

**EVALUASI KINERJA METODE KECERDASAN BUATAN DALAM
DETEKSI PENYAKIT PADA DAUN TEBU**

(Skripsi)

Oleh

NURUL FADILAH

2117051098



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG
2025**

**EVALUASI KINERJA METODE KECERDASAN BUATAN DALAM
DETEKSI PENYAKIT PADA DAUN TEBU**

**Oleh
NURUL FADILAH**

Skripsi

**Sebagai Salah Satu Syarat untuk Mencapai Gelar
SARJANA KOMPUTER**

**Pada Jurusan Ilmu Komputer
Fakultas Matematika dan Ilmu Pengetahuan Alam**



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG
2025**

ABSTRAK

EVALUASI KINERJA METODE KECERDASAN BUATAN DALAM DETEKSI PENYAKIT PADA DAUN TEBU

OLEH

NURUL FADILAH

Produktivitas tanaman tebu (*Saccharum officinarum* Linn.) sangat dipengaruhi oleh berbagai penyakit yang disebabkan oleh bakteri, virus, dan hama. Deteksi penyakit pada daun tebu sangat penting dilakukan untuk mencegah penurunan hasil panen dan menjaga kualitas produksi gula. Dengan membandingkan *Convolutional Neural Networks* (CNN) dan *Support Vector Machine* (SVM), penelitian ini bertujuan untuk menilai keefektifan metode kecerdasan buatan dalam mendeteksi penyakit tebu. Dataset yang digunakan berasal dari Mendeley Data dan mencakup 11 kategori, seperti tebu sehat dan berbagai jenis penyakit. Arsitektur CNN yang digunakan dalam penelitian ini adalah *ResNet50* dan *InceptionV3*, sedangkan SVM digunakan sebagai metode klasifikasi tradisional. Prosedur penelitian meliputi analisis data, pra-pemrosesan, ekstraksi fitur, serta pelatihan dan evaluasi model dengan menggunakan berbagai skenario data. Menggunakan metrik *accuracy*, *presisi*, *recall*, dan *F1-score* digunakan dalam proses evaluasi. Di antara model CNN, *InceptionV3*, dengan rasio pembagian data 80%:10%:10%, mencapai akurasi tertinggi sebesar 0.9636, secara signifikan mengungguli arsitektur lainnya. Dalam SVM, *kernel linear* menghasilkan kinerja terbaik, dengan rasio pembagian data 80%:10%:10%, mencapai akurasi 0.9080.

Kata Kunci: Kecerdasan Buatan, CNN, SVM, Penyakit pada Daun Tebu

ABSTRACT

PERFORMANCE EVALUATION OF ARTIFICIAL INTELLIGENCE METHODS IN SUGARCANE LEAF DISEASE DETECTION

By

NURUL FADILAH

The productivity of sugarcane (*Saccharum officinarum* Linn.) is greatly affected by various diseases caused by bacteria, viruses and pests. Disease detection in sugarcane leaves is very important to prevent a decrease in yield and maintain the quality of sugar production. By comparing Convolutional Neural Networks (CNN) and Support Vector Machine (SVM), this study aims to assess the effectiveness of Artificial Intelligence methods in detecting sugarcane diseases. The dataset used comes from Mendeley Data and includes 11 categories, such as healthy sugarcane and different types of diseases. The CNN architectures used in this study were ResNet50 and InceptionV3, while SVM was used as the traditional classification method. The research procedure includes data analysis, pre-processing, feature extraction, and model training and evaluation using various data scenarios. Accuracy, precision, recall, and F1-score metrics were used in the evaluation process. Among the CNN models, InceptionV3, with a data sharing ratio of 80%:10%:10%, achieved the highest accuracy of 0.9636, significantly outperforming the other architectures. In SVM, the linear kernel produced the best performance, with a data split ratio of 80%:10%:10%, achieving an accuracy of 0.9080.

Keywords: Artificial Intelligence, CNN, SVM, Sugarcane Leaf Disease

Judul Skripsi : Evaluasi Kinerja Metode Kecerdasan Buatan
Dalam Deteksi Penyakit Pada Daun Tebu

Nama Mahasiswa : **Nurul Fadilah**

Nomor Pokok Mahasiswa : 2117051098

Jurusan : Ilmu Komputer

Fakultas : Matematika dan Ilmu Pengetahuan Alam



1. Komisi Pembimbing

Prof. Admi Syarif, Ph.D.
NIP. 19670103 199203 1 003

Dr. Mahfut, S.Si., M.Sc.
NIP. 19810909 201404 1 001


2. Ketua Jurusan Ilmu Komputer FMIPA

Dwi Sakethi, S.Si., M.Kom
NIP. 19680611 199802 1 001


MENGESAHKAN

1. Tim Penguji


Ketua : Prof Admi Syarif, Ph.D



Sekretaris : Dr. Mahfut, S.Si., M.Sc.



Penguji Utama : Dr. rer. nat. Akmal Junaidi, M.Sc.



2. Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam



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

NIP. 197110012005011 002

Tanggal Lulus Ujian Skripsi : **02 Juni 2025**

PERNYATAAN

Saya yang bertanda tangan dibawa ini, menyatakan skripsi saya yang berjudul **“Evaluasi Kinerja Metode Kecerdasan Buatan Dalam Deteksi Penyakit Pada Daun Tebu”** merupakan karya saya sendiri dan bukan karya orang lain. Semua tulisan yang tertuang di skripsi ini telah mengikuti kaidah penulisan karya tulis ilmiah Universitas Lampung. Apabila kemudian hari skripsi ini terbukti hasil jiplakan atau dibuat orang lain, maka saya bersedia menerima sanksi berupa pencabutan gelar yang saya terima.

Bandar Lampung, 18 Juni 2025

Penulis,



Nurul Fadilah

2117051098

RIWAYAT HIDUP



Penulis lahir di Purwodadi Dalam pada tanggal 25 Mei 2004 sebagai anak pertama dari pasangan Bapak Hadiman dan Ibu Karini. Penulis masuk Pendidikan formal di SD Negeri 1 Sidomukti pada tahun 2015, kemudian melanjutkan di Mts Assalam dan selesai pada tahun 2018. Penulis kemudian melanjutkan pendidikan menengah atas di SMA Assalam dan lulus pada tahun 2021.

Pada tahun 2021 penulis terdaftar sebagai mahasiswa Jurusan Ilmu Komputer Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung melalui jalur PMPAP. Selama menjadi mahasiswa penulis aktif mengikuti berbagai kegiatan di antaranya sebagai berikut.

1. Menjadi Sekretaris Biro Kemuslimahan Unit Kegiatan Mahasiswa Rohani Islam (Rois) Fakultas Matematika dan Ilmu Pengetahuan, Alam Universitas Lampung tahun periode 2022.
2. Menjadi Anggota Keilmuan Himpunan Mahasiswa Ilmu Komputer (HIMAKOM) Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung tahun periode 2022.
3. Menajadi Sekretaris Koordinator Acara Panitia Pemira Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung tahun periode 2022.
4. Menjadi Sekretaris Bidang Kajian dan Keumataan Unit Kegiatan Mahasiswa Rohani Islam (Rois) Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung tahun periode 2023.
5. Mengikuti Kerja Praktik di PT PLN (Persero) Unit Induk Distribusi (UID) Lampung di bidang Aset Properti dan Umum.

6. Menjadi Ketua Komisi Hubungan Luar dan Kelembagaan Dewan Perwakilan Mahasiswa (DPM) Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung tahun periode 2024.
7. Melaksanakan KKN di Desa Kedung Ringin, Kecamatan Pasir Sakti, Kabupaten Lampung timur pada tahun 2024.

MOTTO

فَإِنَّ مَعَ الْعُسْرِ يُسْرًا إِنَّ مَعَ الْعُسْرِ يُسْرًا

“Maka sesungguhnya bersama kesulitan ada kemudahan. Sesungguhnya bersama kesulitan ada kemudahan.”

(QS. Al-Insyirah [94]: 5-6)

وَادْخُلِي جَنَّتِي

“Dan masuklah ke dalam surga-Ku.”

(QS. Al-Fajr [89]: 30)

“Jika kamu tidak sanggup menahan lelahnya belajar, maka kamu harus sanggup menahan perihnya kebodohan”

(Imam Syafi'i)

“Impian harus diusahakan bukan dinantikan”

(Zhong Chenle)

“To get something as beautiful as the sky, we also need to do the paths of the sky”

(Anonymous)

PERSEMBAHAN

Alhamdulillah 'ala kulli hal

Dengan rasa syukur kepada Allah *Subhanahu Wa Ta'ala* atas Ridho, Rahmat, dan Karunia-Nya sehingga saya dapat menyelesaikan skripsi ini. Shalawat teriring Salam selalu tercurahkan kepada Nabi Muhammad *Shallallahu Alaihi Wasallam*.

Skripsi ini ku persembahkan dan kuhaturkan kepada:

Keluargaku Tercinta

Perempuan yang bekerja sebagai petani di desa bernama Alam Raya, di tinggal suaminya wafat semenjak tahun 2014 lalu. Perempuan itu ibuku, Kartini namanya. Keningnya menempel di sajadah, nama penulis dilangitkan-nya. Segala hal yang penulis tempuh kini, tidak terlepas dari peranya. Hanya untaian do'a yang penulis berikan, *jazakillah khairan katsir* — semoga Allah SWT membalas segala amal kebajikannya dengan pahala berlipat ganda. *Aamiin*.

Kepada lelaki kuat yang bercita-cita menyekolahkan ku ke luar negeri. Almarhum Hadiman, Ayahku, meski tak jadi keluar negeri, seluruh kebaikanmu saat hidup memberikan kontribusi nyata hingga skripsi ini selesai. Serta Rasyidah adiku tercinta, yang menjadi alasan untuk semangat dalam menyelesaikan skripsi ini.

Terima kasih juga untuk semua pihak yang terlibat dalam pembuatan skripsi ini. Semoga Allah senantiasa membalas setiap kebaikan kalian.

Almamater Tercinta, Universitas Lampung dan Jurusan Ilmu Komputer

Tempat bernaung mengemban ilmu untuk bekal kehidupan.

SANWACANA

Puji syukur penulis ucapkan kehadiran Allah Subhanahu Wata'ala, karena atas rahmat dan hidayah-Nya sehingga penulis dapat menyelesaikan skripsi ini. Shalawat serta salam semoga senantiasa tercurahkan kepada junjungan Nabi Muhammad Shallallahu Alaihi Wasallam yang penulis harapkan syafaatnya di hari akhir kelak. Skripsi dengan judul **“Evaluasi Kinerja Metode Kecerdasan Buatan Dalam Deteksi Penyakit Pada Daun Tebu”** adalah salah satu syarat untuk memperoleh gelar sarjana komputer pada Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.

Dalam penyusunan skripsi ini, penulis mendapat bantuan, dukungan dan motivasi dari berbagai pihak. Oleh karena itu, penulis mengucapkan terima kasih yang sebesar besarnya kepada:

1. Kedua Orang Tuaku tercinta, Alm Bapak Hadiman selaku cinta pertama dan Ibu Kartini tempat pulang ternyaman di dunia, yang selalu mendoakan, mendukung, memotivasi dan memberikan kasih sayang pada penulis.
2. Bapak Dr. Eng. Heri Satria, S.Si., M.Si., selaku Dekan FMIPA Universitas Lampung.
3. Bapak Dwi Sakethi, S.Si., M.Kom., selaku Ketua Jurusan Ilmu Komputer FMIPA Universitas Lampung.
4. Ibu Yunda Heningtyas, M.Kom., selaku Sekretaris Jurusan Ilmu Komputer FMIPA Universitas Lampung.
5. Bapak Prof. Admi Syarif, Ph.D., selaku Dosen Pembimbing Utama yang selalu membimbing, memberikan arahan, motivasi, masukan serta saran, dalam penyelesaian skripsi ini.
6. Bapak Dr. Mahfut, S.Si., M.Sc., selaku Dosen Pembimbing kedua yang selalu membimbing, memberikan arahan, masukan dan saran dalam penyelesaian skripsi ini.

7. Bapak Dr. rer. nat. Akmal Junaidi, M.Sc., selaku Dosen Pembahas yang telah memberikan saran dan masukan yang bermanfaat dalam perbaikan skripsi ini.
8. Ibu Anie Rose Irawati, ST., M.Cs., Selaku Dosen Pembimbing Akademik yang telah memberikan motivasi dan saran kepada penulis.
9. Bapak Tristiyanto, S.Kom., M.I.S., Ph.D. Selaku Kepala Prodi S1 Ilmu Komputer FMIPA Universitas Lampung.
10. Ibu Ade Nora, terimakasih telah membantu segala urusan administrasi yang penulis butuhkan.
11. Bapak dan Ibu semua Staf Jurusan Ilmu Komputer FMIPA Universitas Lampung, yang telah memberikan banyak ilmu dan wawasan baru kepada penulis dan telah membantu segala urusan administrasi yang penulis butuhkan.
12. Adikku tersayang Dek Rasyida, Bik Aas, Bik Asih, Bik Ambar, Mas Taufik terimakasih atas motivasi dan dukungan nya yang selalu kalian berikan di perjalanan yang indah ini.
13. Teman seperjuangan semasa kuliah “YTТА” yaitu, Fitri, Dinda, Revi, Shela, Osmy, Ina, Fira, Retno, terima kasih, karena selalu ada, terima kasih telah mendukung, membantu, mendo’akan dan mewarnai hari penulis selama masa kuliah.
14. Teman Seperjuangan “Until S.Kom” yaitu Dinda, Amel, Sarah, terima kasih, karena selalu ada, terima kasih telah berjuang bersama, terima kasih telah mendukung, membantu, mendo’akan dan mewarnai hari penulis selama masa kuliah terkhusus dalam pengerjaan skripsi ini.
15. Kakak-kakak dan Ibu Bapak seperbimbingan, Ibu Apri, Pak Riko, Pak Nisar, Pak Nurjoko, Bu Lilis, Pak Putra, Kak Safiira, Kak joy, Kak Arman, Kak Nabila, Kak Yoan yang telah memberikan bantuan, masukan, dukungan, dan menemani selama proses pengerjaan skripsi semoga Allah selalu melindungi.
16. Keilmuan HIMAKOM 2022, Pimpinan Rois FMIPA 2022-2023, KKN Desa Kedung Ringin, DPM FMIPA Unila 2024, serta Departemen KIIK

LD-Se Unila 2024 yang telah memberikan pengalaman dan pelajaran hidup serta dukungan dan doa kepada penulis.

17. Teman-teman Ilmu Komputer angkatan 2021 yang menjadi teman satu angkatan selama menjalani masa studi.
18. Semua pihak, keluarga besar, sahabat dan teman teman yang tidak dapat penulis sebutkan satu persatu.
19. Terakhir, untuk perempuan sederhana dengan impian besar—Nurul Fadilah anak pertama yang sedikit keras kepala. Terima kasih telah bertahan hingga saat ini, terima kasih atas perjuangan, kesabaran, dan ketekunan yang telah kamu lalui. Berbahagialah, selalu tumbuh dan berkembang dimanapun kamu berada.

Akhir kata, penulis menyadari bahwa skripsi ini masih jauh dari kata sempurna, tetapi penulis berharap skripsi ini dapat berguna dan bermanfaat bagi semua. Semoga dengan bantuan dan dukungan yang diberikan mendapat balasan pahala di sisi Allah SWT. *Aamiin*.

Bandar Lampung, 18 Juni 2025
Penulis,

Nurul Fadilah
2117051098

DAFTAR ISI

	Halaman
MENGESAHKAN	i
DAFTAR ISI	xvi
DAFTAR TABEL	xvii
DAFTAR GAMBAR	xvii
1. PENDAHULUAN.....	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	5
1.3 Batasan Masalah	5
1.4 Tujuan Penelitian	5
1.5 Manfaat Penelitian	6
II. TINJAUAN PUSTAKA.....	7
2.1 Penelitian Terdahulu	7
2.2 Tebu	9
2.2.1 Jamur.....	10
2.2.2 Virus.....	14
2.2.3 Bakteri.....	16
2.3 Artificial Intelligence	17
2.4 Machine Learning	18
2.5 Neural Networks	20
2.6 Deep Learning	20
2.7 Convolutional Neural Network	21
2.7.1 Layer CNN.....	22
2.7.2 Rectified Linear Unit (ReLU)	24
2.7.3 Flatten.....	25
2.7.4 Dropout Layer.....	25
2.7.5 SoftMax	26
2.8 Model Arsitektur ResNet50.....	26
2.9 Model Arsitektur InceptionV3	28
2.10 Support Vector Machine (SVM).....	28
2.11 Image Augmentation	30
2.12 Confusion Matrix	31
2.13 Multiclass Confusion Matrix.....	33
2.14 Ekstraksi Fitur	41
2.14.1 Ekstraksi fitur warna.....	41

2.14.2 Ekstraksi fitur tekstur menggunakan <i>Gray-Level Co-occurrence Matrix</i> (GLCM)	42
2.14.3 Ekstraksi fitur tekstur menggunakan LBP (<i>Local Binary Pattern</i>)	44
2.14.4 Ekstraksi fitur bentuk.....	44
III. METODE PENELITIAN.....	46
3.1 Tempat dan Waktu.....	46
3.2 Alat dan Bahan.....	46
3.2.1 <i>Hardware</i>	46
3.2.2 <i>Software</i>	46
3.2.3 <i>Library</i>	47
3.3.2 <i>Pre-Processing</i>	55
3.3.3 <i>Convolutional Neural Network (CNN)</i>	59
3.3.4 <i>Support Vector Machine (SVM)</i>	60
IV. HASIL DAN PEMBAHASAN.....	62
4.1 Akuisisi Data.....	62
4.2 <i>Pre-processing</i>	63
4.3. Pemodelan SVM	67
4.3.1 Ekstraksi Fitur.....	67
4.3.2 Evaluasi Performa <i>Kernel SVM</i>	84
4.4 Pemodelan CNN	88
4.4.1 Hasil Performa Arsitektur <i>ResNet50</i>	92
4.4.2 Hasil Performa Arsitektur <i>InceptionV3</i>	94
4.4.3 Hasil Perbandingan Performa Arsitektur	97
4.5 Perbandingan Algoritma	99
4.5. <i>Test Case</i>	105
V. PENUTUP.....	106
5.1 Simpulan	106
5.2 Saran	107
DAFTAR PUSTAKA	108

DAFTAR TABEL

	Halaman
Tabel 1. Penelitian Terdahulu	7
Tabel 2. Confusion Matrix	31
Tabel 3. Multiclass Confusion Matrix	33
Tabel 4. kelas pada Daun Tebu	50
Tabel 5. Balancing Skenario 1	56
Tabel 6. Balancing Skenario 2	57
Tabel 7. Proporsi Pembagian Data	59
Tabel 8. Distribusi Kelas	62
Tabel 9. Balancing Data Binary Clasification	63
Tabel 10. Balancing Data Multiclass Classification	64
Tabel 11. Jumlah data berdasarkan skenario pembagian data	67
Tabel 12. Hasil Perbandingan Metode SVM pada Binary Classification	84
Tabel 13. Hasil Perbandingan Metode SVM pada Multiclass classification	85
Tabel 14. Metrik Evaluasi Binary Classification dan Multiclass Classification ..	88
Tabel 15. Hyperparameter CNN	89
Tabel 16. Evaluasi Performa Arsitektur ResNet50 (Binary Classification) pada berbagai Skema dan Epoch	92
Tabel 17. Evaluasi Performa Arsitektur ResNet50 (Multiclass Classification) pada berbagai Skema dan Epoch	93
Tabel 18. Evaluasi Performa Arsitektur InceptionV3 (Binary Classification) pada berbagai Skema dan Epoch	95
Tabel 19. Evaluasi Performa Arsitektur InceptionV3 (Multiclass Classification) pada berbagai Skema dan Epoch	96
Tabel 20. Metrik evaluasi Arsitektur ResNet50 dan InceptionV3	98
Tabel 21. Metrik evaluasi Arsitektur ResNet50 dan InceptionV3	99
Tabel 22. Metrik evaluasi SVM dan CNN (Binary Classification)	100
Tabel 23. Metrik evaluasi SVM dan CNN (Multiclass Classification)	101
Tabel 24. Perbandingan akurasi algoritma Kecerdasan Buatan	102
Tabel 25. Tabel Pengujian Akurasi Model	105

DAFTAR GAMBAR

Halaman

Gambar 1. Penyakit Karat (Rust) pada daun tebu (https://data.mendeley.com) ...	10
Gambar 2. Penyakit Busuk Merah (Redrot) pada daun tebu (https://data.mendeley.com)	11
Gambar 3. Penyakit pokah bung (pokkah boeng) pada daun tebu (https://data.mendeley.com)	12
Gambar 4. Penyakit luka api (Smutt) pada daun tebu (https://data.mendeley.com)	12
Gambar 5. Penyakit daun kering (dried leaves) (https://data.mendeley.com)	13
Gambar 6. Penyakit Busuk Stek (sett rot) pada daun tebu (https://data.mendeley.com)	14
Gambar 7. Penyakit Mosaik (mosaic) pada daun tebu (https://data.mendeley.com)	15
Gambar 8. Penyakit kuning (Yellow disease) pada daun tebu (https://data.mendeley.com)	15
Gambar 9. Penyakit klorosis belang (banded chlorosis) pada daun tebu (https://data.mendeley.com)	16
Gambar 10. Penyakit tunas rumput (grassy shoot) pada daun tebu (https://data.mendeley.com)	17
Gambar 11. Representasi dari neural network (www.sciencelearn.net)	20
Gambar 12. Convolutional Neural Network (www.analyticsvidhya.com)	22
Gambar 13. Convolutional Layer (https://www.rncm.ac.uk)	23
Gambar 14. tree type pooling operations (Alzubaidi et al., 2021)	24
Gambar 15. Perhitungan hasil grafik fungsi aktivasi ReLu	25
Gambar 16. Skip Connection (https://medium.com)	27
Gambar 17. Arsitektur ResNet50 (https://medium.com)	27
Gambar 18. Ilustrasi arsitektur InceptionV3 (Ali et al., 2021)	28
Gambar 19. Hyperplane positif (+1) dan negatif (-1) (https://data.medium.com)	30
Gambar 20. Contoh Arah untuk GLCM sudut 0°, 45°, 90°, dan 135°	42
Gambar 21. Alur Kerja Penelitian	49
Gambar 22. Daun Tebu Sehat (https://data.mendeley.com)	50
Gambar 23. Penyakit karat (rust) pada daun tebu (https://data.mendeley.com) ...	51
Gambar 24. Penyakit busuk merah (redrot) pada daun tebu (https://data.mendeley.com)	51

Gambar 25. Penyakit daun kering (dried leaves) pada daun tebu (https://data.mendeley.com).....	51
Gambar 26. Penyakit pokkah bung (pokkah boeng) pada daun tebu (https://data.mendeley.com).....	52
Gambar 27. Penyakit luka api (Smutt) pada daun tebu (https://data.mendeley.com)	52
Gambar 28. Penyakit busuk stek (sett rot) pada daun tebu (https://data.mendeley.com).....	52
Gambar 29. Penyakit Mosaik (Mosaic) pada daun tebu (https://data.mendeley.com).....	53
Gambar 30. Penyakit kuning (Yellow disease) pada daun tebu (https://data.mendeley.com).....	53
Gambar 31. Penyakit banded chlorosis pada daun tebu (https://data.mendeley.com).....	53
Gambar 32. Penyakit tunas rumput (grassy shoot) pada daun tebu (https://data.mendeley.com).....	54
Gambar 33. Analisis Penyebaran Data.....	55
Gambar 34. Blok Diagram Tahap Preprocessing Data	55
Gambar 35. Contoh Rotasi.....	65
Gambar 36. Contoh Horizontal flip	66
Gambar 37. Contoh Vertical flip.....	66
Gambar 38. Contoh hasil ekstraksi fitur warna.....	68
Gambar 39. Contoh Ekstraksi Tekstur GLCM Penyakit Yellow	69
Gambar 40. Contoh Ekstraksi Tekstur GLCM Penyakit Smut	70
Gambar 41. Contoh Ekstraksi Tekstur GLCM Penyakit Sett Rot	71
Gambar 42. Contoh Ekstraksi Tekstur GLCM Penyakit Rust	73
Gambar 43. Contoh Ekstraksi Tekstur GLCM Penyakit Red Rot	74
Gambar 44. Contoh Ekstraksi Tekstur GLCM Penyakit Pokkah Boeng	75
Gambar 45. Contoh Ekstraksi Tekstur GLCM Penyakit Dried Leaves	77
Gambar 46. Contoh Ekstraksi Tekstur GLCM Penyakit Banded Chlorosis	78
Gambar 47. Contoh Ekstraksi Tekstur GLCM Penyakit Mosaic.....	79
Gambar 48. Contoh Ekstraksi Tekstur GLCM Penyakit Grassy shoot.....	81
Gambar 49. contoh hasil ekstraksi fitur menggunakan LBP.....	82
Gambar 50. Contoh hasil ekstraksi fitur bentuk.....	83
Gambar 51. Confusion matrix kernel RBF skema 3 Binary Classification	84
Gambar 52. Confusion matrix kernel linear skema 3 Multiclass classification....	85
Gambar 53. Contoh Salah Klasifikasi antara Pokkah Boeng dan Smut	86
Gambar 54. Contoh Salah Klasifikasi antara Pokkah Boeng dan Smut	87
Gambar 55. Grafik metrik evaluasi model SVM.	88
Gambar 56. Arsitektur ResNet50 (https://medium.com)	90
Gambar 57. Layer arsitektur Resnet (He et al., 2016).	90
Gambar 58. Arsitektur InceptionV3 (li et al., 2019).	91
Gambar 59. Confusion matrix skema 2 Binary classification.....	92
Gambar 60. Confusion matrix skema 3 Multiclass classification.....	93
Gambar 61 Confusion matrix skema 3 Binary Classification.....	95

Gambar 62 Confusion matrix skema 3 Multiclass classification.....	96
Gambar 63 Metrik Perbandingan Metrik Evaluasi (Binary Classification)	
Arsitektur ResNet50 dan InceptionV3	98
Gambar 64 Metrik Perbandingan Metrik Evaluasi (Multiclass Classification)	
Arsitektur ResNet50 dan InceptionV3	99
Gambar 65 Metrik Perbandingan Metrik Evaluasi (Binary Classification) Metode CNN dan SVM.....	100
Gambar 66. Metrik Perbandingan Metrik Evaluasi (Multiclass Classification) Metode CNN dan SVM.....	101
Gambar 67 Grafik perbandingan akurasi algoritma metode kecerdasan Buatan	102

1. PENDAHULUAN

1.1 Latar Belakang

Indonesia adalah negara agraris yang sebagian besar penduduknya bekerja di sektor pertanian. Menurut Badan Pusat Statistik Indonesia (2023), sektor pertanian memiliki peran penting dalam perekonomian negara yang dibuktikan dengan kontribusinya terhadap Produk Domestik Bruto (PDB) sebesar 12,40% pada tahun 2022. Peran sektor pertanian tidak hanya sebatas pada kontribusi ekonomi, tetapi juga dalam memenuhi kebutuhan dasar masyarakat dan meningkatkan kesejahteraan, terutama bagi mereka yang masih berada di bawah garis kemiskinan (Ayun *et al.*, 2020). Salah satu upaya untuk meningkatkan kesejahteraan masyarakat adalah melalui pembangunan sektor perkebunan yang merupakan bagian dari pembangunan sektor pertanian dan pembangunan nasional. Sektor perkebunan memiliki peran strategis dalam meningkatkan perekonomian nasional, termasuk sebagai penyumbang PDB. Menurut Badan Pusat Statistik (2023), sektor perkebunan menyumbang 3,76% PDB pada tahun 2022 dan menduduki peringkat pertama. Salah satu komoditas utama dari sektor ini adalah tebu (*Saccharum officinarum* Linn.) dengan produk akhir berupa gula pasir.

Menjaga produktivitas tebu merupakan salah satu upaya untuk menjamin ketersediaan pasokan gula. Namun, produktivitas tebu mengalami penurunan di sebabkan oleh infeksi hama dan penyakit. Tantangan ini berdampak pada penurunan produksi gula, karena infeksi penyakit dapat menyebabkan kualitas gula menurun (Rahmad, 2021). Akibat buruknya kualitas dan kuantitas tebu yang akan terpengaruh, penyakit dan hama tanaman ini tidak hanya menimbulkan kerugian bagi petani, tetapi juga pabrik gula sebagai pemilik perkebunan tebu. Terdapat beberapa penyakit yang menyerang tanaman tebu di sebabkan oleh jamur, virus, dan bakteri.

Penyakit yang disebabkan oleh jamur diantaranya adalah penyakit karat (*rust*) dapat menyebabkan penurunan hasil tanaman tebu sehingga memberikan kerugian yang bervariasi dari angka 10 hingga 20%, dan pada kondisi yang parah, kerugiannya dapat mencapai hingga 50% (Selvakumar & Viswanathan, 2020). Penyakit Busuk Merah (*redrot*) yang disebabkan oleh jamur *Colletotrichum falcatum*. Penyakit ini merupakan salah satu penyakit tebu yang paling merusak dan sering disebut sebagai "kanker tebu". *Redrot* menyerang batang, rimpang (*stubble*), dan tulang daun tebu (Sharma *et al.*, 2017). Penyakit *Pokkah Boeng* adalah penyakit yang disebabkan oleh kompleks spesies jamur *Fusarium*. Penyakit ini menjadi masalah serius dalam budidaya tebu karena dapat menyebabkan kerugian ekonomi yang signifikan, dengan penurunan hasil dan kualitas tebu yang bervariasi antara 5% - 90% tergantung pada varietas yang terinfeksi (Tiwari 2020). Penyakit *Smutt* disebabkan oleh jamur *S. scitamineum*, yang dapat menginfeksi tanaman melalui teliospora yang ada di tanah atau melalui *setts* (batang tebu yang ditanam) yang terinfeksi. Infeksi *Smutt* dapat menyebabkan penurunan persentase germinasi dan hasil panen. Misalnya, hanya 14% dan 31% germinasi yang tercatat pada *setts* yang terinfeksi secara alami dan buatan, dibandingkan dengan 40% pada *setts* yang sehat (Rajput *et al.*, 2021). Penyakit *dried leaves* pada tebu sering kali disebabkan oleh infeksi jamur dan bakteri yang menyerang jaringan tanaman selama kondisi iklim yang kering atau lembab tinggi. Beberapa penelitian mencatat bahwa jamur seperti *Xanthomonas albilineans* dapat menyebabkan gejala *leaf scald*, yaitu daun mengering pada ujung atau muncul garis putih paralel dengan tulang daun (Viswanathan *et al.*, 2022). Penyakit *sett rot* pada tebu disebabkan oleh *Ceratocystis paradoxa*, yang merupakan salah satu penyebab utama kegagalan perkecambahan di ladang (Ravichandran *et al.*, 2023).

Penyakit yang disebabkan oleh virus diantaranya adalah penyakit kuning (*Yellow disease*) yang disebabkan oleh ScyLV (*Sugarcane Yellow leaf virus*). Penyakit ini dapat menyebabkan tanaman tebu memiliki hasil panen yang jauh lebih rendah, dan mengurangi pertumbuhan tanaman dan hasil panen individu antara 39 - 43% dan 30 - 34% (Bertasello *et al.*, 2023). *Banded chlorosis* pada daun tebu diketahui terkait dengan infeksi *Polerovirus*, virus ini menghambat respon pertahanan tanaman dengan mengeluarkan faktor virulensi seperti protein P0, yang menekan

mekanisme pertahanan RNA tanaman (Liang *et al.*, 2023). Dan penyakit mosaik (*mosaic*) juga berdampak signifikan terhadap produksi tebu (Srivastava *et al.*, 2020).

Penyakit yang di sebabkan oleh bakteri diantaranya adalah penyakit *Grassy Shoot* disebabkan oleh infeksi *fitoplasma* yang mengakibatkan gejala pertumbuhan *abnormal*. Tanaman yang terinfeksi seringkali tidak menghasilkan batang tebu yang dapat dipanen, bahkan pada tanaman yang terinfeksi ringan hanya menghasilkan batang yang lemah. Kerugian hasil dapat mencapai 5 - 20% pada tanaman utama, dan hingga 100% pada tanaman ratoon (Anuradha *et al.*, 2019).

Apabila infeksi penyakit tidak segera dideteksi dan ditangani dengan baik, maka akan berakibat pada menurunnya kualitas dan kuantitas tebu yang akan dipanen. Cara ini tidak dapat dilakukan pada perkebunan besar karena memerlukan bantuan tenaga ahli yang sudah berpengalaman di bidangnya, yang mana sangat mahal dan melelahkan. Selain itu, identifikasi secara manual tidak menjamin petani dapat mengidentifikasi dan mengklasifikasikan penyakit dengan tepat (Militante *et al.*, 2019). Untuk mendeteksi penyakit pada tebu secara efektif seperti, pendekatan berbasis kecerdasan buatan *artificial intelligence* sangat direkomendasikan karena memberikan solusi otomatis yang efisien, terutama di perkebunan berskala besar. Teknologi ini mengatasi keterbatasan identifikasi manual yang rentan terhadap *human error*, terutama pada skenario perkebunan dengan area lahan yang luas (Pudupet & Paranjothi 2024). Metode berbasis *Deep Learning*, seperti *Convolutional Neural Network* (CNN) telah digunakan secara khusus untuk deteksi dini penyakit tebu dengan akurasi yang tinggi. Model-model *artificial intelligence* ini mampu menganalisis gejala awal melalui gambar berkualitas tinggi yang diambil dari drone atau sensor dan memberikan hasil yang lebih akurat dibandingkan dengan pengamatan manual (Pratiti *et al.*, 2023).

Pembelajaran mesin telah berkembang secara signifikan, terutama dengan penggunaan *Convolutional Neural Network* (CNN). CNN terbukti efektif untuk identifikasi dan mendeteksi pola. Desain CNN selalu berubah untuk meningkatkan kinerja untuk tugas-tugas tertentu seperti kategorisasi. Arsitektur CNN yang umum termasuk VGG, ResNet, AlexNet, dan EfficientNet. CNN semakin banyak

digunakan bersama dengan metode klasifikasi tradisional seperti *Support Vector Machine* (SVM). Metode *Support Vector Machine* (SVM) banyak digunakan di berbagai bidang karena kekokohan dan efektivitasnya dalam menangani data dimensi tinggi. Hal ini sangat berguna dalam skenario di mana jumlah fitur melebihi jumlah sampel (Fathi *et al.*, 2022).

Seiring dengan perkembangan teknologi, *Convolutional Neural Network* (CNN) telah terbukti efektif dalam mengidentifikasi pola dan fitur visual pada gambar, sehingga menjadi salah satu metode terdepan dalam deteksi gambar, termasuk dalam mendeteksi penyakit tanaman. Selain itu, *Support Vector Machine* (SVM) merupakan metode *Machine learning* yang kuat dan efisien dalam mendeteksi data yang telah diekstraksi oleh CNN (Berhane *et al.*, 2023). Arsitektur *Convolutional Neural Network* (CNN) digunakan dalam pendeteksian tanaman padi, kedua arsitektur ini memberikan hasil akurasi yang tinggi, dimana *ResNet-50* mencapai 99,75% dan *InceptionV3* menganalisis angka dengan akurasi 97,59% (Shah *et al.*, 2023). *Support Vector Machine* (SVM) mencapai akurasi yang mengesankan sebesar 95% dalam deteksi penyakit tanaman Anggur. Tingkat akurasi yang tinggi ini menunjukkan keefektifan SVM dalam membedakan antara gambar tanaman normal dan yang sakit (Zuhdi *et al.*, 2024). Dengan demikian, pendekatan ini memiliki potensi yang besar dalam meningkatkan akurasi deteksi penyakit pada tanaman tebu.

Berdasarkan hal tersebut, penelitian ini bertujuan untuk mengevaluasi kinerja metode kecerdasan buatan, khususnya kombinasi CNN dan *Support Vector Machine* (SVM), dalam deteksi penyakit daun tebu. Evaluasi digunakan untuk mendapatkan model dengan akurasi terbaik dan menghasilkan diagnosa lebih akurat.

1.2 Rumusan Masalah

Berdasarkan uraian dari latar belakang, rumusan masalah dari penelitian ini adalah sebagai berikut.

1. Bagaimana implementasi algoritma CNN dan SVM dalam deteksi penyakit pada daun tebu?
2. Bagaimana pengaruh proporsi pembagian data yang berbeda terhadap kinerja model CNN dan SVM dalam deteksi penyakit pada daun tebu?
3. Bagaimana hasil akurasi algoritma CNN dan SVM dalam deteksi pada penyakit daun tebu?

1.3 Batasan Masalah

Adapun batasan masalah penelitian ini adalah sebagai berikut.

1. Penelitian ini akan mendeteksi 11 kategori tebu yaitu daun tebu sehat, daun tebu dengan penyakit yang disebabkan oleh jamur yaitu penyakit karat (*rust*), busuk merah (*redrot*), pokkah bung (*pokkeh boeng*), luka api (*Smutt*), daun kuning (*dried leaves*), dan busuk stek (*sett rot*), penyakit pada daun tebu yang disebabkan oleh virus yaitu penyakit mosaik (*mosaic*), penyakit kuning (*Yellow disease*), dan *banded chlorosis*, sedangkan penyakit yang disebabkan oleh bakteri yaitu penyakit *grassy shoot*.
2. Dataset diambil dari website Mendeley Data.
3. Arsitektur CNN yang digunakan adalah *ResNet50* dan *InceptionV3*

1.4 Tujuan Penelitian

Adapun tujuan penelitian ini adalah sebagai berikut.

1. Mengimplementasikan SVM dan CNN dalam deteksi penyakit pada daun tebu.
2. Mengetahui pengaruh variasi proporsi pembagian data terhadap kinerja model CNN dan SVM dalam deteksi pada penyakit daun tebu.
3. Mengukur hasil akurasi algoritma CNN dan SVM dalam deteksi penyakit pada daun tebu.

1.5 Manfaat Penelitian

Manfaat yang akan diperoleh dari penelitian ini antara lain sebagai berikut.

1. Penelitian ini diharapkan dapat memberikan solusi praktis bagi petani dalam mengidentifikasi penyakit pada tanaman tebu, sehingga mereka dapat mengambil tindakan cepat untuk mencegah kerugian.
2. Berkontribusi dalam pengembangan penelitian di bidang deteksi penyakit tanaman menggunakan CNN dan SVM.
3. Memperkaya literatur dan penelitian terkait penerapan kecerdasan buatan dalam meningkatkan produktivitas sektor perkebunan, khususnya pada komoditas tebu.

II. TINJAUAN PUSTAKA

2.1 Penelitian Terdahulu

Terdapat beberapa penelitian terdahulu yang berhubungan dengan penelitian ini yang diuraikan dalam Tabel 1.

Tabel 1. Penelitian Terdahulu

Penelitian	Metode	Data	Akurasi
Klasifikasi Penyakit Daun Tebu Menggunakan Algoritma <i>Convolutional Neural Network</i> (CNN) dan <i>Support Vector Machine</i> (SVM) (Yunizar, 2024)	<i>Convolutional Neural Network</i> (CNN) dan <i>Support Vector Machine</i> (SVM)	Website Mendeley Data, terdiri dari 2569 citra gambar yg dibagi menjadi lima kategori: <i>healthy, mosaik, red rot, rust, and Yellow disease.</i>	<i>ResNet50</i> : 85.08% SVM : 61.69%
Segmentasi Penyakit Pada Citra Daun Tebu Menggunakan <i>Fuzzy C Means</i> – <i>Support Vector</i>	Metode segmentasi FCM-SVM	30 Citra daun tebu	Akurasi 76%

Machine Dengan
Fitur Warna
(Mentari *et al.*,
2015)

Klasifikasi Kematangan Tebu Berdasarkan Tekstur Batang Menggunakan Metode <i>Naïve</i> <i>Bayes</i> (Putra <i>et</i> <i>al.</i> , 2020)	<i>Naive Bayes</i>	400 Citra	Akurasi 71%
Klasifikasi Penyakit Daun Tebu dengan Model AlexNet (Kursun <i>et al.</i> , 2024)	Model <i>deep learning</i> AlexNet	Website Mendeley Data, terdiri dari 2569 citra gambar	LeakyReLU : 90,67% ReLU : 87,90%,
Klasifikasi Jenis Penyakit Tebu Menggunakan Metode <i>Naïve</i> <i>Bayes</i> Berdasarkan Tekstur Pada Citra Daun Tebu (Sugiarto 2019)	<i>Naïve Bayes</i>	300 Citra	68%
Evaluasi Augmentasi Data pada Deteksi	Yolo v8	Website Mendeley Data,	mAP dari 40.3% menjadi 50.5%

Penyakit Daun	terdiri dari 2569
Tebu dengan	citra
YOLO v8 (Adib <i>et al.</i> , 2024)	

2.2 Tebu

Tebu (*Saccharum officinarum* Linn.) adalah tanaman yang tumbuh di daerah tropis dan sub tropis. Tanaman ini merupakan bagian dari keluarga rumput-rumputan (*Graminae*) (Adrian *et al.*, 2019). Tebu disebutkan sebagai tanaman yang memiliki kandungan sukrosa tinggi dan digunakan sebagai bahan baku utama gula dan biofuel (Mahfut *et al.*, 2024).

Menurut (Indrawanto *et al.*, 2010), tanaman tebu dapat dibedakan menjadi 3 jenis berdasarkan waktu masakannya, yaitu

1. Varietas yang berumur genjah yang dikenal dengan sebutan *early maturing* yang dapat dipanen pada umur 8-10 bulan,
2. Varietas yang berumur sedang atau *middle maturing* yang dapat dipanen pada umur 10-12 bulan, dan
3. Varietas yang berumur dalam atau *slow maturing* yang dapat dipanen pada umur di atas 12 bulan.

Saat memilih tanaman tebu untuk budidaya, penting untuk mempertimbangkan karakteristik varietas unggul, seperti kesehatan tanaman dan potensi produksi gula yang tinggi (Mahfut *et al.*, 2024). Tebu yang sehat umumnya ditandai dengan daun hijau dan segar, batang yang kokoh, dan pertumbuhan vegetatif yang optimal (Rezende *et al.*, 2022). Selain itu, varietas tebu dengan kandungan sukrosa tinggi dan ketahanan terhadap kekeringan sangat direkomendasikan, karena faktor iklim secara signifikan mempengaruhi kualitas dan produktivitas tebu (Khuimphukhieo *et al.*, 2024).

2.2.1 Jamur

1. Penyakit Karat (*Rust*)

Penyakit Karat (*Rust*) pada tanaman tebu adalah salah satu jenis penyakit yang disebabkan oleh jamur, khususnya dari genus *Puccinia*. Penyakit ini dapat muncul dalam dua bentuk utama, yaitu karat jingga dan karat biasa. Gejala penyakit karat ditandai dengan adanya bercak-bercak pada daun, terutama pada permukaan bawah, dengan ukuran bercak bervariasi antara panjang 2-20 mm dan lebar 1-3 mm. Daun yang terinfeksi parah dapat menunjukkan banyak bintik-bintik coklat yang mengarah ke area nekrotik yang luas. Karat biasa memiliki karakteristik lesi yang mirip dengan karat jingga, tetapi perbedaannya terletak pada warna dan bentuk bercak. Karat biasa berwarna coklat kemerahan hingga coklat, sedangkan karat jingga memiliki bercak kuning kecil memanjang yang dapat dilihat pada kedua permukaan daun (Ratnasari *et al.*, 2014). Berikut ini adalah ilustrasi penyakit *rust* pada tebu yang ditunjukkan pada Gambar 1.



Gambar 1. Penyakit Karat (*Rust*) pada daun tebu (<https://data.mendeley.com>)

2. Penyakit Busuk Merah (*Redrot*)

Penyakit Busuk Merah (*Redrot*) adalah penyakit yang disebabkan oleh jamur *Colletotrichum falcatum*. Penyakit ini merupakan salah satu masalah utama dalam budidaya tebu, terutama di daerah tropis. Gejala awal penyakit ini sulit dikenali, namun setelah musim hujan, gejala mulai muncul. Tanda-tanda awal termasuk hilangnya warna dan daun rontok dari bagian atas batang. Seiring perkembangan penyakit, batang tebu menjadi keriput, dan bagian dalam batang

akan menunjukkan warna merah yang diselingi bercak-bercak putih. Pada stadium lanjut, jamur dapat membentuk titik-titik hitam (*acervuli*) di sekitar ruas batang. Penyebaran Penyakit ini terutama menyebar melalui bibit yang terinfeksi (*stek*) dan juga dapat menyebar melalui konidia dan *klamidospora* yang ada di dalam tanah. Jamur dapat bertahan hidup pada sisa-sisa tanaman yang terinfeksi di dalam tanah selama beberapa bulan (Thineshkumar 2023). Berikut ini adalah ilustrasi penyakit *redrot* pada tebu yang ditunjukkan pada Gambar 2.



Gambar 2. Penyakit Busuk Merah (*Redrot*) pada daun tebu
(<https://data.mendeley.com>)

3. Penyakit Pokah Bung (*Pokkah Boeng*)

Penyakit Pucuk *Pokkah Boeng* adalah penyakit yang disebabkan oleh kompleks spesies jamur *Fusarium*, yang paling umum adalah *Fusarium proliferatum*, *F. moniliformae*, *F. verticillioides*, *F. sacchari*, dan *F. andiyazi* (Tiwari *et al.*, 2020). Penyakit ini menjadi masalah serius dalam budidaya tebu karena dapat menyebabkan kerugian ekonomi yang signifikan, dengan penurunan hasil dan kualitas tebu yang bervariasi antara 5% - 90% tergantung pada varietas yang terinfeksi (Tiwari 2020). Penyakit ini ditandai dengan gejala seperti klorosis pada daun muda, deformasi batang, dan pembusukan bagian atas batang, yang dapat menyebabkan kematian seluruh bagian atas tanaman. Selain itu, penyakit ini telah dilaporkan menyebar dengan cepat di berbagai daerah penghasil tebu di India dan negara lain, menjadikannya ancaman yang semakin meningkat bagi produksi tebu global. *Pokkah Boeng* juga dipengaruhi oleh kondisi iklim yang berubah, yang dapat meningkatkan insiden penyakit dan hama pada tanaman

tebu (Tiwari 2020). Berikut ini adalah ilustrasi penyakit *Pokkah Boeng* pada tebu yang ditunjukkan pada Gambar 3.



Gambar 3. Penyakit pokah bung (*pokkah boeng*) pada daun tebu (<https://data.mendeley.com>)

4. Penyakit Luka Api (*Smutt*)

Penyakit *Smutt* disebabkan oleh jamur *S. scitamineum*, yang dapat menginfeksi tanaman melalui teliospora yang ada di tanah atau melalui setts (batang tebu yang ditanam) yang terinfeksi. Infeksi *Smut* dapat menyebabkan penurunan persentase germinasi dan hasil panen. Misalnya, hanya 14% dan 31% germinasi yang tercatat pada setts yang terinfeksi secara alami dan buatan, dibandingkan dengan 40% pada setts yang sehat (Rajput *et al.*, 2021). Berikut ini adalah ilustrasi penyakit *Smutt* pada tebu yang ditunjukkan pada Gambar 4.



Gambar 4. Penyakit luka api (*Smutt*) pada daun tebu (<https://data.mendeley.com>)

5. Penyakit Daun Kering (*dried leave*)

Penyakit *dried leaves* pada tebu sering kali disebabkan oleh infeksi jamur dan bakteri yang menyerang jaringan tanaman selama kondisi iklim yang kering atau lembab tinggi. Beberapa penelitian mencatat bahwa jamur seperti *Xanthomonas albilineans* dapat menyebabkan gejala leaf scald, yaitu daun mengering pada ujung atau muncul garis putih paralel dengan tulang daun (Viswanathan *et al.*, 2022). Infeksi *Xanthomonas albilineans* pada tebu, terutama pada musim kemarau atau musim dengan kelembapan tinggi, dapat memperparah gejala penyakit daun kering. Selain itu gejala daun melepuh dengan garis-garis putih sejajar, infeksi ini menyebabkan daun menguning dan akhirnya mengering, yang berakibat pada berkurangnya kemampuan fotosintesis tanaman. Tanaman yang terinfeksi dapat menunjukkan penurunan kualitas dan hasil panen karena jaringan yang rusak menghambat transportasi air dan nutrisi, mempercepat proses pengeringan daun dan kematian tanaman (Viswanathan 2022). Berikut ini adalah ilustrasi penyakit *dried leave* pada tebu yang ditunjukkan pada Gambar 5.



Gambar 5. Penyakit daun kering (*dried leaves*) (<https://data.mendeley.com>)

6. Penyakit Busuk Stek (*Sett Rot*)

Penyakit Busuk Stek (*sett rot*) pada tebu disebabkan oleh jamur *Ceratocystis paradoxa*, yang menginfeksi tebu melalui potongan batang (*setts*) yang digunakan untuk regenerasi tanaman. Infeksi ini sering terjadi pada lahan dengan drainase buruk, di mana kelembapan yang tinggi mendukung perkembangan patogen. Jamur ini menghasilkan senyawa berbau seperti etil asetat, yang

membuat *setts* terinfeksi berbau seperti nanas matang. Infeksi *sett rot* mengakibatkan kegagalan perkecambahan, yang menyebabkan area tanaman yang tidak merata dan menurunkan populasi tebu secara signifikan di ladang (Ravichandran *et al.*, 2023). Berikut ini adalah ilustrasi penyakit *sett rot* pada tebu yang ditunjukkan pada Gambar 6.



Gambar 6. Penyakit Busuk Stek (*sett rot*) pada daun tebu
(<https://data.mendeley.com>)

2.2.2 Virus

1. Penyakit Mosaik (*Mosaic*)

Penyakit Mosaik adalah penyakit yang disebabkan oleh *Sugarcane streak mosaic virus* (SCSMV). Penyakit ini ditandai dengan gejala mosaik pada daun, yang dapat mencakup pola klorosis dan garis-garis pada daun muda. Penyakit ini terutama ditularkan melalui bahan *vegetatif* tanaman dan penularan melalui serangga vektor spesifik belum diketahui. Gejala penyakit ini dapat bervariasi dalam intensitas dan dapat mempengaruhi pertumbuhan serta hasil tanaman tebu secara keseluruhan (Rizqiyah *et al.*, 2023). Serangan penyakit mosaik oleh SCSMV dan SCMV ditemukan menyebar di daerah Lampung, Bone, Gowa, dan Takalar. Hal ini disebabkan karena daerah-daerah tersebut menggunakan bibit tebu yang tidak bebas virus. Sebaliknya, daerah Takalar memiliki tingkat keparahan penyakit yang rendah dibandingkan dengan daerah lainnya, karena Takalar merupakan daerah yang memiliki curah hujan yang rendah (Subekti *et al.*, 2020). Ilustrasi penyakit mosaik pada tanaman tebu dapat dilihat pada Gambar 8.



Gambar 7. Penyakit Mosaik (*mosaic*) pada daun tebu (<https://data.mendeley.com>)

2. Penyakit Kuning (*Yellow disease*)

Penyakit kuning merupakan salah satu penyakit yang menghambat produksi tebu yang disebabkan oleh *Sugarcane Yellow leaf virus* (ScYLV). Menurut Bertasello *et al.*, (2023), gejala penyakit kuning yang dominan adalah menguningnya pelepah pada permukaan bawah daun secara mencolok yang dapat menyebar secara horizontal ke lamina daun, kemudian berubah menjadi kering dan memutih, hingga akhirnya terjadi nekrosis jaringan yang dimulai dari ujung daun. Menurut Viswanathan (2020), gejala-gejala tersebut dipengaruhi oleh beberapa faktor seperti virus, varietas, musim tanam, tanah dan faktor lingkungan. Selain itu, kondisi kekeringan yang progresif akan memperparah gejala penyakit dan keparahan penyakit pada fase awal pertumbuhan tanaman. Berikut ini adalah ilustrasi penyakit kuning pada tebu yang ditunjukkan pada Gambar 8.



Gambar 8. Penyakit kuning (*Yellow disease*) pada daun tebu (<https://data.mendeley.com>)

3. Penyakit Klorosis Belang (*Banded Chlorosis*)

Penyakit *banded chlorosis* pada daun tebu disebabkan virus *Polerovirus* yang menyebabkan menghambat respons imun tanaman dengan menghasilkan protein virulensi seperti P0, yang menekan jalur pertahanan berbasis RNA *silencing*. Protein P0 berperan dalam menguraikan protein penting untuk pertahanan, sehingga mempercepat penyebaran infeksi dan meningkatkan kerusakan jaringan pada daun tebu (Liang *et al.*, 2023). Selain menghambat mekanisme pertahanan RNA, infeksi *Polerovirus* yang menyebabkan klorosis berpita juga mengganggu proses *fotosintesis* pada daun tebu, yang dapat mengakibatkan penurunan produksi energi penting untuk pertumbuhan tanaman. Dampak dari infeksi ini juga mencakup perubahan ekspresi gen pertahanan tanaman, membuat tebu lebih rentan terhadap patogen sekunder dan menurunkan kualitas hasil panen secara keseluruhan (Liang *et al.*, 2023). Berikut ini adalah ilustrasi penyakit kuning pada tebu yang ditunjukkan pada Gambar 9.



Gambar 9. Penyakit klorosis belang (*banded chlorosis*) pada daun tebu (<https://data.mendeley.com>)

2.2.3 Bakteri

1. Penyakit Tunas Rumput (*Grassy Shoot*)

Penyakit *Grassy Shoot* pada tebu disebabkan oleh infeksi *fitoplasma* yang mengakibatkan gejala pertumbuhan abnormal, seperti tunas yang lemah, daun berwarna kuning pucat, dan tanaman terlihat seperti rumput karena pertumbuhan tunas berlebih dan kecil. Penyakit ini terutama merusak pada tanaman ratoon

(regenerasi dari tebu yang telah dipanen), menyebabkan kerugian besar pada hasil panen dan kualitas tebu. Tanaman yang terinfeksi seringkali tidak menghasilkan batang tebu yang dapat dipanen, bahkan pada tanaman yang terinfeksi ringan hanya menghasilkan batang yang lemah (Liang *et al.*, 2023). Kerugian hasil dapat mencapai 5-20% pada tanaman utama, dan hingga 100% pada tanaman ratoon. *Fitoplasma* menyebabkan perubahan dalam *metabolisme* tanaman, termasuk penurunan kadar klorofil dan aktivitas fotosintesis, yang mempengaruhi pertumbuhan dan produksi gula. Terjadi juga perubahan pada *metabolisme* karbohidrat dan protein, meningkatkan kandungan gula reduksi dan menyebabkan penurunan kadar pati pada daun yang terinfeksi (Liang *et al.*, 2023). Berikut ini adalah ilustrasi penyakit *grassy shoot* pada tebu yang ditunjukkan pada Gambar 10.



Gambar 10. Penyakit tunas rumput (*grassy shoot*) pada daun tebu (<https://data.mendeley.com>)

2.3 Artificial Intelligence

Kecerdasan buatan (*Artificial Intelligence*) adalah teknologi yang memungkinkan analisis dan pemahaman pola-pola kompleks dalam data yang sulit dipahami oleh manusia. *Artificial Intelligence* memberikan kemampuan untuk mengidentifikasi dan bertindak berdasarkan wawasan yang mungkin tidak dapat diakses oleh pikiran manusia. Dengan menggunakan algoritma *Artificial Intelligence*, organisasi dapat mengekstrak informasi berharga dari volume data yang besar, yang membantu dalam mendeteksi perilaku curang dan pola-pola yang tidak biasa (Gupta, 2024), *Artificial Intelligence* terdiri dari berbagai sub bidang, di antaranya yaitu *Machine*

Learning yang berfokus pada kemampuan mesin untuk belajar dari data dan meningkatkan kinerjanya tanpa harus diprogram secara *eksplisit*. *Natural Language Processing* (NLP) yang memungkinkan mesin untuk memahami, menafsirkan, dan menghasilkan bahasa manusia. *Computer Vision* yang memungkinkan mesin untuk menafsirkan dan memahami informasi visual, sub bidang ini biasa digunakan dalam pengenalan gambar dan video, deteksi objek, dan analisis gambar medis. Selain itu, terdapat sub bidang *Pattern Recognition* yaitu proses mengidentifikasi pola atau struktur dalam data, biasa digunakan untuk pengenalan wajah, pengenalan suara, dan analisis gambar (Yunizar, 2024).

Kecerdasan Buatan diciptakan dengan tujuan untuk mempermudah pekerjaan manusia sehingga menjadi lebih efektif dan efisien. Saat ini, *Artificial Intelligence* telah diaplikasikan di semua sektor kehidupan, termasuk pendidikan, kesehatan, bisnis dan keuangan, transportasi, keamanan, dan sektor-sektor penting lainnya. Di bidang kesehatan, *Artificial Intelligence* digunakan untuk membantu mendiagnosis penyakit dan memprediksi hasil kesehatan pasien. Di bidang bisnis dan keuangan, *Artificial Intelligence* digunakan untuk mendeteksi kecurangan, serta digunakan untuk melakukan perdagangan atau alat transaksi seperti perbankan digital. Di bidang pendidikan, *Artificial Intelligence* juga digunakan untuk membantu melakukan pembelajaran secara online, membantu administrasi sekolah, dan membantu tenaga pengajar dalam kegiatan belajar mengajar (Yunizar, 2024).

Meskipun *Artificial Intelligence* memiliki banyak manfaat dalam membantu kehidupan manusia, *Artificial Intelligence* juga memiliki banyak kelemahan, terutama pada masalah resiko keamanan dan privasi. Masalah privasi ini telah menjadi banyak perhatian karena *Artificial Intelligence* seringkali membutuhkan akses ke data pribadi agar dapat berfungsi dengan baik. Risiko keamanan juga menjadi perhatian karena *Artificial Intelligence* dapat disalahgunakan untuk tujuan yang tidak baik.

2.4 Machine Learning

Salah satu cabang atau sub-bidang dari Kecerdasan Buatan adalah Pembelajaran Mesin (*Machine Learning*). Menurut Mahesh (2020). *Machine Learning* adalah

algoritma dan model statistik yang digunakan oleh sistem komputer untuk melakukan tugas tertentu tanpa perlu diprogram secara eksplisit. *Machine Learning* memungkinkan komputer untuk belajar dari data dan mengidentifikasi pola, sehingga dapat melakukan tugas secara otomatis setelah algoritma mempelajari cara menangani data tersebut.

Sesuai dengan namanya, *Machine Learning* mencoba meniru bagaimana manusia atau makhluk cerdas belajar dan melakukan generalisasi. Setidaknya ada dua aplikasi utama dalam *Machine Learning*, yaitu klasifikasi dan prediksi. Ciri khas dari *Machine Learning* adalah proses pelatihan, pembelajaran, atau *training*. Oleh karena itu, *Machine Learning* membutuhkan data untuk dipelajari yang disebut sebagai data training. Klasifikasi adalah metode dalam *Machine Learning* yang digunakan oleh mesin untuk memilah atau mengklasifikasikan objek berdasarkan karakteristik tertentu sebagaimana manusia berusaha membedakan satu objek dengan objek lainnya (Ahmad, 2017). Menurut Iqbal *et al.* (2021), *Machine learning* dibagi menjadi empat kategori, yaitu Sebagai berikut.


1. *Supervised learning* adalah metode yang akan mempelajari data training yang telah diberi label kemudian mengklasifikasikan kelas yang belum diketahui berdasarkan label sebelumnya.
2. *Unsupervised learning* adalah proses pengelompokan data berdasarkan kemiripannya, disebut juga *cluster* karena tidak perlu memberi label pada data.
3. *Semi - Unsupervised learning* pendekatan hibrida yang menggabungkan data berlabel dan tidak berlabel untuk pelatihan.
4. *Reinforcement learning* berada di antara *Supervised learning* dan *unsupervised learning*, pembelajaran ini memiliki konsep harus menyelesaikan suatu tujuan tanpa komputer secara eksplisit diberitahu jika tujuan tersebut telah tercapai.

Adapun manfaat dari *Machine Learning* adalah dapat meningkatkan akurasi prediksi dan efisiensi dalam berbagai aplikasi, seperti diagnosis medis, analisis keuangan, dan pengenalan pola. Memungkinkan analisis data besar secara otomatis,

mengidentifikasi pola dan tren yang mungkin tidak terlihat oleh manusia. Dapat mengotomatiskan proses pengambilan keputusan dan meningkatkan kinerja sistem dalam berbagai bidang, termasuk bisnis dan teknologi (Roihan *et al.*, 2020).

2.5 Neural Networks

Neural Networks adalah aspek penting dalam *Machine Learning*, yang dirancang untuk memodelkan hubungan yang kompleks antara input dan output melalui simpul yang saling terhubung, atau *neuron*. Model-model ini telah berkembang secara signifikan sejak awal kemunculannya di tahun 1950-an (Zeng *et al.*, 2022). *Neural Networks* dari lapisan neuron yang saling terhubung, di mana setiap neuron dapat menerima input (*input layer*), memproses nya (*Hidden layer*), dan menghasilkan output (*Output layer*) (Zhou *et al.*, 2024). Seperti pada Gambar 11. *Input layer* memiliki fungsi untuk menerima data dari luar yang perlu dianalisa dan dipelajari oleh *Neural Networks*, kemudian data tersebut akan melewati satu atau lebih *hidden layer* yang dapat mengubah input tersebut menjadi data yang sesuai untuk *output layer*. Selanjutnya, lapisan output akan memberikan hasil berupa respon *Neural Networks* terhadap data yang diberikan. Jaringan saraf ini digunakan untuk berbagai aplikasi, termasuk pengenalan pola, klasifikasi, regresi, dan pemrosesan gambar (Zhou *et al.*, 2024).



Gambar 11. Representasi dari *neural network* (www.sciencelearn.net)

2.6 Deep Learning


Deep learning adalah area khusus dalam *Machine Learning* dan *Artificial Intelligence* yang berfokus pada penggunaan jaringan saraf dengan banyak lapisan

untuk menganalisis berbagai bentuk data (Farhad *et al.*, 2023). *Deep learning* memiliki kemampuan untuk secara otomatis mempelajari representasi fitur yang kompleks. Selain itu, *Deep Learning* juga dapat mengoptimalkan parameternya dengan menggunakan algoritma pembelajaran yang disebut *backpropagation* (Jiantono, 2023). Beberapa algoritma yang termasuk dalam kategori *deep learning* adalah *Convolutional Neural Network* (CNN), *Recurrent Neural Network* (RNN), *Generative Adversarial Network* (GAN) (Ashraf *et al.*, 2023).

Model *deep learning* dilatih menggunakan sejumlah besar data dan algoritma yang dapat dipelajari dan ditingkatkan dari waktu ke waktu, sehingga menjadi lebih akurat saat memproses lebih banyak data. Oleh karena itu, *deep learning* cocok untuk menangani masalah yang kompleks seperti visi komputer, pemrosesan bahasa alami, dan pengenalan suara. Namun, karena *deep learning* membutuhkan data dalam jumlah besar, hal ini menyebabkan waktu komputasi yang lama dan biaya yang tinggi. Selain itu, model yang menggunakan *deep learning* rentan terhadap *overfitting* pada data pelatihan, yang dapat mengakibatkan akurasi kinerja yang buruk pada data baru.

2.7 Convolutional Neural Network

Salah satu metode *deep learning* yang digunakan serta memiliki hasil yang paling signifikan dalam pengenalan gambar adalah *Convolutional Neural Network* (CNN). *Convolutional Neural Network* (CNN) dirancang khusus untuk aplikasi visi komputer. Unggul dalam tugas-tugas seperti klasifikasi gambar dan video, serta deteksi objek dalam gambar. Arsitektur CNN memungkinkan mereka untuk secara otomatis mempelajari fitur dari gambar (Ari *et al.*, 2024). Menurut Alzubaidi *et al.*, (2021), keuntungan menggunakan CNN adalah fitur pembagian bobot yang membantu mengurangi jumlah parameter jaringan yang dapat dilatih sehingga meningkatkan generalisasi dan menghindari *overfitting*. Selain itu, CNN adalah metode yang sangat terorganisir dan jauh lebih mudah diimplementasikan dalam skala besar dari pada jaringan saraf lainnya. Gambar 12. Berikut merupakan gambaran umum arsitektur CNN dan proses *training* dalam CNN.



Gambar 12. *Convolutional Neural Network* (www.analyticsvidhya.com)


Jenis CNN yang umum digunakan mirip dengan *multi-layer perceptron* (MLP), yang terdiri dari banyak layer seperti *convolutional layer*, *pooling layer*, dan *Fully Connected* (FC) layer. Pada Gambar 2.12 CNN dimulai dengan menerima gambar input, yang kemudian diproses oleh lapisan *convolutional* untuk menerapkan *filter* atau kernel untuk menyesuaikan fitur seperti tepi atau pola tertentu. Implementasi fungsi *ReLU* meningkatkan efisiensi komputasi dengan mengurangi nilai negatif menjadi nol. Setelah itu, penyatuan lapisan mengurangi ukuran *filter* untuk mengurangi risiko *overfitting* sekaligus mengurangi ukuran *filter*. Pada bagian akhir, *SoftMax* mengubah hasil prediksi menjadi probabilitas, di mana kelas dengan probabilitas tertinggi menjadi prediksi akhir, seperti yang terlihat pada klasifikasi antara kuda, zebra, dan anjing. Adapun Pembahasan yang lebih rinci mengenai cara kerja arsitektur CNN adalah sebagai berikut.

2.7.1 Layer CNN

1. Convolutional Layer

Convolutional Layer merupakan blok bangunan mendasar dari *Convolutional Neural Network* (CNN), terutama digunakan untuk memproses data dengan topologi seperti *grid*, seperti gambar. Ini menerapkan rangkaian filter (atau kernel) ke data input untuk mengekstrak fitur (Cui *et al.*, 2024). Lapisan konvolusi bekerja dengan menggeser filter ini di atas data input, melakukan perkalian berdasarkan elemen, dan


menjumlahkan hasilnya untuk menghasilkan peta fitur. Proses ini membantu mendeteksi pola seperti tepi, tekstur, dan bentuk pada gambar (Cui *et al.*, 2024). Secara tradisional, pengetahuan sebelumnya tertanam dalam lapisan konvolusi melalui desain kernel yang dapat dikontrol atau dengan menggunakan bank kernel. Metode ini memungkinkan jaringan untuk mempelajari fitur-fitur spesifik dari data selama pelatihan, sehingga meningkatkan kinerjanya dalam tugas-tugas seperti klasifikasi gambar atau deteksi objek (Cui *et al.*, 2024).



Gambar 13. *Convolutional Layer* (<https://www.rncm.ac.uk>)

2. *Pooling Layer*

Pooling Layer, disebut sebagai *downsampling*, berada setelah lapisan *convolutional*. Setiap pergeseran di seluruh peta fitur atau wilayah peta aktivasi ditentukan oleh jumlah langkah yang dipindahkan di *Pooling Layer*, yang terdiri dari filter dengan ukuran dan langkah tertentu (Alzubaidi *et al.*, 2021). Karena keduanya bekerja untuk mengurangi ukuran spasial dari fitur konvolusi (yaitu, lebar dan tinggi) dari volume input, maka *Pooling Layer* dan *Convolutional Layer* dapat dibandingkan. Selain berguna untuk mengidentifikasi fitur-fitur yang mendominasi yang bersifat rotasi dan posisi invarian, hal ini dilakukan untuk meminimalkan jumlah parameter dan komputasi dalam jaringan untuk mengontrol *overfitting* dan menjaga keefektifan proses pelatihan model (Saha, 2018). Ada tiga tipe utama dari *pooling layers* yang dapat digabung dalam *deep neural network* di antaranya *Average Pooling*, *Max Pooling* dan *Global Average Pooling*.




Gambar 14. *tree type pooling operations* (Alzubaidi *et al.*, 2021)

3. *Fully Connected Layer*

Fully Connected Layer, sering disebut sebagai lapisan padat, merupakan jenis lapisan dalam jaringan saraf di mana setiap neuron terhubung ke setiap neuron di lapisan sebelumnya. Struktur ini memungkinkan jaringan untuk mempelajari pola kompleks dalam data. Terutama bila dikombinasikan dengan aktivasi *ReLU*, karena mereka membantu dalam mempelajari pola kompleks dan menentukan batas keputusan dalam tugas klasifikasi (Vallin *et al.*, 2023).

2.7.2 *Rectified Linear Unit (ReLU)*

ReLU (Rectified Linear Unit) adalah fungsi aktivasi yang umum digunakan dalam jaringan saraf tiruan. Secara matematis, fungsi ini didefinisikan sebagai $f(x) = \max(0, x)$, yang berarti bahwa jika x bernilai positif, maka output-nya adalah x ; sedangkan jika x bernilai negatif, maka output-nya adalah 0. Fungsi *ReLU* digunakan untuk memperkenalkan non-linearitas ke dalam model, sehingga jaringan dapat mempelajari pola yang kompleks dalam data. Non-linearitas ini sangat penting dalam berbagai tugas seperti pengenalan citra dan pemrosesan bahasa alami (Vallin *et al.*, 2023). Pada gambar 15 adalah visualisasi dari grafik fungsi *ReLU*.



Gambar 15. Perhitungan hasil grafik fungsi aktivasi *ReLU*

2.7.3 Flatten

Flatten merupakan metode yang digunakan untuk mengubah output dari konvolusi dan pooling layer menjadi *vektor* satu dimensi. Proses ini penting karena lapisan berikutnya, yaitu lapisan yang terhubung sepenuhnya, membutuhkan input dalam bentuk vektor untuk melakukan klasifikasi. Setelah fitur diekstraksi dari gambar melalui lapisan konvolusi dan *pooling*, keluarannya biasanya berupa matriks multi-dimensi. Dengan menggunakan lapisan perataan, matriks ini diubah menjadi vektor panjang tunggal, yang kemudian dapat diproses oleh lapisan yang terhubung sepenuhnya untuk menghasilkan prediksi kategori. Proses perataan ini membantu menyederhanakan struktur data yang kompleks ke dalam format yang lebih mudah dikelola oleh jaringan syaraf, sehingga memungkinkan model untuk belajar dari data secara lebih efektif (Jeczminek *et al.*, 2021).

2.7.4 Dropout Layer

Dropout layer merupakan teknik yang dapat meminimalisir terjadinya kesalahan pada pelatihan yang menyebabkan model *overfitting*, dengan cara meningkatkan generalisasi model. *Dropout layer* akan menonaktifkan beberapa fitur secara acak ketika model dalam tahap pelatihan yang terhubung dengan *neuron* sesuai dengan parameter yang telah diinisialisasi (Norhikmah *et al.*, 2022). Lapisan *dropout* biasanya ditempatkan setelah lapisan yang terhubung penuh, sebelum lapisan *output*. *Dropout* memiliki parameter yang disebut probabilitas, parameter ini dapat diatur dalam rentang 0 sampai 1.

2.7.5 SoftMax


SoftMax merupakan fungsi yang banyak digunakan dalam pembelajaran mesin yang mengubah vektor input menjadi distribusi probabilitas. Fungsi ini memetakan nilai input ke simpleks probabilitas, yang berarti bahwa nilai output dijumlahkan menjadi satu, sehingga dapat ditafsirkan sebagai probabilitas, peran utama *SoftMax* adalah menimbang ulang input dengan memusatkan massa probabilitas pada entri yang lebih besar. Ini berarti bahwa ini menekankan input yang paling signifikan sambil mengurangi pengaruh input yang lebih kecil (Zhou *et al.*, 2024).

2.8 Model Arsitektur ResNet50

ResNet50 adalah arsitektur yang dikembangkan oleh Kaiming He, Xiangyu Zhang, Shaoqing Ren, dan Jian Sun dari *Microsoft Research* yang berhasil meningkatkan kompetensi ILSVRC pada tahun 2015. *ResNet* adalah singkatan dari *Residual Network*, yang berfokus pada blok residual yang mendukung arsitektur jaringan. Arsitektur *ResNet* dikembangkan sebagai respon dari hasil eksperimen yang dilakukan dalam penelitian *deep learning* mengenai keandalan jaringan syaraf yang tidak selalu meningkat meskipun lapisannya ditambah. Ketika lapisan jaringan syaraf bertambah, muncul masalah yang dikenal dengan istilah degradasi performa, yaitu ketika jumlah lapisan bertambah, akurasi yang seharusnya meningkat justru menurun (He *et al.*, 2015), hal ini bukan disebabkan oleh *overfitting*, di mana model menjadi sangat spesifik terhadap data, tetapi lebih disebabkan oleh kesulitan dalam mempelajari model.


Kondisi ini dapat terjadi karena informasi penting dari lapisan awal tidak dapat mencapai lapisan berikutnya karena degradasi selama perjalanan melalui banyak lapisan. Akibatnya, jaringan syaraf sulit untuk dipelajari dan dipelihara. Menurut penelitian yang dilakukan oleh Tim Kaiming He, sulit untuk mengoptimalkan setiap sistem (jaringan) karena ada lebih banyak kesalahan dalam model yang sudah mapan daripada meningkatkannya selama pelatihan. Untuk mengatasi masalah ini, sebuah teknik yang dikenal sebagai "*skip connection*" atau "*identity block*". digunakan. Hal ini memerlukan pemindahan beberapa blok konvolusi (lapisan) yang ada di antara dua unit aktivasi *ReLU* dengan menghubungkan output dari unit

ReLU pertama secara langsung ke unit *ReLU* kedua, seperti yang ditunjukkan pada Gambar 16.



Gambar 16. *Skip Connection* (<https://medium.com>)


Pendekatan ini membuat jaringan pembelajaran menjadi lebih efisien dan meningkatkan kinerja, terutama dalam arsitektur yang sangat efektif seperti *ResNet50*. Karena ada koneksi residual yang memungkinkan jaringan tetap stabil, bahkan pada kedalaman yang tetap, meningkat dari 20 ke 50 lapisan atau dari 50 ke 100 lapisan, meningkatkan lapisan tambahan tidak akan mempengaruhi kinerja. Koneksi residual ini memastikan bahwa kinerja jaringan tidak akan terpengaruh karena lapisan. Arsitektur *ResNet* yang paling terkenal adalah *ResNet50*, di mana angka 50 sesuai dengan jumlah lapisan dalam jaringan yang mencapai 50 lapisan. *ResNet50* terdiri dari 16 blok sisa, yang masing-masing terdiri dari beberapa lapisan berbelit-belit dengan koneksi sisa. Sebagai gantinya, Arsitek memungkinkan penyatuan, koneksi penuh, dan lapisan *softmax* untuk klasifikasi. Contoh arsitektur *ResNet50* dapat dilihat pada Gambar 17.



Gambar 17. Arsitektur *ResNet50* (<https://medium.com>)

2.9 Model Arsitektur *InceptionV3*

Inception-v3 adalah arsitektur *Convolutional Neural Network* (CNN) yang dibangun di atas versi sebelumnya dari model *Inception*, yang bertujuan untuk meningkatkan kinerja pada tugas klasifikasi gambar sambil mempertahankan efisiensi komputasi. *Inception-v3* mencapai tingkat kesalahan top-1 sebesar 4,48% dan tingkat kesalahan top-5 sebesar 19,47% dengan evaluasi tanaman tunggal pada tolok ukur klasifikasi ILSVRC 2012. Ketika dievaluasi dengan 144 tanaman, tingkat kesalahan teratas-1 meningkat menjadi 4,2% dan tingkat kesalahan teratas-5 menjadi 18,77%. Arsitektur ini dirancang untuk menjadi efisien secara komputasi, mencapai kinerja tinggi dengan peningkatan biaya komputasi yang relatif kecil dibandingkan dengan arsitektur yang lebih sederhana. *Inception-v3* tercatat enam kali lebih murah secara komputasi dibandingkan jaringan yang lebih padat dengan menggunakan parameter yang jauh lebih sedikit (Szegedy *et al.*, 2015). Adapun ilustrasi pada arsitektur *InceptionV3* dapat dilihat di Gambar 18.



Gambar 18. Ilustrasi arsitektur *InceptionV3* (Ali *et al.*, 2021)


2.10 Support Vector Machine (SVM)

Support Vector Machine (SVM) adalah salah satu metode dalam *supervised learning* yang biasanya digunakan untuk klasifikasi (seperti *Support Vector Classification*) dan regresi (*Support Vector Regression*). Dalam pemodelan klasifikasi, SVM memiliki konsep yang lebih matang dan lebih jelas secara matematis dibandingkan dengan teknik klasifikasi lainnya. SVM juga dapat

menyelesaikan masalah klasifikasi dan *regresi* dengan *linear* dan *non-linear* (samsudiney, 2019).

SVM dapat dikategorikan menjadi dua jenis utama berdasarkan sifat data yaitu SVM *linier* dan *non-linear* (Ali *et al.*, 2024).

1. SVM *linier* digunakan ketika data dapat dipisahkan oleh garis lurus (atau *hyperplane* dalam dimensi yang lebih tinggi). Ini berarti bahwa ada batas linier yang dapat secara efektif mengklasifikasikan titik data ke dalam kelas yang berbeda. Tujuan dari SVM *linier* adalah untuk menemukan *hyperplane* optimal yang memaksimalkan margin antar kelas. Margin adalah jarak antara *hyperplane* dan titik data terdekat dari salah satu kelas, yang dikenal sebagai vektor pendukung. SVM linier efektif dalam skenario di mana data dapat dipisahkan secara *linier*, seperti dalam tugas klasifikasi teks tertentu atau ketika fitur-fiturnya terdefinisi dengan baik dan berbeda (Ali *et al.*, 2024).
2. SVM *non-linier* digunakan ketika data tidak dapat dipisahkan oleh garis lurus. Dalam kasus seperti itu, hubungan antara kelas lebih kompleks, membutuhkan pendekatan yang lebih fleksibel. Untuk menangani data non-linear, SVM menggunakan fungsi kernel. Fungsi-fungsi ini mengubah ruang input asli menjadi ruang dimensi yang lebih tinggi dimana *hyperplane linier* dapat digunakan untuk memisahkan kelas. Transformasi ini memungkinkan SVM untuk mengklasifikasikan data yang tidak dapat dipisahkan secara *linear* secara efektif. SVM *non-linear* banyak digunakan dalam kumpulan data yang kompleks (Ali *et al.*, 2024).



Gambar 19. *Hyperplane* positif (+1) dan negatif (-1) (<https://data.medium.com>)

Hyperplane yang ditemukan oleh SVM diilustrasikan seperti Gambar 19 Berikut adalah rangkuman dari penjelasan tersebut. *Hyperplane* dalam SVM adalah garis pemisah utama yang terletak di tengah-tengah dua kelas, ditentukan oleh persamaan $w^T x = 0$. SVM memaksimalkan margin, yaitu jarak antara *hyperplane* positif ($w^T x = +1$) dan negatif ($w^T x = -1$). Titik-titik data terdekat dari kedua kelas yang berada di batas margin disebut *support vectors*. *Support vectors* ini sangat penting karena menentukan posisi *hyperplane* optimal, sehingga meningkatkan kemampuan generalisasi model (Cortes & Vapnik1995).

2.11 Image Augmentation

Augmentasi gambar adalah teknik penting dalam *Deep Learning* yang meningkatkan keragaman dan ukuran kumpulan data pelatihan, sehingga meningkatkan kinerja model. Berbagai metode inovatif telah muncul, masing-masing menjawab tantangan spesifik yang terkait dengan ketersediaan data yang terbatas dan *over-fitting*. Tujuan utama *augmentasi* gambar adalah untuk meningkatkan akurasi pengenalan model, terutama ketika berhadapan dengan lingkungan yang kompleks dan sampel pelatihan terbatas. Ini sangat relevan dalam studi pengenalan bercak daun tebu, di mana kumpulan data mungkin tidak cukup luas untuk melatih model yang kuat secara efektif (Amrulloh *et al.*, 2022).

2.12 Confusion Matrix

Confusion Matrix adalah instrumen untuk menampilkan kinerja model klasifikasi pada data uji dengan hasil yang sudah diketahui sebelumnya. Matriks kebingungan umumnya digunakan untuk mengevaluasi kinerja tugas klasifikasi pembelajaran mesin dengan dua atau lebih kelas. Matriks kebingungan adalah tabel matriks dengan empat kemungkinan kombinasi nilai prediksi dan nilai aktual. Tabel 2. berisi rincian tentang matriks kebingungan.

Tabel 2. *Confusion Matrix*

	<i>Actual Positive</i>	<i>Actual Negative</i>
<i>Predicted Positive</i>	<i>True Positive</i>	<i>False Positive</i>
<i>Predicted Negative</i>	<i>True Negative</i>	<i>False Negative</i>

Menurut Kotu & Deshpande (2019), terdapat 4 istilah yang biasa digunakan sebagai representasi hasil pada proses klasifikasi *confusion matrix*. Adapun keempat istilah tersebut yaitu:

- a) *True Positive* (TP): Terjadi ketika kelas yang diprediksi adalah positif, dan prediksi tersebut benar. Misalnya, sistem deteksi penyakit memprediksi daun tebu terkena *redrot* dan benar bahwa daun tersebut memang terkena *redrot*.
- b) *False Positive* (FP): Terjadi ketika kelas yang diprediksi adalah positif, tetapi prediksi tersebut salah. Misalnya, sistem memprediksi daun tebu terkena *Yellow disease*, tetapi sebenarnya daun tersebut sehat.
- c) *False Negative* (FN): Terjadi ketika kelas yang diprediksi adalah negatif, dan prediksi tersebut salah. Misalnya, sistem memprediksi daun tebu sehat, padahal sebenarnya daun tersebut terkena *rust*.
- d) *True Negative* (TN): Terjadi ketika kelas yang diprediksi adalah negatif, dan prediksi tersebut benar. Misalnya, sistem memprediksi daun tebu sehat, dan benar bahwa daun tersebut memang dalam kondisi sehat.

Adapun beberapa *performance metrics* populer yang umum dan sering digunakan, yaitu:

1. Accuracy

Accuracy menggambarkan kemampuan model untuk mengklasifikasikan sesuatu dengan benar. Akurasi dalam klasifikasi mengacu pada kemampuan model untuk memprediksi kelas dengan benar, baik positif maupun negatif. Ketika data tidak seimbang, model yang memprediksi kelas mayoritas (positif) mungkin memiliki nilai akurasi yang lebih tinggi daripada model yang mengidentifikasi kelas minoritas (negatif). Model yang memprediksi kelas mayoritas (positif) mungkin kurang efektif dalam mendeteksi kelas minoritas (negatif). Untuk menghitung nilai akurasi, kita dapat menggunakan persamaan 1 dibawah ini.

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (1)$$

2. Precision

Precision adalah metrik yang mengukur seberapa baik model memprediksi kelas positif dari semua prediksi positif dari semua prediksi positif yang dibuat. Presisi dalam klasifikasi mengacu pada seberapa sering model secara akurat memprediksi kelas kelas positif, dibandingkan dengan semua prediksi positif yang diberikan oleh model. Untuk menghitung nilai presisi, gunakan persamaan 2 di bawah ini.

$$Precision = \frac{TP}{TP+FP} \quad (2)$$

3. Recall

Statistik penilaian yang disebut *recall* mengindikasikan seberapa baik sebuah model mengenali kelas positif. Jumlah prediksi positif yang akurat dibagi dengan seluruh jumlah data yang benar-benar positif adalah *recall*. Rumus 3 dapat digunakan untuk menentukan nilai *recall*.

$$Recall = \frac{TP}{TP+FN} \quad (3)$$

4. *F1-Score*

F1-Score adalah metrik evaluasi yang menggambarkan keseimbangan antara presisi dan *recall*. Nilai *F1-Score* akan memberikan gambaran sejauh mana model mampu mengintegrasikan presisi dan *recall*. Untuk menghitung nilai *F1-Score*, kita dapat menggunakan persamaan 4 di bawah ini.

$$F1-Score = 2x \frac{recall \times precision}{recall + precision} \quad (4)$$

2.13 Multiclass Confusion Matrix

Perluasan dari konsep *confusion matrix* yang digunakan dalam klasifikasi gabungan untuk klasifikasi dengan lebih dari dua kelas dikenal sebagai *multiclass confusion matrix*. *Matrix* berbentuk persegi dengan dimensi $n \times n$, di mana n adalah jumlah kelas yang diklasifikasikan. *Matrix* memiliki setiap baris yang merepresentasikan kelas nyata (*ground truth*) dan setiap kolom yang merepresentasikan kelas prediksi model (Markoulidakis *et al.*, 2021). Terdapat empat indikator *multiclass confusion matrix*. Seperti yang ditunjukkan pada tabel 3.

Tabel 3. *Multiclass Confusion Matrix*

		Predicted Class			
		C ₁	C ₂	...	C _N
Actual Class	C ₁	TP ₁	IM	IM	IM
	C ₂	IM	TP ₂	IM	IM
	...	IM	IM	TP...	IM
	C _N	IM	IM	IM	TP _N

Tabel *multiclass confusion matrix* menggambarkan hasil evaluasi klasifikasi model pada data. Tabel ini memiliki diagonal utama yang menunjukkan jumlah prediksi yang benar untuk masing-masing kelas, yang disebut sebagai *True Positive* (TP). Elemen-elemen ini menunjukkan sampel yang diklasifikasikan dengan benar oleh model, seperti TP₁ untuk kelas C₁, TP₂ untuk kelas C₂, dan seterusnya hingga TP_N untuk kelas C_N. Elemen non-diagonal disebut *Incorrect Misclassifications* (IM), yang menunjukkan jumlah prediksi yang salah, yaitu ketika model memprediksi suatu kelas tetapi sebenarnya kelas tersebut berasal dari kelas lain. Dibandingkan

dengan klasifikasi biner, *Multiclass Classification* menghadapi masalah analisis kesalahan yang lebih kompleks. Nilai *True Positive* (TP), *False Positive* (FP), *False Negative* (FN), dan *True Negative* (TN) dihitung secara berbeda dalam *matrix confusion multiclass*.

- a) *True Positive* (TP): Terjadi ketika kelas yang diprediksi adalah positif, dan prediksi tersebut benar. Misalnya, sistem deteksi penyakit memprediksi daun tebu terkena *redrot* dan benar bahwa daun tersebut memang terkena *redrot*.
- b) *False Positive* (FP): Terjadi ketika kelas yang diprediksi adalah positif, tetapi prediksi tersebut salah. Misalnya, sistem memprediksi daun tebu terkena *Yellow disease*, tetapi sebenarnya daun tersebut sehat.
- c) *False Negative* (FN): Terjadi ketika kelas yang diprediksi adalah negatif, dan prediksi tersebut salah. Misalnya, sistem memprediksi daun tebu sehat, padahal sebenarnya daun tersebut terkena *rust*.
- d) *True Negative* (TN): Terjadi ketika kelas yang diprediksi adalah negatif, dan prediksi tersebut benar. Misalnya, sistem memprediksi daun tebu sehat, dan benar bahwa daun tersebut memang dalam kondisi sehat.

Untuk mengevaluasi model klasifikasi *multiclass*, formula dasar masih menggunakan metrik seperti *accuracy*, *presisi*, *recall*, dan *F1-score*.

1. Accuracy

Accuracy adalah ukuran seberapa akurat sistem dapat mengklasifikasikan objek. Dalam *Multiclass Classification*, akurasi dapat dihitung dengan membandingkan jumlah prediksi yang benar (*True Positif*) untuk setiap kelas terhadap jumlah total sampel yang ada. Berikut merupakan persamaan untuk menghitung akurasi:

$$Acc = \frac{\sum_{i=1}^N TP(C_i)}{N} \quad (5)$$

Keterangan:

$TP(C_i)$ = data positif untuk kelas C_i , yaitu jumlah sampel yang benar diklasifikasikan sebagai kelas C_i .

N = total jumlah sampel

Rumus ini menghitung rasio antara jumlah prediksi yang benar (*True Positives*) untuk setiap kelas dibandingkan dengan jumlah sampel total. Kualitas klasifikasi data model ditentukan oleh nilai keakuratannya, semakin tinggi nilai akurasi maka semakin baik performa model tersebut.

2. Precision

Precision adalah rasio perbandingan jumlah data yang dikategorikan positif dan diklasifikasikan dengan benar oleh sistem terhadap semua data yang diklasifikasikan positif. Secara khusus, presisi mengukur rasio antara jumlah data yang benar diklasifikasikan sebagai positif (*True Positive*, TP) terhadap total data yang diprediksi sebagai positif, baik yang benar maupun yang salah (*False Positive*, FP). *Precision* sangat penting dalam situasi di mana *false positif* memiliki efek yang signifikan, seperti mendeteksi suatu penyakit. Dalam konteks klasifikasi *multiclass*, akurasi dapat dihitung menggunakan tiga pendekatan berbeda: akurasi per kelas (*Class Precision*), akurasi rata-rata makro (*macro-average precision*), dan akurasi rata-rata mikro (*micro-average precision*). Masing-masing pendekatan ini memiliki kemampuan dan tujuan yang berbeda tergantung pada tujuan evaluasi dan karakteristik kumpulan data.

a) Presisi perkelas (*Class Precision*)

Berikut merupakan persamaan untuk menghitung presisi per kelas:

$$P(C_i) = \frac{TP(C_i)}{TP(C_i) + FP(C_i)} \quad (6)$$

Keterangan:

$TP(C_i)$ = data positif untuk kelas C_i , yaitu jumlah sampel yang benar diklasifikasikan sebagai kelas C_i .

$FP(C_i)$ = data negative untuk kelas C_i , yaitu jumlah sampel yang salah diklasifikasikan sebagai kelas C_i .

Rumus ini digunakan untuk menghitung presisi khusus untuk setiap kelas. Ini berguna ketika kita ingin mengetahui performa model pada kelas tertentu, terutama dalam kasus dataset yang tidak seimbang (*imbalanced*),

di mana kelas tertentu mungkin memiliki dominasi yang lebih besar daripada yang lain.

b) *Macro*

Berikut merupakan persamaan untuk menghitung *macro-precision*.

$$P(\text{macro}) = \frac{1}{N} \sum_{i=1}^N P(C_i) \quad (7)$$

Keterangan:

N = total jumlah sampel

P (C_i) = precision untuk setiap kelas C_i

Macro-average memiliki tujuan untuk menghitung rata-rata presisi dari semua kelas tanpa mempertimbangkan distribusi sampel di setiap kelas. Terlepas dari jumlah sampel yang digunakan, setiap kelas diperlakukan dengan cara yang sama. Metode ini berguna dalam situasi di mana kita ingin memberikan nilai yang sama kepada semua kelas, terutama dalam dataset yang seimbang atau ketika kelas minoritas dan kelas mayoritas sama pentingnya.

c) *Micro*

Berikut merupakan persamaan untuk menghitung *micro-precision*:

$$P(\text{micro}) = \frac{\sum_{i=1}^N TP(C_i)}{\sum_{i=1}^N [TP(C_i) + FP(C_i)]} \quad (8)$$

Keterangan:

$TP(C_i)$ = data positif untuk kelas C_i , yaitu jumlah sampel yang benar diklasifikasikan sebagai kelas C_i .

$FP(C_i)$ = data negative untuk kelas C_i , yaitu jumlah sampel yang salah diklasifikasikan sebagai kelas C_i .

N = total jumlah sampel.

Dengan menggabungkan semua nilai *true positive* dan *false positive* dari setiap kelas, *micro-average precision* digunakan untuk menghitung presisi semua kelas. Teknik ini memberikan bobot yang lebih besar kepada kelas

dengan jumlah sampel yang lebih besar, sehingga cocok untuk dataset yang tidak seimbang tetapi juga ketika kita lebih tertarik pada kinerja model secara keseluruhan daripada kinerja per kelas.

3. Recall

Recall adalah metrik evaluasi yang digunakan untuk mengukur seberapa baik model dapat mengidentifikasi semua kasus positif yang ada dalam dataset. Secara khusus, *recall* mengukur rasio antara jumlah data yang benar diklasifikasikan sebagai positif (*True Positive*, TP) terhadap total data yang sebenarnya positif, baik yang berhasil diklasifikasikan sebagai positif benar maupun yang salah diklasifikasikan sebagai negative (*False Negatif*, FN).

Recall per kelas (*Class Recall*), *macro-average recall*, dan *micro-average recall* adalah tiga metode yang digunakan untuk menghitung *recall* dalam klasifikasi multi kelas. Tergantung pada tujuan evaluasi dan karakteristik dataset, masing-masing metode memiliki tujuan dan manfaat yang berbeda.

a) *Recall* per kelas (*class recall*)

Berikut merupakan persamaan untuk menghitung *recall* per kelas.

$$R(C_i) = \frac{TP(C_i)}{TP(C_i) + FN(C_i)} \quad (9)$$

Keterangan:

$TP(C_i)$ = data positif untuk kelas C_i , yaitu jumlah sampel yang benar diklasifikasikan sebagai kelas C_i .

$FN(C_i)$ = data negatif untuk kelas C_i , yaitu jumlah sampel sebenarnya termasuk C_i tetapi salah diklasifikasikan sebagai kelas lain.

Rumus tersebut digunakan untuk mengukur *recall* secara khusus untuk setiap kelas. Ini berguna ketika ingin mengetahui seberapa baik model dapat menemukan *instance* positif pada kelas tertentu. Misalnya, kita mungkin ingin memastikan bahwa model menemukan *instance* positif untuk kelas minoritas dalam dataset yang tidak seimbang.

b) *Macro-Average Recall*

Berikut merupakan persamaan untuk menghitung *macro-average recall*:

$$R(\text{macro}) = \frac{1}{N} \sum_{i=1}^N R(C_i) \quad (10)$$

Keterangan:

$R(C_i)$ = nilai *recall* untuk setiap kelas C_i .

N = total jumlah sampel.

Macro-average recall menghitung rata-rata *recall* dari semua kelas tanpa mempertimbangkan distribusi sampel masing-masing kelas. Metode ini berguna untuk memberikan bobot yang sama kepada semua kelas dalam dataset yang seimbang atau ketika kelas minoritas dan mayoritas sama pentingnya.

c) *Micro-Average Recall*

Berikut merupakan persamaan untuk menghitung *micro-average recall*:

$$R(\text{micro}) = \frac{\sum_{i=1}^N TP(C_i)}{\sum_{i=1}^N [TP(C_i) + FN(C_i)]} \quad (11)$$

Keterangan:

$TP(C_i)$ = data positif untuk kelas C_i , yaitu jumlah sampel yang benar diklasifikasikan sebagai kelas C_i .

$FN(C_i)$ = data negatif untuk kelas C_i , yaitu jumlah sampel sebenarnya termasuk C_i tetapi salah diklasifikasikan sebagai kelas lain.

N = total jumlah sampel.

Micro-average recall menghitung *recall* di seluruh dunia dengan menggabungkan semua *True Positive* dan *False Negative* dari semua kelas. Metode ini memprioritaskan kelas dengan jumlah sampel yang lebih besar, yang membuatnya sesuai untuk dataset yang tidak

seimbang. Namun, ini juga sesuai untuk situasi di mana kita lebih tertarik pada kinerja model secara keseluruhan daripada kinerja kelas tertentu.

4. *F1-Score*

F-Score atau *F1-Score* adalah metrik evaluasi yang menggabungkan presisi (*precision*) dan *recall* menggunakan *harmonic mean*. *Harmonic mean* dipilih karena lebih sensitif terhadap nilai yang rendah, sehingga *F-Score* memberikan penilaian yang seimbang antara presisi dan *recall*. Ini sangat bermanfaat ketika kita ingin menyeimbangkan kedua metrik tersebut, terutama ketika *False Positive* (FP) dan *False Negative* (FN) memiliki konsekuensi yang signifikan. Tiga metode untuk menghitung *F-Score* adalah *F1-Score* per kelas, *macro-average F1-Score*, dan *micro-average F1-Score*. Bergantung pada tujuan evaluasi dan karakteristik dataset, masing-masing metode memiliki peran dan manfaat yang berbeda.

a) *F1-Score* per Kelas (*Class F1-Score*)

Berikut merupakan persamaan untuk menghitung *F1-Score*.

$$F_1(C_i) = 2 \cdot \frac{R(C_i) \cdot P(C_i)}{R(C_i) + P(C_i)} \quad (12)$$

Keterangan:

$R(C_i)$ = nilai *recall* untuk setiap kelas C_i .

$P(C_i)$ = nilai *precision* untuk setiap kelas C_i .

Untuk menghitung *F1-Score* spesifik untuk setiap kelas, rumus ini berguna ketika ingin mengevaluasi performa model pada kelas tertentu dengan mempertimbangkan keseimbangan antara *presisi* dan *recall*. Misalnya, ketika ingin memastikan bahwa model memiliki *F-Score* yang baik untuk kelas minoritas dalam dataset yang tidak seimbang.

b) *Macro-Average F1-Score*

Berikut merupakan persamaan untuk menghitung *Macro-Average F1-Score*.

$$F_1(\text{macro}) = \frac{\sum F_1(C_i)}{N} \quad (13)$$

Keterangan:

$\sum F_1(C_i)$ = F1-Score untuk setiap kelas C_i .

N = Jumlah Kelas.

Macro-average F1-Score menghitung skor rata-rata dari semua kelas tanpa mempertimbangkan distribusi sampel di masing-masing kelas. Terlepas dari jumlah sampel yang digunakan, setiap kelas diperlakukan dengan cara yang sama. Metode ini berguna dalam situasi di mana kita ingin memberikan nilai yang sama kepada semua kelas, terutama dalam dataset yang seimbang atau ketika kelas minoritas dan kelas mayoritas sama pentingnya.

c) *Micro-Average F1-Score*

Berikut merupakan persamaan untuk menghitung *Micro-Average F1-Score*.

$$F_1(\text{micro}) = 2 \cdot \frac{R(\text{micro}) \cdot P(\text{micro})}{R(\text{micro}) + P(\text{micro})} \quad (14)$$

Keterangan;

$R(\text{macro})$ = nilai *recall* pada *micro-average*.

$P(\text{macro})$ = nilai *precision* pada *micro-average*.

Micro-average F1-Score menghitung skor *F1-global* dengan menggabungkan semua Nilai *True Positif* (TP), Nilai *False Negatif* (FN) dari semua kelas. Metode ini memprioritaskan kelas dengan jumlah sampel yang lebih besar, yang membuatnya sesuai untuk dataset yang tidak

seimbang. Namun, ini juga sesuai untuk situasi di mana kita lebih tertarik pada kinerja model secara keseluruhan daripada kinerja kelas tertentu.

Dengan memahami *multiclass confusion matrix* secara lebih mendalam, model klasifikasi dapat dievaluasi dengan lebih akurat, terutama dalam skenario yang melibatkan banyak kategori (Markoulidakis *et al.*, 2021).

2.14 Ekstraksi Fitur

Ekstraksi fitur adalah proses untuk mengubah data mentah menjadi representasi yang lebih ringkas dan informatif, sehingga memudahkan proses analisis, pengenalan pola, atau klasifikasi. Ini merupakan langkah penting dalam berbagai bidang seperti pengolahan citra, sinyal, teks, dan data ilmiah lainnya (Winkler *et al.*, 2020). Beberapa metode ekstraksi fitur yang sering digunakan pada data citra adalah sebagai berikut.


2.14.1 Ekstraksi fitur warna

Ekstraksi warna merupakan proses untuk memperoleh fitur atau parameter dari informasi warna dalam sebuah citra digital, yang bertujuan untuk mendeskripsikan dan membedakan objek berdasarkan karakteristik warnanya. penggunaan ruang warna seperti RGB, HSV, dan CIE Lab dapat meningkatkan kestabilan dan keefektifan ekstraksi karena mampu menampilkan karakteristik warna secara lebih stabil, terutama dalam menghadapi variasi pencahayaan dan sudut pandang (Cernadas *et al.*, 2017). Metode ekstraksi warna meliputi histogram warna yang menghitung distribusi frekuensi piksel berdasarkan nilai warna tertentu, serta fitur statistik warna seperti mean, varians, dan kurtosis saluran warna, yang dapat digunakan secara kombinasi untuk menggambarkan gambar secara lebih lengkap (Ledoux *et al.*, 2016). Namun, tantangan utama ekstraksi adalah sensitivitas terhadap perubahan lingkungan dan pencahayaan, sehingga diperlukan prapemrosesan, seperti normalisasi dan konversi ke area peringatan yang lebih stabil (Humeau-Heurtier, 2022). Secara umum, Ekstraksi fitur warna telah digunakan secara luas dalam pengenalan tekstur permukaan, penilaian kualitas bahan, klasifikasi citra medis, dan pencarian citra berbasis konten (CBIR), di mana

karakteristik warna menjadi komponen utama yang meningkatkan performa sistem pengolahan citra (Humeau-Heurtier, 2022).

2.14.2 Ekstraksi fitur tekstur menggunakan *Gray-Level Co-occurrence Matrix* (GLCM)

Gray-Level Co-occurrence Matrix (GLCM) adalah metode statistik yang digunakan untuk mengekstraksi fitur tekstur dari citra digital dengan menghitung probabilitas kemunculan pasangan intensitas piksel tertentu yang berdekatan dalam jarak dan arah tertentu, seperti sudut 0° , 45° , 90° , dan 135° , kemudian fitur seperti *Contrast*, *Correlation*, *Energy*, dan *Homogeneity* dihitung dari matriks ini untuk merepresentasikan karakteristik tekstur citra secara statistik (T3) (Amalia, 2018). Gambar berikut memperlihatkan empat arah untuk GLCM.



Gambar 20. Contoh Arah untuk GLCM sudut 0° , 45° , 90° , dan 135° (Talib *et al.*, 2024)

Setelah itu, matriks GLCM dibangun dengan menghitung jumlah kemunculan pasangan piksel yang sesuai dengan jarak dan sudut yang ditentukan. Dari matriks ini, berbagai fitur tekstur dapat dihitung, seperti *Contrast* yang mengukur tingkat variasi intensitas lapisan keabuan, *Correlation* yang menunjukkan hubungan *linier* antara piksel tetangga, *Energy* yang merepresentasikan tingkat homogenitas citra, serta *Homogeneity* yang mengukur kedekatan nilai elemen GLCM ke diagonal utama. Fitur-fitur ini sangat berguna dalam proses klasifikasi dan pengenalan pola karena mampu merepresentasikan karakteristik tekstur secara statistik dan kuantitatif (T2, T3). (Ullu *et al.*, 2022). Setelah matriks GLCM dibangun, beberapa fitur tekstur utama dapat dihitung dengan rumus sebagai berikut.

1. Contrast

Contrast (Kontras) mengukur variasi intensitas piksel yang berdekatan:

$$Contrast = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} (i - j)^2 \cdot P(i, j) \quad (15)$$

2. Correlation

Correlation (Korelasi) mengukur hubungan linier antar piksel dalam pasangan:

$$Correlation = \frac{\sum_{i,j} (i - \mu_i)(j - \mu_j) \cdot P(i,j)}{\sigma_i} \quad (16)$$

3. Energy

Energy (Energi) menunjukkan homogenitas dan keseragaman tekstur:

$$Energy = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} (i - j)^2 P(i, j)^2 \quad (17)$$

4. Homogeneity

Homogeneity (Kedekatan diagonal) mengukur seberapa dekat elemen matriks GLCM ke diagonal utama:

$$Homogeneity = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} \frac{P(i,j)}{1 + |i - j|} \quad (18)$$

Keterangan:

- a. $P(i, j)$ adalah nilai elemen matriks GLCM pada posisi (i, j) .
- b. N adalah jumlah level intensitas pada citra (misal 256 atau sesuai skala).
- c. μ_i, μ_j adalah rata-rata nilai intensitas pada baris dan kolom.
- d. σ_i, σ_j adalah standar deviasi pada baris dan kolom.

Menurut penelitian yang dilakukan oleh Lamasigi (2021), ekstraksi fitur GLCM telah terbukti efektif dalam membedakan pola tekstur pada berbagai jenis citra, termasuk batik dan tenun, serta mampu meningkatkan akurasi dalam proses sistem pengenalan pola. Oleh karena itu, metode GLCM sangat populer dan sering digunakan dalam bidang pengolahan citra untuk analisis tekstur karena kemampuannya menghasilkan fitur yang spesifik dan mudah diimplementasikan (T1).

2.14.3 Ekstraksi fitur tekstur menggunakan LBP (*Local Binary Pattern*)

Kemampuan *Local Binary Pattern* (LBP) untuk secara efektif menangkap properti lokal dari permukaan objek membuatnya menjadi teknik deskripsi tekstur yang populer dalam pemrosesan gambar digital. LBP membandingkan nilai intensitas piksel inti dengan nilai intensitas piksel tetangganya dalam radius tertentu. Jika intensitas setiap piksel di sekitarnya lebih tinggi atau sama dengan intensitas piksel pusat, piksel tersebut diberi nilai 1; jika tidak, maka diberi nilai 0. Struktur tekstur lokal kemudian diwakili oleh nilai desimal yang berasal dari pola biner yang dihasilkan (Barburiceanu *et al.*, 2021). *Output* dari proses ini adalah *histogram* yang menunjukkan frekuensi kemunculan pola-pola LBP pada citra. Histogram ini merupakan fitur yang digunakan dalam proses klasifikasi atau pengenalan pola. Keunggulan LBP disebabkan oleh ketahanannya terhadap perubahan pencahayaan lokal (*grayscale invariance*) dan kompleksitas komputasi yang tinggi, sehingga cocok digunakan untuk aplikasi real-time dan sistem dengan daya sumber yang lebih rendah (Singh, 2020). LBP juga dapat digunakan dengan metode ekstraksi fitur lainnya, seperti GLCM (*Gray Level Co-occurrence Matrix*), untuk meningkatkan representasi fitur dan akurasi klasifikasi. Dalam konteks pengenalan pola pada citra daun atau kulit tanaman, LBP dapat digunakan untuk mendeskripsikan kondisi sehat dan tidak sehat (Kaplan *et al.*, 2020).

2.14.4 Ekstraksi fitur bentuk

Ekstraksi fitur bentuk digunakan untuk membedakan bentuk satu objek dengan bentuk objek lainnya. Pada pengenalan pola objek pada citra, fitur bentuk yang dapat digunakan adalah *eccentricity* dan *metric* (Rachmawanto, 2018). Dua fitur bentuk yang sering digunakan dalam penelitian adalah *eccentricity* dan *metric*. *Eccentricity* mengukur tingkat kelonggaran suatu objek dan didefinisikan sebagai rasio antara jarak antara fokus-fokus elips terhadap panjang sumbu utama elips yang mengelilingi objek. Nilai *eccentricity* berkisar antara 0 hingga 1, di mana nilai mendekati 0 menunjukkan bentuk objek yang hampir melingkar, sedangkan nilai mendekati 1 menunjukkan objek yang lebih lonjong atau memanjang (Widians *et al.*, 2019). *Metric* merupakan ukuran kebulatan suatu objek yang dihitung

berdasarkan luas (*area*) dan keliling (*perimeter*) dari objek tersebut. Rumus yang digunakan adalah.

$$M = \frac{4\pi A}{P^2} \quad (19)$$

Dimana M adalah *metric*, A adalah *area*, dan P adalah *perimeter*.

Nilai *metric* juga berada pada rentang antara 0 hingga 1, di mana nilai yang mendekati 1 mengindikasikan bahwa objek memiliki bentuk mendekati lingkaran sempurna. Sebaliknya, nilai lebih kecil menunjukkan bentuk yang tidak simetris atau menyimpang dari bentuk lingkaran (Fansyuri & Yunita, 2022).

III. METODE PENELITIAN

3.1 Tempat dan Waktu

Penelitian ini dilakukan di Laboratorium Komputasi Jurusan Ilmu Komputer Fakultas Matematika dan Ilmu Pengetahuan Alam yang beralamat di Jalan Soemantri Brodjonegoro No.1 Gedung Meneng, Bandar Lampung. Di mulainya proyek penelitian ini adalah Oktober 2024 – April 2025.

3.2 Alat dan Bahan

Alat dan bahan yang digunakan dalam penelitian ini adalah *hardware* dan *software* sebagai berikut.

3.2.1 *Hardware*

Hardware yang digunakan dalam penelitian ini adalah Laptop Dell Inc dengan spesifikasi sebagai berikut.

1. *Processor* : Intel Core i7-6500U
2. *Installed* : RAM 8 GB
3. *System Type* : 64-bit operating system, x64 – based processor

3.2.2 *Software*

Software yang digunakan dalam penelitian ini antara lain sebagai berikut.

1. Sistem operasi Windows 10
2. Tools: *Google Colab*, untuk menjalankan kode secara *cloud*, *Python* sebagai bahasa pemrograman utama dan *Google Drive* sebagai penyimpanan dataset.

3.2.3 Library

Library yang digunakan dalam penelitian ini diantaranya sebagai berikut.

1. *NumPy*

NumPy adalah salah satu pustaka yang paling populer untuk komputasi ilmiah. Pustaka *numpy* menyediakan operasi matematika pada larik dan matriks serta fungsi-fungsi dalam pustaka *Open cv* (Sundaram *et al*, 2023).

2. *Scikit-learn*

scikit-learn adalah sebuah *library* di *Python* yang mendukung berbagai algoritma pembelajaran mesin seperti klasifikasi, regresi, dan pengelompokan. Selain itu, ia juga menyediakan alat untuk memilih dan mengevaluasi model (Sundaram *et al.*, 2023).

3. *Scikit-image*

Scikit-image atau *skimage* dirancang untuk mempermudah pemrosesan gambar di *python*. Pengolahan gambar di *python*, terutama bagi mereka yang sudah terbiasa dengan *tools python*. Salah satu cara untuk mencapai hal ini adalah dengan menggunakan larik *NumPy* standar sebagai dasar representasi dasar dari gambar yang memungkinkan akses langsung ke piksel (van *et al.*, 2014).

4. *TensorFlow*

TensorFlow di *Python* menyediakan dukungan untuk berbagai macam pembelajaran mesin dan algoritma pembelajaran mendalam. Algoritma program ini mencakup berbagai alat, termasuk alat untuk mengevaluasi dan menerapkan model, serta alat untuk membuat dan melatih jaringan syaraf (Sundaram *et al.*, 2023). Program ini mencakup berbagai alat, termasuk alat untuk mengevaluasi dan menerapkan model, serta alat untuk membuat dan melatih jaringan syaraf (Sundaram *et al.*, 2023).

5. Keras

Keras adalah pustaka jaringan saraf tiruan tingkat tinggi berbasis *Python* pustaka jaringan saraf tingkat tinggi berbasis *Python* yang digunakan di platform *TensorFlow*, *Theano*, dan CNTK untuk membangun jaringan saraf tiruan yang kuat. Keras memiliki antar muka yang mudah digunakan, yang membuat proses pembangunan model *deep learning* menjadi lebih sederhana (Sundaram *et al.*, 2023).

6. Joblib

Joblib adalah serangkaian alat untuk menyediakan *pipelining* ringan di *Python*, khususnya untuk *caching* transparan dan komputasi paralel. Ini sangat berguna saat bekerja dengan model pembelajaran mesin besar atau *array numpy* yang besar (Baldanulla *et al.*, 20203).

7. Matplotlib

Pustaka *Matplotlib* di *Python* digunakan untuk membuat visualisasi statis, animasi, dan visualisasi interaktif menggunakan *Python*. Pustaka ini menyediakan berbagai jenis grafik yang yang dapat disesuaikan dan tersedia untuk berbagai format (Sundaram *et al.*, 2023).

V. PENUTUP

5.1 Simpulan

Dari hasil penelitian yang telah dilakukan, dapat ditarik beberapa kesimpulan utama sebagai berikut.

1. Model *convolutional neural network* berhasil dibangun dengan arsitektur terbaik yaitu arsitektur *InceptionV3* pada skema 3 yaitu pembagian data Rasio 80%:10%:10%. Hasil evaluasi menunjukkan bahwa CNN memiliki akurasi yang sangat baik, sebesar 0.9752 pada *Binnary Classification* dan 0.9636 pada *Multiclass Classification* menjadikannya sebagai metode yang cukup efektif untuk tugas deteksi dan klasifikasi penyakit pada daun tebu.
2. Model SVM juga berhasil dikembangkan dan diuji dalam tugas deteksi dan klasifikasi penyakit pada daun tebu SVM menunjukkan performa yang baik, dengan menggunakan Kernel *RBF* pada skema 3 yaitu pembagian data Rasio 80%:10%:10%, memperoleh akurasi sebesar 0.9706 pada *Binnary Classification*, dan menggunakan kernel *linear* sebesar 0.9080 pada *Multiclass Classification*. Meskipun hasilnya di bawah performa CNN dalam hal akurasi model SVM tetap memberikan kontribusi signifikan dengan hasil yang cukup konsisten untuk deteksi penyakit pada daun tebu.
3. Berdasarkan evaluasi, CNN memiliki performa yang lebih baik daripada SVM dalam hal *accuracy*, *percision*, *recall*, dan *f1-score*. Perbandingan dengan penelitian sebelumnya juga menunjukkan bahwa CNN adalah metode yang lebih efektif untuk mengklasifikasikan penyakit pada daun tebu, mengungguli metode lain yang sebelumnya digunakan.

5.2 Saran

Adapun saran yang diberikan dalam penelitian ini meliputi hal hal sebagai berikut.

1. Penelitian selanjutnya dapat membandingkan model dengan set data yang lebih besar dan lebih beragam untuk meningkatkan akurasi dan generalisasi model.
2. Teknik optimasi *hyperparameter* yang lebih lanjut dapat digunakan untuk meningkatkan efisiensi kerja model.
3. Melanjutkan penelitian dengan membandingkan model lain dengan pendekatan *deep learning* yang lebih modern dapat memberikan perspektif tambahan dan mungkin meningkatkan performa dalam klasifikasi penyakit pada daun tebu.

DAFTAR PUSTAKA

- Adib, I. T. A., Sari, B. N., and Padilah, T. N. "Evaluasi Augmentasi Data pada Deteksi Penyakit Daun Tebu dengan YOLO v8." *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 8, no. 4, 2024, pp. 7547–7552. <https://doi.org/10.36040/jati.v7i3.7047>
- Adrian, R., Nasamsir, & Meilin, A. (2019). Survei serangan hama pada perkebunan tebu (*Saccharum officinarum L.*) di Provinsi Jambi. *Jurnal Media Pertanian*, 4(1), 1–7.
- Ali, M. W., Smith, John, & Zhang, Li. (2024). Non-contact breath rate classification using SVM model and mmWave radar sensor data. *arXiv*. <https://doi.org/10.5281/zenodo.1234567>
- Alzubaidi, L., Zhang, J., Humaidi, A.J. (2021). Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. *J Big Data* 8,53 <https://doi.org/10.1186/s40537-021-00444-8>
- Agarwal, K., & Singh, T. (2022). Classification of skin cancer images using convolutional neural networks. *ArXiv Preprint ArXiv:2202.00678*.
- Amalia, I. (2018). Ekstraksi fitur citra songket berdasarkan tekstur menggunakan metode Gray Level Co-occurrence Matrix (GLCM). *Jurnal Infomedia*, 3(2), 64–68. <https://doi.org/10.30811/jim.v3i2.715>
- Amrulloh, I. A., Sari, B. N., & Padilah, T. N. (2024). Evaluasi augmentasi data pada deteksi penyakit daun tebu dengan YOLOv8. *JATI: Jurnal Mahasiswa Teknik Informatika*, 8(4), 7547-7552.
- Anuradha, Kashyap, L., Kumar, R., & Singh, P. (2019). Sugarcane Grassy Shoot (SCGS) Disease – An Overview. *Indian Journal of Pure and Applied Biosciences*, 7(4), 371-378. Doi: 10.18782/2320-7051.7670.

- Anuradha, S., Suresh, S., & Reddy, M. S. (2019). Grassy Shoot Disease of Sugarcane: Etiology, Symptoms, and Management. *Sugar Tech*, 21(5), 1–10. <https://doi.org/10.1007/s12355-019-00710-0>
- Ardiansyah, & Hasan, N. F. (2023). Deteksi dan Klasifikasi Penyakit Pada Daun Kopi Menggunakan Yolov7. *Jurnal SISFOKOM (Sistem Informasi dan Komputer)*, 12(1), 30-35. <https://doi.org/10.32736/sisfokom.v12i1.1545>
- Ashraf, M., Abid, F., Ud Din, I., & Rasheed, J. (2023). A Hybrid CNN and RNN Variant Model for Music Classification. *Applied Sciences*, 13(3), 1476. <https://doi.org/10.3390/app13031476>
- Ayun, Q., Kurniawan, S., & Saputro, W. A. (2020). Perkembangan konversi lahan pertanian di bagian negara agraris. *VIGOR: Jurnal Ilmu Pertanian Tropika dan Subtropika*, 5(2), 38-44. <https://jurnal.untidar.ac.id/index.php/vigor/article/view/304>
- Ayumaya, I. G., & Kurnia, M. S. (2018, 13 Maret). Tebu (*Saccharum officinarum* Linn). Diakses dari <https://distan.bulelengkab.go.id/informasi/detail/artikel/tebu-saccharum-officinarum-linn-12>
- Azizah, S., Pradana, A. I., & Hartanti, D. (2024). Identifikasi Kesehatan Daun Tanaman Padi Menggunakan Klasifikasi Biner Sehat dan Tidak Sehat dengan Algoritma Convolutional Neural Network (CNN) Di Kabupaten Klaten. *Komputika: Jurnal Sistem Komputer*, 13(2), 173-181. <https://doi.org/10.34010/komputika.v13i2.12771>
- Badan Pusat Statistik. (2023). Statistik Tebu Indonesia 2022. Diakses dari <https://www.bps.go.id/id/publication/2023/11/30/3296e8514178dfdad17fc500/statistik-tebu-indonesia-2022.html>
- Baldanullah, N. I. S., Mulyarizki, N., Permatasari, I., Naufal, I. P., & Pratama, D. C. (2023). Parallel processing pada pemodelan machine learning menggunakan random forest. *Journal of Informatics and Advanced Computing (JIAC)*, 4(1), Mei 2023.
- Barburiceanu, S., Terebes, R., & Meza, S. (2021). 3D Texture Feature Extraction and Classification Using GLCM and LBP-Based Descriptors. *Applied Sciences*, 11(5), 2332. <https://doi.org/10.3390/app11052332>

- Berhane, T., Melese, T., Waleign, A., & Mohammed, A. (2023). A hybrid convolutional neural network and support vector machine-based credit card fraud detection model. *Mathematical Problems in Engineering*, 2023, Article ID 8134627. <https://doi.org/10.1155/2023/8134627>
- Bertasello, L. E. T., da Silva, M. F., Pinto, L. R., Nóbile, P. M., Carmo-Sousa, M., Dos Anjos, I. A., Perecin, D., Spotti Lopes, J. R., & Gonçalves, M. C. (2023). Yellow leaf disease resistance and *Melanaphis sacchari* preference in commercial sugarcane cultivars. *Plants (Basel, Switzerland)*, 12(17), 3079. <https://doi.org/10.3390/plants12173079>
- Cernadas, E., Fernández-Delgado, M., González-Ruño, E., & Carrión, P. (2017). Influence of normalization and color space to color texture classification. *Pattern Recognition*, 61, 120–138. <https://doi.org/10.1016/j.patcog.2016.07.022>
- Cui, J., Tao, D., Tao, L., Liu, R., & Yu, C. (2024). *Analytic convolutional layer: A step to analytic neural network*. arXiv. <https://doi.org/10.48550/arxiv.2407.06087>
- Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20(3), 273–297. <https://doi.org/10.1007/BF00994018>
- Fathi, S., & Moaberfard, Z. (2022). A new trigonometric kernel function for support vector machine. *Iran Journal of Computer Science*, 6(137–145). <https://doi.org/10.1007/s42044-022-00130-9>
- Fansyuri, M., & Yunita, D. (2022). Identifikasi jenis buah apel berdasarkan ekstraksi ciri bentuk dan warna. *Jurnal Open Access Informatika dan Ilmu Artificial (JOAIIA)*, 1(1)
- Farhad, M., Perumal, T., Mustapha, N., & Mohamed, R. (2023). A Comprehensive Overview and Comparative Analysis on Deep Learning Models: CNN, RNN, LSTM, GRU. *arXiv preprint arXiv:2305.17473*. <https://arxiv.org/abs/2305.17473>
- Gupta, P. (2023). Leveraging Machine Learning and Artificial Intelligence for Fraud Prevention. *SSRG International Journal of Computer Science and Engineering*, 10(5), 47-52. <https://doi.org/10.14445/23488387/IJCSE-V10I5P107>

- He, K., Zhang, X., Ren, S., & Sun, J. (2015). Deep residual learning for image recognition. *In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (pp. 770-778). <https://doi.org/10.1109/CVPR.2016.90>
- Humeau-Heurtier, A. (2022). Color texture analysis: A survey. *IEEE Access*, 10, 111291–111319. <https://doi.org/10.1109/ACCESS.2022.3214919>
- Indrawanto, C., Purwono, Siswanto, Syakir, M., Rumini, W. (2010). Budidaya dan Pasca Panen Tebu. Pusat Penelitian dan Pengembangan Perkebunan. Diakses dari <https://repository.pertanian.go.id/items/ae64b5e4-d2d5-4fff-a832-3f42afaaa960>
- Ikhwanul Akhmad DLY, Jasril, Sanjaya, S., Handayani, L., & Yanto, F. (2023). Klasifikasi citra daging sapi dan babi menggunakan CNN Alexnet dan augmentasi data. *Journal of Information System Research (JOSH)*, 4(4), 1176–1185. <https://doi.org/10.47065/josh.v4i4.3702>
- Iqbal, H., Sarker. (2021). Machine Learning: Algorithms, Real-World Applications and Research Directions. 2(3), 160-160. Doi: 10.1007/S42979-021-00592X
- Jeczminek, E., & Kowalski, P. A. (2021). Flattening layer pruning in convolutional neural networks. *Symmetry*, 13(1147), 1-13. <https://doi.org/10.3390/sym13071147>
- Jiantono, A. C. (2023, 18 Juli). Mengenal Deep Learning Beserta Contoh Penerapannya. Diakses pada 27 Oktober 2024, dari Mengenal Deep Learning Beserta Contoh Penerapannya – *School of Information Systems*
- Kaplan, K., Kaya, Y., Kuncan, M., Minaz, M. R., & Ertunç, H. M. (2020). An Improved Feature Extraction Method Using Texture Analysis with LBP for Bearing Fault Diagnosis. *Applied Soft Computing*, 87, 106019. <https://doi.org/10.1016/j.asoc.2019.106019>
- Krinsawan, Y. J., & Setiawan, W. (2024). Implementasi Convolutional Neural Network (CNN) untuk Deteksi Katarak pada Citra Mata. *Jurnal Ekonomi Manajemen Sistem Informasi (JEMSI)*, 6(1). <https://doi.org/10.83035/jemsi.v6i1>
- Khuimphukhieo, I., Marconi, T. G., Enciso, J., & da Silva, J. A. (2023). The use of UAS-based high-throughput phenotyping (HTP) to assess sugarcane yield.

Journal of Agriculture and Food Research, 11, 100501.
<https://doi.org/10.1016/j.jafr.2023.100501>

Kursun, R., Yasin, E. T., & Koklu, M. (2024). Classification of sugarcane leaf disease with AlexNet model. In *Proceedings of the 2nd International Conference on Intelligent Systems and New Applications (ICISNA '24)*.
<https://doi.org/10.58190/icisna.2024.86>

Kotu, V., & Deshpande, B. (2019). Data science: Concepts and practice. *Elsevier*.
<https://www.elsevier.com/books/data-science/kotu/9780128147627>

Lamasigi, Z. Y. (2021). DCT untuk ekstraksi fitur berbasis GLCM pada identifikasi batik menggunakan K-NN. *Jambura Journal of Electrical and Electronics Engineering (JJEEE)*, 3(1), 1–6. <https://doi.org/10.37905/jjee.v3i1.7113>

Ledoux, A., Losson, O., & Macaire, L. (2016). Color local binary patterns: Compact descriptors for texture classification. *Journal of Electronic Imaging*, 25(6), Article 061404. <https://doi.org/10.1117/1.JEI.25.6.061404>

Li, L., Chen, Y., Shen, Z., Zhang, X., Sang, J., Ding, Y., Yang, X., Li, J., Chen, M., Jin, C., Chen, C., & Yu, C. (2019). Convolutional neural network for the diagnosis of early gastric cancer based on magnifying narrow band imaging. *Gastric Cancer*. <https://doi.org/10.1007/s10120-019-00992-2>

Liang, K.-L.; Liu, J.-Y.; Bao, Y.-Y.; Wang, Z.-Y.; Xu, X.-B. Screening and Identification of Host Factors Interacting with the Virulence Factor P0 Encoded by Sugarcane Yellow Leaf Virus by Yeast Two-Hybrid Assay. *Genes* 2023, 14, 1397. <https://doi.org/10.3390/genes14071397>

Markoulidakis, I., Rallis, I., Georgoulas, I., Kopsiaftis, G., Doulamis, A., & Doulamis, N. (2021). Multiclass Confusion Matrix Reduction Method and Its Application on Net Promoter Score Classification Problem. *Technologies*, 9(4). <https://doi.org/10.3390/technologies9040081>

Mahesh, B. (2020). Machine Learning Algorithms – A Review. *International Journal of Science and Research (IJSR)*, 9(1). <https://doi.org/10.21275/ART20203995>

Mahfut, M., Kendari, P., Bangsawan, R., & Susiyanti, E. (2024). Agronomic characteristics of sugarcane cultivar GMP3 mutants induced through colchicine. *SABRAO Journal of Breeding and Genetics*, 56(3), 1083–1094. <https://doi.org/10.54910/sabrao2024.56.3.16>

- Mentari, M., Ginardi, R.V.H., & Fatichah, C. (2025). Segmentasi Penyakit pada Citra Daun Tebu Menggunakan Fuzzy C Means – Support Vector Machine dengan Fitur Warna a. *Jurnal Teknik Informatika*, Institut Teknologi Sepuluh Nopember
- Militante, S. V., & Gerardo, B. D. (2019). Detecting sugarcane diseases through adaptive deep learning models of convolutional neural network. *2019 IEEE 6th International Conference on Engineering Technologies and Applied Sciences (ICETAS)*. <https://doi.org/10.1109/ICETAS48360.2019.9117332>
- Nahr, J. G., Nozari, H., & Sadeghi, M. E. (2021). Artificial intelligence and Machine Learning for Real-world problems (A survey). *International Journal of Innovation in Engineering*, 1(3), 38–47. <https://doi.org/10.59615/ijie.1.3.38>
- Norhikmah, R., Lutfhi, A., & Rumini. (2022). The effect of layer batch normalization and dropout of CNN model performance on facial expression classification. *JOIV: International Journal on Informatics Visualization*, 6(2-2), 481-488. <https://doi.org/10.30630/joiv.6.2-2.921>
- Oktafiani, R., Hermawan, A., & Avianto, D. (2023). Pengaruh Komposisi Split Data Terhadap Performa Klasifikasi Penyakit Kanker Payudara Menggunakan Algoritma *Machine Learning*. *Jurnal Sains dan Informatika*, 9(1).
- Pudupet, S., & Paranjothi, S. (2024). Kecerdasan Buatan untuk Monitoring Hama dan Penyakit pada Tanaman: Tinjauan dan Aplikasi. *Jurnal Ilmu dan Teknologi Hasil Ternak*, 19(1), 1–10. <https://doi.org/10.21776/ub.jitkt.2024.19.1.1>
- Putra, N. A. E., & Agustin, S. (2020). Klasifikasi Kematangan Tebu Berdasarkan Tekstur Batang Menggunakan Metode Naïve Bayes. *Indexia: Informatics and Computational Intelligent Journal*, 2(2), 23–38. <https://doi.org/10.30587/indexia.v2i2.2559>
- Praghakusuma, A. Z., & Charibaldi, N. (2021). Komparasi Fungsi Kernel Metode Support Vector Machine untuk Analisis Sentimen Instagram dan Twitter (Studi Kasus: Komisi Pemberantasan Korupsi). *Jurnal Sarjana Teknik Informatika*, 9(2), 33–42.
- Prasetya, I. A., Sukandiarasyah, F., Fitri, N. A., & Adam, S. (2024). Klasifikasi kualitas buah jeruk menggunakan computer vision dengan arsitektur YOLO

- V8. *Jurnal Pendidikan Informatika dan Sains*, 13(2), 187–201.
<https://journal.upgripnk.ac.id/index.php/saintek/article/view/8346/3052>
- Pratitis, W. L., Kurniasari, K., & Al Fata, H. (2023). Classification of Spotted Disease on Sugarcane Leaf Image Using Convolutional Neural Network Algorithm. *Jurnal Sistem Telekomunikasi Elektronika Sistem Kontrol Power Sistem dan Komputer*, 3(2), 117-128.
- Rajput, M.A., Rajput, N.A., Syed, R.N., Lodhi, A.M & Que, Y. Sugarcane Smut: Current Knowledge and the Way Forward for Management. *J. Fungi* 2021, 7, 1095. <https://doi.org/10.3390/jof7121095>
- Rahmad, D. (2021). Uji patogenitas cendawan pendegradasi bahan organik pada bibit tanaman tebu (*Saccharum officinarum*). *J. Agrolantae*, 10(2), 76-84.
<https://ppnp.e-journal.id/agro/article/view/296>
- Rachmawanto, E. H., Anarqi, G. R., Setiadi, D. R. I. M., & Sari, C. A. (2018). Handwriting recognition using eccentricity and metric feature extraction based on K-nearest neighbors. *2018 International Seminar on Application for Technology of Information and Communication (iSemantic)*.
<https://doi.org/10.1109/ISEMANTIC.2018.8549804>
- Ratnasari, R., Ginardi, A., & Fatichah, C. (2014). Pengenalan penyakit noda tanaman tebu berdasarkan ciri tekstur Fractal Dimension Co-Occurrence Matrix (FDCM) dan Lab Color Moments. *JUTI: Jurnal Ilmiah Teknologi Informasi*, 12(2), 27–36.
- Ravichandran, V., Saravanan, P. A., Veeramani, P., Velmurugan, M., Ganapathy, S., Jayakumar, J., & Raguchander, T. (2023). Biosuppression of sugarcane sett rot disease (*Ceratocystis paradoxa*) with *Chaetomium globosum*. *The Pharma Innovation Journal*, 12(7), 2330–2334.
- Rezende, D. E., Ribeiro, R. V., Machado, D. F. S. P., & Machado, E. C. (2022). Physiological responses of sugarcane genotypes to progressive drought stress. *Agricultural Water Management*, 261, 107379.
<https://doi.org/10.1016/j.agwat.2021.107379>
- Rizqiyah, N., Putra, L. K., & Astono, T. H. (2023). Observasi penyakit utama pada klon tebu unggul di PG Kribet Baru, Malang. *Jurnal Fitopatologi Indonesia*, 18(6), 231–238. <https://doi.org/10.14692/jfi.18.6.231-238>

- Roihan, A., Sunarya, P. A., & Rafika, A. S. (2020). Pemanfaatan machine learning dalam berbagai bidang. *Jurnal Khatulistiwa Informatika*, 5(1), 490845.
- Saha, S. (2018). *A Comprehensive Guide to Convolutional Neural Networks (CNNs)*. Diakses dari <https://towardsdatascience.com/a-comprehensive-guide-to-convolutional-neural-networks-the-eli5-way-3bd2b1164a53>
- Samsudiney, M. (2019, July 25). Penjelasan sederhana tentang apa itu SVM. *Medium*. <https://medium.com/%40samsudiney/penjelasan-sederhana-tentang-apa-itu-svm-149fec72bd02>
- Selvakumar, R., & Viswanathan, R. (2020). Sugarcane rust: Changing disease dynamics and its management. *Journal of Sugarcane Research*, 9(2), 97–118. <https://doi.org/10.37580/JSR.2019.2.9.97-118>
- Shah, S.R.; Qadri, S.; Bibi, H.; Shah, S.M.W.; Sharif, M.I.; Marinello, F. Comparing Inception V3, VGG 16, VGG 19, CNN, and ResNet 50: A Case Study on Early Detection of a Rice Disease. *Agronomy* 2023, 13, 1633. <https://doi.org/10.3390/agronomy13061633>
- Sharma, G., Singh, J., Arya, A., & Sharma, S.R. (2017). Biology and Management of Sugarcane Red Rot: A Review. *Plant Archives*, 17(2), 775-784
- Singh, R. (2020). Comparative Analysis of Texture Feature Extraction Techniques for Rice Grain Classification. *IET Image Processing*, 14(8), 1447–1454. <https://doi.org/10.1049/iet-ipr.2019.1055>
- Singh, S., & Malik, K. (2022). Feature selection and classification improvement of Kinnow using SVM classifier. *Measurement: Sensors*, 24, 100518. <https://doi.org/10.1016/j.measen.2022.100518>
- Srivastava, S., Kumar, P., Mohd, N., Singh, A., & Gill, F. S. (2020). A novel deep learning framework approach for sugarcane disease detection. *SN Computer Science*, 1, 1–7. <https://doi.org/10.1007/s42979-020-0094-9>
- Subekti, D., Hidayat, S. H., Damayanti, T. A., & Purwono, P. (2020). Penyebaran virus utama tebu di Lampung dan Sulawesi Selatan. *Jurnal Ilmu Pertanian Indonesia*, 25(1), 60–66. <https://doi.org/10.18343/jipi.25.1.60>
- Sugiarto, R. (2019). Klasifikasi jenis penyakit tebu menggunakan metode Naïve Bayes berdasarkan tekstur pada citra daun tebu (*Skripsi, Universitas Muhammadiyah Gresik*). Universitas Muhammadiyah Gresik Repository.

- Sundaram, J., Gowri, K., Devaraju, S., Gokuldev, S., Jayaprakash, S., Anandaram, H., Manivasagan, C., & Thenmozhi, M. (2023). *An Exploration of Python Libraries in Machine Learning Models for Data Science* (pp. 1–31). <https://doi.org/10.4018/978-1-6684-8696-2.ch001>
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., & Wojna, Z. (2015). Rethinking the Inception architecture for computer vision. *In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (pp. 2818-2826). <https://doi.org/10.1109/CVPR.2016.308>
- Talib, S., Sudin, S., & Suratin, M. D. (2024). Penerapan metode support vector machine (SVM) pada klasifikasi jenis cengkeh berdasarkan fitur tekstur daun. *Jurnal RESTIA*, 2(1), 17–27.
- Thineshkumar, J. (2023). Recent Advances in Control of Red Rot in Sugarcane – An Overview. *International Journal of Advanced Research in Science, Communication and Technology*, 3(2), 193-196. DOI:10.48175/IJARSCT-8378.
- Tiwari, R. (2020). Pokkah Boeng Disease of Sugarcane: Current Status and Opportunities. *Current Advances in Agricultural Sciences*, 12(1), 1-7. <https://doi.org/10.5958/2394-4471.2020.00001.5>
- Ullu, H. H., Baso, B., Risald, R., & Mitra, P. G. (2022). Ekstraksi fitur berbasis tekstur pada citra tenun Timor menggunakan metode Gray Level Co-occurrence Matrix (GLCM). *Journal of Information and Technology UNIMOR (JITU)*, 2(2), 70–74. <https://doi.org/10.32938/jitu.v2i2.3245>
- Vallin, J., Larsson, K., G. Larson, M. (2023). The geometric structure of fully-connected *ReLU*-layers. *arXiv*. <https://doi.org/10.48550/arxiv.2310.03482>
- Van der Walt, S., Schönberger, J. L., Nunez-Iglesias, J., Boulogne, F., Warner, J. D., Yager, N., Gouillart, E., & Yu, T. (2014). *scikit-image: Image processing in Python*. PeerJ, 2, e453. <https://doi.org/10.7717/peerj.453>
- Viswanathan, P. (2022). Emerging diseases of sugarcane and new disease management strategies. *Journal of Sugarcane Research*, 12, 1–15. <https://doi.org/10.37580/JSR.2022.1.12.1-15>
- Widians, J. A., Pakpahan, H. S., Budiman, E., Havaluddin, & Soleha, M. (2019). Klasifikasi jenis bawang menggunakan metode K-Nearest Neighbor

berdasarkan ekstraksi fitur bentuk dan tekstur. *Jurnal Rekayasa Teknologi Informasi (JURTI)*, 4(2)

- Winkler, C., Neidlin, M., Groß-Hardt, S., Breuer, J., Linden, K., & Herberg, U. (2020). Estimation of left ventricular stroke work based on a large cohort of healthy children. *Computers in Biology and Medicine*, 123, 103908. <https://doi.org/10.1016/j.combiomed.2020.103908>
- Wijaya, C., Irsyad, H., & Widhiarso, W. (2020). Klasifikasi Pneumonia Menggunakan Metode K-Nearest Neighbor Dengan Ekstraksi GLCM. *Jurnal Algoritme*, 1(1), 33–44. <https://doi.org/10.35957/algoritme.v1i1.431>
- Xiangming, Z., & Liangqu, L. (2022). Neural networks. In *Neural networks* (pp. 191–234). Springer. https://doi.org/10.1007/978-1-4842-7915-1_6
- Yudianto, M. R. A., Sukmasetya, P., Hasani, R. A., & Sasongko, D. (2022). Pengaruh Data Preprocessing terhadap Imbalanced Dataset pada Klasifikasi Citra Sampah menggunakan Algoritma Convolutional Neural Network. *Building of Informatics, Technology and Science (BITS)*, 4(3), 1367–1375. <https://doi.org/10.47065/bits.v4i3.2575>
- Yunizar, S. F. (2024). Klasifikasi penyakit daun tebu menggunakan algoritma convolutional neural network (CNN) dan support vector machine (SVM) (*Skripsi*). Universitas Pembangunan Nasional “Veteran” Jawa Timur.
- Zalvadila, A., Purnawansyah, L., Syafie, L., & Darwis, H. (2023). Klasifikasi Penyakit Tanaman Bawang Merah Menggunakan Metode SVM dan CNN. *Jurnal Informatika: Jurnal Pengembangan IT (JPIT)*, 8(3).
- Zeng, Y., Wei, Z., Yu, W., Yin, R., Yuan, Y., Li, B., Tang, Z., Lu, Y., & Yang, Y. (2022). Spatial transcriptomics prediction from histology jointly through Transformer and graph neural networks. *Briefings in Bioinformatics*, 23(5), bbac297. <https://doi.org/10.1093/bib/bbac297>
- Zhou, X., You, Z., Sun, W., Zhao, D., & Yan, S. (2024). Fractional-order stochastic gradient descent method with momentum and *Energy* for deep neural networks. *Neural Networks*, 137, 1–13. <https://doi.org/10.1016/j.neunet.2024.01.001>
- Zhou, Y., Fritz, M., & Keuper, M. (2024). *MultiMax: Sparse and multi-modal attention learning*. *arXiv*. <https://doi.org/10.48550/arxiv.2406.01189>

Zuhdi, K., Syaputra, B., Fazri, R., & Nugroho, S. P. (2024). Literatur review: Penggunaan Support Vector Machine untuk klasifikasi penyakit tanaman anggur. *Buletin Ilmiah Ilmu Komputer dan Multimedia (BIIKMA)*, 2(3), 532–53