6 dengan Metode Convolutional Neural Network (CNN). *Jurnal Edukasi dan Penelitian Informatika*. **7**(3) : 335-339.
- Makovskaja, N. 2018. Classification of High Vegetation in an Urban environment: A Performance Comparison of Machine Learning Methods in a LiDAR dataset (Thesis). Aalborg University, Copenhagen.
- Manaswi, N. K. 2018. *Deep Learning with Applications Using Python*. Apress.
- Maulana, S. A., Batubara, S. H., Amelia, T. A., dan Pasaribu, Y. P. P. 2023. Penerapan Metode CNN (Convolutional Neural Network) dalam Mengklasifikasi Jenis Ubur-Ubur. *Jurnal Penelitian Rumpun Ilmu Teknik (JUPRIT)*. **2**(4) : 122-130.
- Markoulidakis, I., Rallis, I., Georgoulas, I., Kopsiaftis, G., Doulamis, A., dan Doulamis, N. 2021. Multiclass Confusion Matrix Reduction Method and Its Application on Net Promoter Score Classification Problem. *Technologies*. **9**(4) : 1-22.
- Mignoni, M. E. 2021. Images of Soybean Leaves. Mendeley Data, V1, doi: 10.17632/bycbh73438.1.
- Mughal, N. E., Khan, M. J., Khalil, K., Javed, K., Sajid, H., Naseer, N., Ghafoor, U., dan Hong, K. 2022. EEG-fNIRS-based hybrid image construction and classification using CNN-LSTM. *Frontiers in Neurorobotics*. **16** : 1-17.
- Nurashila, S. S., Hamami, F., & Kusumasari, T. F. 2023. Perbandingan Kinerja Algoritma Recurrent Neural Network (Rnn) Dan Long Short-Term Memory (Lstm): Studi Kasus Prediksi Kemacetan Lalu Lintas Jaringan Pt Xyz. *JIPi (Jurnal Ilmiah Penelitian Dan Pembelajaran Informatika)*. **8**(3) : 864–877.

- Paryadi, C., Diqi, M., dan Mulyani, S. H. 2020. Implementation of CNN for Plant Leaf Classification. *International Journal of Informatics and Computation*. **2**(2) : 1-9.
- Patel, S., dan Rahul, S. N. 2020. Insect Pests of Soybean and Their Management. *Popular Kheti*. **8**(4) : 58-61.
- Putra, R. P., Rahmadwati., dan Setyawati, O. 2018. Klasifikasi Penyakit Tanaman Kedelai Melalui Tekstur Daun dengan Metode *Gabor Filter*. *Jurnal EECCIS*. **12**(1) : 40–46.
- Ratna, S. 2020. Pengolahan Citra Digital dan Histogram dengan Phyton dan Text Editor Phycharm. *Jurnal Ilmiah "Tecnologia"*. **11**(3) : 181-186.
- Romario, M. H., Ihsanto, E., dan Kadarina, T. M. 2020. Sistem Hitung dan Klasifikasi Objek dengan Metode Convolutional Neural Network. *Jurnal Teknologi Elektro*. **11**(2) : 108-114.
- Susanto, A., Kusumawati, Y., Niagara, E. D., dan Sari, C. A. 2022. Convolutional Neural Network Dalam Sistem Deteksi Helm Pada Pengendara Motor. *Seminar Nasional Teknologi Dan Multidisiplin Ilmu (SEMNASTEKMU)*. **2**(1) : 91–99.
- Vasumathi, M. T., dan Kamarasan, M. 2021. An Effective Pomegranate Fruit Classification Based On CNN-LSTM Deep Learning Models. *Indian Journal of Science and Technology*. **14**(16) : 1310-1319.
- Wiranda, L., dan Sadikin, M. 2019. Penerapan Long Short Term Memory pada Data Time Series untuk Memprediksi Penjualan Produk PT. Metiska Farma. *Jurnal Nasional Pendidikan Teknik Informatika (JANAPATI)*. **8**(3) : 184–196.