

**TESIS**

**IDENTIFIKASI PENYAKIT TANAMAN JAGUNG BERDASARKAN  
CITRA DAUN MENGGUNAKAN CONVOLUTIONAL NEURAL  
NETWORK DAN SUPPORT VECTOR MACHINE**



Disusun oleh:

Nama : Bima Widlanto  
NIM : 21.52.2124  
Konsentrasi : Business Intelligence

**PROGRAM STUDI S2 TEKNIK INFORMATIKA  
PROGRAM PASCASARJANA UNIVERSITAS AMIKOM YOGYAKARTA  
YOGYAKARTA  
2024**

**TESIS**

**IDENTIFIKASI PENYAKIT TANAMAN JAGUNG BERDASARKAN  
CITRA DAUN MENGGUNAKAN CONVOLUTIONAL NEURAL  
NETWORK DAN SUPPORT VECTOR MACHINE**

**IDENTIFICATION OF CORN PLANT DISEASES BASED ON LEAF  
IMAGE USING CONVOLUTIONAL NEURAL NETWORK AND  
SUPPORT VECTOR MACHINE**

Diajukan untuk memenuhi salah satu syarat memperoleh derajat Magister



Disusun oleh:

Nama : Bima Widianto  
NIM : 21.52.2124  
Konsentrasi : Business Intelligence

**PROGRAM STUDI S2 TEKNIK INFORMATIKA  
PROGRAM PASCASARJANA UNIVERSITAS AMIKOM YOGYAKARTA  
YOGYAKARTA**

**2024**

## HALAMAN PENGESAHAN

**IDENTIFIKASI PENYAKIT TANAMAN JAGUNG BERDASARKAN CITRA DAUN  
MENGUNAKAN CONVOLUTIONAL NEURAL NETWORK DAN SUPPORT  
VECTOR MACHINE**

**IDENTIFICATION OF CORN PLANT DISEASES BASED ON LEAF IMAGE  
USING CONVOLUTIONAL NEURAL NETWORK AND SUPPORT VECTOR  
MACHINE**

Dipersiapkan dan Disusun oleh

**Bima Widianto**

**21.52.2124**

Telah Diujikan dan Dipertahankan dalam Sidang Ujian Tesis  
Program Studi S2 Teknik Informatika  
Program Pascasarjana Universitas AMIKOM Yogyakarta  
pada hari Jumat, 2 Februari 2024

Tesis ini telah diterima sebagai salah satu persyaratan  
untuk memperoleh gelar Magister Komputer

Yogyakarta, 2 Februari 2024  
**Rektor**

**Prof. Dr. M. Suvanto, M.M.**  
**NIK. 190302001**

## HALAMAN PERSETUJUAN

### IDENTIFIKASI PENYAKIT TANAMAN JAGUNG BERDASARKAN CITRA DAUN MENGUNAKAN CONVOLUTIONAL NEURAL NETWORK DAN SUPPORT VECTOR MACHINE

### IDENTIFICATION OF CORN PLANT DISEASES BASED ON LEAF IMAGE USING CONVOLUTIONAL NEURAL NETWORK AND SUPPORT VECTOR MACHINE

Dipersiapkan dan Disusun oleh

**Bima Widiyanto**

21.52.2124

Telah Diujikan dan Dipertahankan dalam Sidang Ujian Tesis  
Program Studi S2 Teknik Informatika  
Program Pascasarjana Universitas AMIKOM Yogyakarta  
pada hari Jumat, 2 Februari 2024

**Pembimbing Utama**

Prof. Dr. Ema Utami, S.Si., M.Kom.  
NIK. 190302037

**Anggota Tim Penguji**

Dr. Kumara Ari Yuana, S.T., M.T.  
NIK. 190302575

**Pembimbing Pendamping**

Dhani Ariatmanto, M.Kom., Ph.D.  
NIK. 190302197

Dr. Andi Sunyoto, M.Kom.  
NIK. 190302052

Prof. Dr. Ema Utami, S.Si., M.Kom.  
NIK. 190302037

Tesis ini telah diterima sebagai salah satu persyaratan  
untuk memperoleh gelar Magister Komputer

Yogyakarta, 2 Februari 2024  
**Direktur Program Pascasarjana**

Prof. Dr. Kusriani, M.Kom.  
NIK. 190302106

## HALAMAN PERNYATAAN KEASLIAN TESIS

Yang bertandatangan di bawah ini,

Nama mahasiswa : Bima Widianto  
NIM : 21.52.2124  
Konsentrasi : Business Intelligence

Menyatakan bahwa Tesis dengan judul berikut:  
**Identifikasi Penyakit Tanaman Jagung Berdasarkan Citra Daun  
Menggunakan Convolutional Neural Network Dan Support Vector Machine**

Dosen Pembimbing Utama : Prof. Dr. Ema Utami, S.Si., M.Kom.  
Dosen Pembimbing Pendamping : Dhani Ariatmanto, M.Kom., Ph.D.

1. Karya tulis ini adalah benar-benar ASLI dan BELUM PERNAH diajukan untuk mendapatkan gelar akademik, baik di Universitas AMIKOM Yogyakarta maupun di Perguruan Tinggi lainnya
2. Karya tulis ini merupakan gagasan, rumusan dan penelitian SAYA sendiri, tanpa bantuan pihak lain kecuali arahan dari Tim Dosen Pembimbing
3. Dalam karya tulis ini tidak terdapat karya atau pendapat orang lain, kecuali secara tertulis dengan jelas dicantumkan sebagai acuan dalam naskah dengan disebutkan nama pengarang dan disebutkan dalam Daftar Pustaka pada karya tulis ini
4. Perangkat lunak yang digunakan dalam penelitian ini sepenuhnya menjadi tanggung jawab SAYA, bukan tanggung jawab Universitas AMIKOM Yogyakarta
5. Pernyataan ini SAYA buat dengan sesungguhnya, apabila di kemudian hari terdapat penyimpangan dan ketidakbenaran dalam pernyataan ini, maka SAYA bersedia menerima SANKSI AKADEMIK dengan pencabutan gelar yang sudah diperoleh, serta sanksi lainnya sesuai dengan norma yang berlaku di Perguruan Tinggi

Yogyakarta, 02-Februari-2024

Yang Menyatakan,



M. FEBELAI  
M. FEBELAI  
BFAL3038427200

Bima Widianto

## HALAMAN PERSEMBAHAN

Dengan segala puji syukur kepada Allah SWT yang telah memberikan Rahmat dan Hidayah-Nya juga atas dukung serta doa dari orang-orang tercinta dan terkasih, akhirnya tesis ini mampu terselesaikan dengan baik. Dengan rasa bangga dan bahagia, tesis ini saya persembahkan untuk :

1. Kedua orang tua saya yang senantiasa memberikan semangat, dukungan moral maupun materi serta doa, motivasi dan kesabaran kepada saya.
2. Kepada kakak-kakak saya yang senantiasa memberikan semangat serta dukungan kepada saya.
3. Ibu Prof. Dr. Ema Utami, S.Si., M.Kom dan Bapak Dhani Ariatmanto, M.Kom., Ph.D., selaku pembimbing saya yang selalu memberikan arahan, saran, motivasi serta bimbingan positif dalam menyelesaikan tesis ini sehingga dapat terselesaikan dengan baik.
4. Putri Sari Yasmi, terima kasih sudah bersedia menemani, memberikan semangat, doa, berbagi suka dan duka selama proses pengerjaan thesis.
5. Keluarga besar MTI AMIKOM Angkatan 27 B, yang telah menjadi teman-teman saya semasa kuliah pascasarjana serta kenangan yang tidak dapat saya rasakan dikesempatan lain.

## HALAMAN MOTTO

Berbuatlah baik dimanapun, kapanpun, dan selalu berikanlah kebaikan kepada setiap orang.

Bermanfaatlah untuk sekelilingmu dan lingkunganmu.

Janganlah menyerah sebelum memulainya, kita tidak akan pernah tau hasilnya sebelum kita memulainya dan apapun hasilnya itu merupakan hasil maksimal dari usaha kita.



## KATA PENGANTAR

Dengan memanjatkan puji syukur kepada kehadiran Allah SWT atas limpahan rahmat dan hidayah-Nya sehingga mampu menyelesaikan tesis yang berjudul “Identifikasi Penyakit Tanaman Jagung Berdasarkan Citra Daun Menggunakan Convolutional Neural Network Dan Support Vector Machine”. Dalam penyusunan dan penulisan tesis ini, tidak terlepas dari bantuan dan bimbingan serta dukungan dari beberapa pihak. Oleh karena itu dalam kesempatan ini, penulis dengan senang hati menyampaikan terima kasih yang sebesar-sebesarnya kepada:

1. Prof. Dr. M. Suyanto, MM. selaku Rektor Universitas AMIKOM Yogyakarta.
2. Prof. Dr. Kusriani M.Kom. selaku Direktur Program Pascasarjana Universitas AMIKOM Yogyakarta
3. Prof. Dr. Ema Utami S.Si., M.Kom. dan Dhani Ariatmanto, M.Kom., Ph.D. selaku dosen pembimbing yang telah sabar memberikan arahan, masukan, dan saran dalam menyelesaikan tesis ini.
4. Kepada kedua orangtua saya yang selalu memberikan support dan doa kepada saya.
5. Teman-teman Magister Informatika angkatan 27 Kelas B.

Yogyakarta, 2 Februari 2024

Penulis



## DAFTAR ISI

HALAMAN JUDUL.....	ii
HALAMAN PENGESAHAN.....	iii
HALAMAN PERSETUJUAN.....	iv
HALAMAN PERNYATAAN KEASLIAN TESIS.....	v
HALAMAN PERSEMBAHAN.....	vi
HALAMAN MOTTO.....	vii
KATA PENGANTAR.....	viii
DAFTAR ISI.....	ix
DAFTAR TABEL.....	xii
DAFTAR GAMBAR.....	xiii
INTISARI.....	xv
<i>ABSTRACT</i> .....	xvi
BAB I PENDAHULUAN.....	1
1.1. Latar Belakang Masalah.....	1
1.2. Rumusan Masalah.....	6
1.3. Batasan Masalah.....	7
1.4. Tujuan Penelitian.....	7
1.5. Manfaat Penelitian.....	8
BAB II TINJAUAN PUSTAKA.....	9
2.1. Tinjauan Pustaka.....	9
2.2. Keaslian Penelitian.....	15

2.3. Landasan Teori.....	23
2.3.1. Citra Digital.....	23
2.3.2. Pengolahan Citra Digital .....	24
2.3.3. Citra HSV .....	24
2.3.4. Citra Grayscale .....	25
2.3.5. Gray Level Co-occurrence Matrix.....	26
2.3.6. Klasifikasi.....	30
2.3.7. Convolutional Neural Network .....	30
2.3.8. Support Vector Machine.....	33
2.3.9. Confusion Matrix.....	35
<b>BAB III METODE PENELITIAN.....</b>	<b>37</b>
3.1. Jenis, Sifat, dan Pendekatan Penelitian.....	37
3.2. Metode Pengumpulan Data.....	37
3.3. Metode Analisis Data.....	38
3.4. Alur Penelitian .....	40
<b>BAB IV HASIL PENELITIAN DAN PEMBAHASAN .....</b>	<b>44</b>
4.1. Pengumpulan Data.....	44
4.2. <i>Preprocessing</i> Data.....	46
4.3. Ekstraksi Fitur GLCM .....	49
4.4. Split Data .....	54
4.5. Skenario Penelitian .....	55
4.5.1. Convolutional Neural Network .....	56

4.5.2. Support Vector Machine.....	59
4.6. Analisis Hasil Klasifikasi.....	61
4.6.1. Convolutional Neural Network .....	62
4.6.2. Convolutional Neural Network + GLCM.....	66
4.6.3. Support Vector Machine.....	70
4.6.4. Support Vector Machine + GLCM.....	74
4.6.5. Perbandingan Hasil Klasifikasi .....	78
<b>BAB V PENUTUP</b> .....	81
5.1. Kesimpulan .....	81
5.2. Saran .....	82
<b>DAFTAR PUSTAKA</b> .....	83


## DAFTAR TABEL

Tabel 2.1. Matriks literatur review dan posisi penelitian Identifikasi Penyakit Tanaman Jagung Berdasarkan Citra Daun Menggunakan.....	15
Convolutional Neural Network Dan Support Vector Machine.....	15
Tabel 2.1. Rumus <i>Confusion Matrix</i> .....	35
Tabel 4.1. Jumlah Data Citra Daun Jagung.....	44
Tabel 4.2. Jumlah Dataset Augmentasi.....	45
Tabel 4.3. Hasil Ekstraksi Fitur GLCM.....	50
Tabel 4.4. Pembagian Data.....	55
Tabel 4.5. Skenario Penelitian.....	55
Tabel 4.6. Perbandingan Hasil Pengujian.....	79

## DAFTAR GAMBAR

Gambar 2.1. Matriks Citra Digital .....	23
Gambar 2.2. Sudut <i>Gray Level Co-occurrence Matrix</i> .....	27
Gambar 2.3. Arsitektur <i>Convolutional Neural Network</i> .....	31
Gambar 2.4. SVM berusaha menemukan <i>hyperplane</i> terbaik .....	34
Gambar 3.1. Alur Penelitian .....	40
Gambar 4.1. Contoh Citra Daun Jagung .....	46
Gambar 4.2. Tranformasi Citra RGB ke HSV .....	47
Gambar 4.3. Tranformasi Citra HSV ke <i>Grayscale</i> .....	48
Gambar 4.4. Menyamakan Ukuran Piksel Semua Citra. ....	49
Gambar 4.5. Potongan Kode Import dan Menampilkan Jumlah Data .....	51
Gambar 4.6. Potongan Kode Menentukan sudut dan fitur .....	52
Gambar 4.7. Menghitung nilai matriks setiap fitur .....	53
Gambar 4.8. Menyimpan hasil perhitungan GLCM .....	53
Gambar 4.9. Hasil Ekstraksi Fitur GLCM .....	54
Gambar 4.10. Model Arsitektur Metode CNN .....	57
Gambar 4.11. Model Arsitektur Metode CNN + GLCM .....	58
Gambar 4.12. Model Arsitektur Metode SVM .....	60
Gambar 4.13. Grafik Akurasi dan Loss Metode CNN .....	62
Gambar 4.14. <i>Confusion Matrix</i> Metode CNN .....	63
Gambar 4.15. <i>Classification Report</i> Metode CNN .....	65
Gambar 4.16. Grafik Akurasi dan Loss Metode CNN + GLCM .....	66

Gambar 4.17. <i>Confusion Matrix</i> Metode CNN + GLCM.....	67
Gambar 4.18. <i>Classification Report</i> Metode CNN + GLCM.....	70
Gambar 4.19. <i>Confusion Matrix</i> Metode SVM.....	71
Gambar 4.20. <i>Classification Report</i> Metode SVM.....	74
Gambar 4.21. <i>Confusion Matrix</i> Metode SVM + GLCM.....	75
Gambar 4.22. <i>Classification Report</i> Metode SVM + GLCM.....	78
Gambar 4.23. Perbandingan Hasil Performa.....	80



## INTISARI

Tanaman jagung di Indonesia merupakan komoditi tanaman pangan terbesar kedua setelah padi sebagai sumber karbohidrat. Produktivitas tanaman pangan ini dalam beberapa tahun terakhir mengalami fluktuasi yang berpengaruh terhadap kesediaan pangan. Terdapat beberapa faktor yang menyebabkan produksi tanaman jagung menjadi terganggu. Apabila tidak segera dilakukan pencegahan, dapat menyebabkan penurunan kualitas maupun produktivitas panen. Dalam mengatasi masalah ini mampu memanfaatkan bidang informatika dalam mengidentifikasi penyakit tanaman dengan menerapkan *image processing* dan *image classification*.

Penelitian ini membandingkan performa dua metode klasifikasi, yaitu *Convolutional Neural Network* dan *Support Vector Machine* untuk mendeteksi penyakit pada tanaman jagung berdasarkan citra daun. Masing-masing metode klasifikasi akan menerapkan dua skenario pengolahan dataset yang telah melalui proses *preprocessing data* yaitu penerapan ekstraksi fitur dan tanpa penerapan ekstraksi fitur GLCM. Pengujian ini bertujuan untuk mengetahui pengaruh penerapan GLCM terhadap performa klasifikasi.

Hasil pengujian yang telah dilakukan menunjukkan metode CNN dengan penerapan ekstraksi fitur GLCM menghasilkan performa kinerja tertinggi dengan nilai *accuracy* mencapai 97%, *precision* 95%, dan *recall* 97%. Hal ini menunjukkan dengan memanfaatkan ekstraksi fitur GLCM mampu meningkatkan performa kinerja metode CNN dan mampu mempersingkat waktu pengujian *training* dan *testing*, serta mengurangi kecenderungan terjadinya *overfitting*.

Kata kunci: Penyakit Jagung, Pengolahan Citra, Convolutional Neural Network, Support Vector Machine, GLCM

## **ABSTRACT**

*Corn in Indonesia is the second largest food crop commodity after rice as a source of carbohydrates. In recent years, the productivity of these food crops has experienced fluctuations that impact food availability. Several factors cause corn production to be disrupted. If prevention is not taken immediately, it can cause a decrease in crop quality and productivity. In overcoming this problem, we can use informatics to identify plant diseases by applying image processing and classification.*

*This research compares the performance of two classification methods, Convolutional Neural Network, and Support Vector Machine, for detecting diseases in corn plants based on leaf images. Each classification method will apply two dataset processing scenarios that have undergone a data preprocessing process, namely implementing feature extraction and not implementing GLCM feature extraction. This test aims to determine the effect of implementing GLCM on classification performance.*

*The test results that have been carried out show that the CNN method using GLCM feature extraction produces the highest performance, with accuracy values reaching 97%, precision at 95%, and recall at 97%. This shows that utilizing GLCM feature extraction can improve the performance of the CNN method, shorten training and testing times, and reduce the tendency for overfitting to occur.*

*Keyword: Corn Diseases, Image Processing, Convolutional Neural Network, Support Vector Machine, GLCM*



# BAB I

## PENDAHULUAN

### 1.1. Latar Belakang Masalah

Perkembangan teknologi saat ini telah mengalami kemajuan dengan sangat pesat seiring berkembangnya jaman. Sehingga pada perkembangannya, telah memberikan banyak manfaat kepada manusia. Dengan berkembangnya teknologi, semua industri bisnis merasakan akan manfaat dengan adanya teknologi, salah satunya pada sektor pertanian. Saat ini dalam industri pertanian, penggunaan teknologi sudah tidak dapat dihindari, bahkan sudah umum diterapkan. Diperkirakan bahwa penggunaan teknologi modern di sektor pertanian dapat meningkatkan nilai pendapatan ekonomi hingga US\$ 6,6 miliar per tahun. Dengan demikian, penggunaan teknologi pertanian dirasa mampu memberikan perubahan positif bagi para petani. Contohnya dengan pemanfaatan teknologi pengolahan citra digital, seperti mampu mengidentifikasi penyakit pada tanaman dalam upaya pencegahan menyebar luasnya penyakit pada tanaman (Syahriani-dkk., 2021). Apabila tidak segera dilakukan pencegahan, dapat menghambat dalam stabilitas produksi. Bukan hanya menurunkan kualitas dan produktivitas panen, tetapi juga seringkali menimbulkan *fuso* bahkan pada akhirnya berimbas pada gangguan sistem pengadaan pangan hampir seluruh dunia (Sutarman, 2017).

Tanaman jagung merupakan salah satu tanaman pangan terpenting di dunia, selain gandum dan padi. Di Indonesia, tanaman jagung merupakan makanan pokok kedua setelah padi yang sering dikonsumsi untuk memenuhi karbohidrat (Sudjono,

2018). Melansir data dari *Food and Agriculture Organization (FAO)*, produksi jagung cenderung meningkat sejak tahun 2010 - 2018 dengan mencapai 30,25 juta ton pada tahun 2018. Namun, pada 2019 produksi jagung mengalami penurunan 25% menjadi 22,59 juta ton dan pada tahun 2020 kembali mengalami penurunan 0,38% menjadi 22,5 juta ton. Faktor pembatas dalam upaya peningkatan jumlah produksi jagung terdapat beberapa hambatan salah satunya adanya serangan organisme pengganggu tanaman (Ulhaq & Masnilah, 2019). Gangguan serangga hama dan patogen merupakan organisme pengganggu tanaman yang dapat menyebabkan penyakit pada tanaman dan dapat menghambat dalam stabilitas produksi. Upaya dalam penanggulangan untuk pencegahan dan mengatasi organisme pengganggu tanaman (OPT) seperti halnya gangguan hama dan penyakit pada tanaman jagung terus dilakukan. Namun mengingat faktor lingkungan seperti halnya cuaca, suhu dan kelembaban menyebabkan perkembangan penyakit pada tanaman jagung pun akan semakin berkembang.

Menurut laporan Direktorat Perlindungan Tanaman Pangan (Sudjono, 2018), dari periode 1978 sampai 1981, rata-rata areal yang rusak oleh serangan hama dan penyakit sebesar 57.871 hektar dengan intensitas sebesar 26,5%. Epidemii penyakit bulai (*peronosclerospora maydis*) di daerah Lampung pertama kali terjadi tahun 1973 mengakibatkan penurunan hasil jagung cukup drastis pada tahun-tahun berikutnya. Dari tahun 1973 sampai 1979 diperoleh hasil panen masing-masing sebesar 115, 92, 19, 44, 62, 55 dan 70 ton atau terjadi kerugian masing-masing sebesar 0, 20, 83, 62, 46, 44, dan 48%. Penyakit pada tanaman jagung cukup berfluktuasi dari satu tempat ke tempat lainnya, maupun dari waktu ke waktu, di

antara penyakit karat daun, hawar daun *Helminthosporium*, busuk batang, dan busuk tongkol. Sebagai gambaran, kerugian hasil oleh penyakit bercak *Helminthosporium maydis* di Amerika Serikat pernah mencapai 90% senilai 2,5 juta dolar.

Upaya pencegahan penyebaran penyakit pada daun tanaman agar tidak semakin meluas telah banyak dilakukan dalam penelitian sebelumnya, tidak hanya penelitian terkait bidang pertanian, namun pada bidang teknologi pun turun adil dalam menyelesaikan permasalahan ini. Salah satu manfaat dengan penerapan bidang teknologi yaitu identifikasi penyakit pada daun tanaman dengan menggunakan citra atau bisa disebut *image processing*. Dengan memanfaatkan *image processing* pada identifikasi penyakit daun tanaman dapat membantu para pengelola pertanian dalam mengambil langkah yang efektif dan efisien dalam pencegahan menyebarnya penyakit (Rozaqi dkk., 2021).

Penelitian terkait penerapan *image processing* dalam upaya pencegahan menyebarnya penyakit pada daun tanaman telah banyak dilakukan dengan menggunakan berbagai metode *machine learning* atau *deep learning* yang dapat mengklasifikasi citra dengan berbagai kondisi yang berbeda-beda seperti pada penelitian (Wafa Akhyari dkk., 2021) menggunakan metode *convolutional neural network* dengan arsitektur VGG-16 untuk mendiagnosis penyakit pada daun tanaman jagung. Data citra daun tanaman jagung yang digunakan dalam penelitian ini sebesar 3.846 yang dibagi ke dalam tiga jenis penyakit jagung. Dalam penelitian ini menghasilkan tingkat akurasi mencapai 90%. Selanjutnya, Penelitian dari (Nurchayati dkk., 2022) melakukan klasifikasi citra penyakit daun jagung dengan

membandingkan 4 model kernel pada *convolutional neural network* yaitu 3x2, 3x3, 3x4 dan 4x4 dengan membandingkan 6 metode optimasi yaitu RMSProp, AdaGrad, SGD, Adam, Adamax, dan Adadelta. Dalam penelitian ini metode optimasi Adam dengan kernel 3x3 menghasilkan tingkat akurasinya tertinggi sebesar 84% untuk *data test* dan 89% untuk *data train*. Kemudian pada penelitian (Rasywir dkk., 2020) melakukan penelitian penerapan metode *deep neural network* untuk sistem pakar identifikasi penyakit pada daun tanaman sawit. Dalam penelitian ini terdapat 11 kelas penyakit yang akan diujikan. Dari pengujian yang telah dilakukan menghasilkan rata-rata akurasi sebesar 86%.

Berbeda dengan penelitian (Felix dkk., 2019) yang melakukan penelitian identifikasi penyakit tanaman tomat dengan membandingkan metode *convolutional neural network* dan *support vector machine*. Dalam penelitian ini pengujian sangat dipengaruhi pada tahapan *preprocessing*, sehingga pada tahap ekstraksi fitur tekstur dengan GLCM (*Gray Level Co-occurrence Matrix*) dapat menghasilkan fitur tekstur pada citra yang berpengaruh dalam pengklasifikasian. Dalam penelitian ini menghasilkan metode *convolutional neural network* sebagai metode klasifikasi yang lebih baik dalam mengidentifikasi penyakit daun tomat. Selanjutnya pada penelitian (Suhendra dkk., 2022) melakukan klasifikasi penyakit daun jagung menggunakan metode *support vector machine* dengan memanfaatkan ekstraksi fitur tekstur *gray level co-occurrence matrix*. Dalam penelitian ini membandingkan hasil ekstraksi fitur tekstur GLCM yaitu tekstur, warna dan tekstur & warna. Dari pengujian yang telah dilakukan menghasilkan akurasi hingga 90% pada gabungan warna dan tekstur.

Selanjutnya penelitian dari (Maria dkk., 2020) melakukan penelitian membangun sistem pendukung keputusan dalam mendiagnosis penyakit pada tanaman padi berdasarkan gejala-gejala yang dialami dengan menerapkan metode *promethee*. Dalam mendiagnosis penyakit tanaman padi, terdapat 20 gejala untuk mendeteksi 5 jenis penyakit pada tanaman padi. Hasil penelitian yang telah dilakukan menghasilkan penilaian berupa perankingan yang mendekati jenis penyakit berdasarkan gejala yang ada. Pada penelitian (Hasan dkk., 2021) melakukan identifikasi penyakit daun anggur menggunakan metode CNN. Dalam penelitian ini pada proses segmentasi menggunakan metode K-Means dan proses ekstraksi fitur menerapkan metode *transfer learning* VGG-16. Dari pengujian yang telah dilakukan menghasilkan nilai akurasi 97,25%. Selain itu, terdapat juga penelitian terdahulu yang dilakukan oleh (Soekarta dkk., 2023) melakukan klasifikasi penyakit tanaman tomat dengan menggunakan model *convolutional neural network* dan arsitektur VGG-16. Pada tahapan pembuatan model CNN tersebut membutuhkan *training time* sekitar 50 menit untuk 20 *epoch* sehingga terjadi *gap accuracy* antara *train accuracy* sebesar 98% dan 82% *validation accuracy*, berdasarkan pada hasil yang diperoleh sangat dimungkinkan terjadinya *overfitting*.

Berdasarkan latar belakang permasalahan yang telah diuraikan maka perlunya peningkatan model klasifikasi yang lebih baik dengan waktu pengujian relatif cepat & akurat sehingga menghasilkan nilai akurasi tinggi tanpa terjadinya *overfitting*. Maka didapatkan perbedaan dari kegiatan penelitian yang telah dilakukan oleh para peneliti, perbedaan terdapat pada tujuan, obyek, dan metode

penelitian. Pada penelitian ini membandingkan performa dua metode klasifikasi, yaitu *Convolutional Neural Network* dan *Support Vector Machine*, untuk mengidentifikasi penyakit pada tanaman jagung berdasarkan citra daun. Selain itu, penelitian ini juga akan menerapkan ekstraksi fitur menggunakan *Gray Level Co-Occurrence Matrix* (GLCM) untuk mengetahui pengaruh penerapan GLCM terhadap performa klasifikasi. Dengan adanya penelitian ini diharapkan mampu mengetahui model penelitian manakah yang mampu mengklasifikasi penyakit daun jagung dengan lebih baik dan akurat.

## 1.2. Rumusan Masalah

Berdasarkan latar belakang yang telah disampaikan, maka dapat diambil perumusan permasalahan sebagai berikut:

- a. Bagaimana performa yang dihasilkan metode *Convolutional Neural Network* dan *Support Vector Machine* dengan beberapa rancangan model penelitian?
- b. Model penelitian manakah yang menghasilkan nilai performa tertinggi untuk mengidentifikasi penyakit pada tanaman jagung berdasarkan citra daun?
- c. Bagaimana pengaruh ekstraksi fitur pada performa metode *Convolutional Neural Network* dan *Support Vector Machine* dalam mengidentifikasi penyakit pada tanaman jagung?

### 1.3. Batasan Masalah

Mengingat masalah yang diangkat sangat luas, maka dibutuhkan sebuah batasan dalam penelitian sehingga penelitian dapat lebih terarah dan tidak menyimpang jauh. Berikut merupakan batasan masalah dalam penelitian ini:

- a. Metode yang digunakan dalam identifikasi citra daun menggunakan *Convolutional neural network* dan *support vector machine*.
- b. Penelitian ini akan mengidentifikasi penyakit pada tanaman jagung berdasarkan citra daun.
- c. Data citra daun terbagi ke dalam 4 kelas penyakit tanaman jagung yaitu *blight*, *common rust*, *gray leaf spot* dan *healthy*.
- d. Data citra daun yang digunakan dalam identifikasi penyakit tanaman jagung bersifat publik yang didapatkan dari website [www.kaggle.com](http://www.kaggle.com).
- e. Data citra daun penyakit tanaman jagung yang digunakan berjumlah 4188 data.
- f. Pengujian evaluasi model klasifikasi menggunakan metode *confusion matrix*.
- g. Target penelitian ini hanya berupa uji akurasi *modelling* dengan *python*, dan tidak ke tahap implementasi pembuatan aplikasi.

### 1.4. Tujuan Penelitian

Berdasarkan rumusan masalah tujuan dari penelitian ini adalah:

- a. Mengetahui bagaimana penerapan metode *Convolutional Neural Network* dan *Support Vector Machine* dalam mengidentifikasi penyakit pada tanaman jagung dengan memanfaatkan ekstraksi fitur.

- b. Mengetahui rancangan model penelitian yang menghasilkan nilai performa terbaik dalam mengidentifikasi penyakit pada tanaman jagung.
- c. Mengetahui pengaruh ekstraksi fitur pada performa metode *Convolutional Neural Network* dan *Support Vector Machine* dalam mengidentifikasi penyakit pada tanaman jagung.

### **1.5. Manfaat Penelitian**

Manfaat dari penelitian ini adalah:

- a. Hasil rancangan model dapat digunakan untuk mempercepat penanganan identifikasi penyakit tanaman jagung, sehingga dimasa yang akan datang diharapkan memperoleh solusi yang tepat.
- b. Memberikan kontribusi penelitian pada penerapan metode *convolutional neural network* dan *support vector machine*.
- c. Dapat dijadikan referensi untuk penelitian selanjutnya dalam pengembangan identifikasi penyakit tanaman berdasarkan citra daun.



## BAB II

### TINJAUAN PUSTAKA

#### 2.1. Tinjauan Pustaka

Dalam mencapai keberhasilan sebuah penelitian terkait identifikasi penyakit pada tanaman jagung berdasarkan citra daun, maka dibutuhkan kajian-kajian pustaka yang bersifat ilmiah serta relevan dengan tema penelitian sebagai acuan dalam pengembangan penelitian yang akan dilakukan.

Pada penelitian (Soekarta dkk., 2023) melakukan klasifikasi penyakit daun tanaman tomat menggunakan *convolution neural network* dengan menerapkan arsitektur VGG16. Dataset citra daun tomat yang digunakan diperoleh dari situs *kaggle* yang bersifat open dengan jumlah data 10519 untuk data training dan 1100 data untuk data testing. Citra daun diubah menjadi ukuran piksel yang dengan ukuran 256x256 piksel. Hasil pengujian yang telah dilakukan menghasilkan nilai training sebesar 98% dan 84% untuk nilai testing yang membutuhkan waktu 50 menit.

Penelitian dari (Suhendra dkk., 2022) melakukan penelitian terkait deteksi dini dan klasifikasi penyakit daun tanaman jagung menggunakan *support vector machine* dengan memanfaatkan ekstraksi fitur tekstur dan warna. Data citra daun jagung yang digunakan bersifat sekunder yang diambil dari situs *kaggle* dengan jumlah data sebesar 3600 citra. Dalam penerapannya, citra daun jagung melalui tahap *preprocessing* menggunakan *gray level co-occurrence matrix* guna menghasilkan 22 fitur terdiri dari 18 fitur warna dan 4 fitur tekstur. Penelitian ini

membandingkan hasil ekstraksi fitur tekstur yaitu hanya tekstur, hanya warna, dan gabungan tekstur dan warna. Hasil pengujian yang telah dilakukan menghasilkan akurasi hingga 90% pada gabungan tekstur dan warna.

Penelitian selanjutnya dari (Rosadi dkk., 2021) berfokus pada upaya mendeteksi jenis penyakit daun tanaman jagung menggunakan metode *convolutional neural network pre-trained model*. Penelitian ini mencoba untuk mengenali empat jenis daun tanaman jagung, termasuk satu jenis daun yang sehat, serta tiga jenis penyakit daun jagung. Data citra daun jagung sebesar 3847 citra yang diperoleh dari para petani jagung se-kabupaten pasuruan. Hasil pengujian klasifikasi *pre-trained model* dengan menggunakan 1923 citra daun jagung sebagai data training menunjukkan tingkat akurasi sebesar 83%, sementara pada data validasi dengan 770 citra daun menghasilkan akurasi sebesar 88%.

Penelitian dari (Yanto dkk., 2021) melakukan klasifikasi tingkat kematangan buah jeruk berdasarkan tingkat kecerahan warna dengan menerapkan metode *convolutional neural network*. Penelitian ini mencoba untuk mengenali buah jeruk yang bagus dan yang busuk berdasarkan tingkat kecerahan warna pada tekstur buah jeruk. Dataset yang digunakan diperoleh dari situs *kaggle* yang bersifat open dengan jumlah data 100. Citra daun diubah menjadi ukuran piksel yang dengan ukuran 256x256 piksel dan dilakukan *Laplacian of Gaussian* untuk mendeteksi tepian citra. Dari pengujian yang telah dilakukan menghasilkan nilai akurasi pada training data sebesar 96% dan pada testing data sebesar 92%.

Penelitian selanjutnya yang dilakukan oleh (Khotimah dkk., 2022) melakukan penelitian berkaitan mengidentifikasi hama dan penyakit pada tanaman

jagung berdasarkan gejala yang telah diamati dari pengamatan dengan metode *support vector machine*. Dalam pengumpulan data dilakukan dari pengisian kuisioner yang telah divalidasi oleh para pakar, kemudian dilakukan tahap *preprocessing* data, kemudian proses klasifikasi dengan menerapkan metode *support vector machine* dengan membandingkan kernel *Polynomial* dan *Radial Basis Function* (RBF), dan terakhir dilakukan evaluasi kinerja pada model. Hasil kinerja metode SVM dengan kernel *Radial Basis Function* menghasilkan akurasi sebesar 94.95%, dan pada kernel *Polynomial* menghasilkan akurasi sebesar 93.53%. Berdasarkan pengujian yang telah dilakukan menunjukkan jika kernel *Radial Basis Function* menghasilkan akurasi paling tinggi.

Penelitian yang dilakukan (Wafa Akhyari dkk., 2021) melakukan penelitian terkait klasifikasi penyakit daun pada tanaman jagung dengan menggunakan metode *convolutional neural network* dengan arsitektur VGG-16. Data citra daun yang digunakan dalam penelitian ini berjumlah 3846 yang terbagi menjadi tiga jenis penyakit daun jagung. Hasil pengujian yang telah dilakukan dengan menerapkan arsitektur VGG-16 menghasilkan akurasi mencapai di atas 90%.

Pada penelitian selanjutnya yang dilakukan (Supriyanto dkk., 2023) menggunakan metode *support vector machine* dengan menerapkan ekstraksi fitur *gray level co-occurrence matrix* untuk mengklasifikasi penyakit pada daun kopi berdasarkan citra gambar. Penelitian ini menerapkan segmentasi menggunakan *k-means clustering*, dimana proses segmentasi menggunakan tiga cluster untuk membedakan bagian yang terdampak penyakit dengan bagian yang tidak terdampak penyakit. Dalam proses pengumpulan data, penelitian ini menggunakan data yang

diambil dari perkebunan kopi robusta di daerah Desa Plaosan yang berjumlah 400 citra. Dari pengujian yang telah dilakukan dengan menerapkan ekstraksi ciri GLCM menggunakan fitur energi, kontras, korelasi, homogenitas, dan entropi dengan sudut  $0^\circ$ ,  $45^\circ$ ,  $90^\circ$ ,  $135^\circ$  dan dengan menerapkan kernel RBF Gaussian menghasilkan nilai akurasi sebesar 97,5%, presisi sebesar 95,24%, recall sebesar 100%, dan F1-score sebesar 97,56%.

Pada penelitian (Felix dkk., 2019) yang melakukan penelitian identifikasi penyakit daun tanaman tomat dengan membandingkan metode *convolutional neural network* dan *support vector machine*. Dalam penelitian ini menerapkan beberapa tahap *preprocessing* serta ekstraksi fitur GLCM (*Gray Level Co-occurrence Matrix*) yang menghasilkan fitur tekstur pada citra. Dalam penelitian ini menghasilkan metode *convolutional neural network* sebagai metode klasifikasi yang lebih baik dalam mengidentifikasi penyakit daun tomat dengan menghasilkan akurasi sebesar 97,5%.

Selanjutnya pada penelitian (Rasywir dkk., 2020) melakukan penelitian terakit sistem pakar dalam identifikasi penyakit tanaman sawit menggunakan metode *deep neural network*. Data yang digunakan dalam penelitian ini bersumber dari data diagnosis kelapa sawit dari Dinas Perkebunan Provinsi Jambi dengan jumlah kelas sebanyak 11 dengan jumlah gejala penyakit sebanyak 65. Dari hasil pengujian yang telah dilakukan menghasilkan rata-rata akurasi sebesar 86%.

Penelitian dari (Haque dkk., 2022) melakukan identifikasi penyakit pada tanaman jagung dengan membandingkan model dari kerangka arsitektur *Inception-v3* pada metode *convolutional neural network*. Data citra pada penelitian ini diambil

dari lapangan percobaan ICAR-IIMR, India dengan jumlah citra sebesar 5939 citra. Dalam penerapannya, citra daun jagung dilakukan tahap *preprocessing* diantaranya mengubah seluruh ukuran citra menjadi 256x256 piksel, kemudian mengubah citra dalam bentuk array, dan dilakukannya proses klasifikasi. Pada model pertama *Inception-v3 fatten layer with fully connected layer* menghasilkan tingkat akurasi sebesar 95.42%, pada model yang kedua *Inception-v3 global average pooling layer* mendapatkan akurasi sebesar 95.71%, dan pada model yang ketiga *Inception-v3 global average pooling layer with fully connected layer* menghasilkan akurasi 95.38%. Hasil pada penelitian ini dengan penerapan arsitektur *Inception-v3* dengan model *global average pooling layer* menghasilkan akurasi tertinggi dalam identifikasi penyakit tanaman jagung.

Penelitian dari (Hasan dkk., 2021) melakukan penelitian terkait identifikasi penyakit daun tanaman jagung menggunakan *convolutional neural network* dengan memanfaatkan algoritma K-Means untuk proses segmentasi citra dan proses ekstraksi menggunakan metode *transfer learning* VGG16. Data citra daun anggur diperoleh dari Kaggle dengan jumlah data citra sebesar 4000 citra yang terbagi menjadi 4 kelas. Citra dari Google digunakan sebagai data uji diluar dataset sebanyak 100 citra. Dari hasil yang telah dilakukan menghasilkan akurasi sebesar 99,5% pada proses training, 97% pada proses testing, dan 95% pada proses testing menggunakan data dari luar.

Pada penelitian yang dilakukan (Huda dkk., 2022) melakukan klasifikasi jenis penyakit pada daun tanaman padi berdasarkan citra. Dalam mengidentifikasi jenis penyakit menerapkan metode klasifikasi yaitu KNN berdasarkan hasil

ekstraksi ciri pada citra menggunakan metode *gray level co-occurrence matrix*. Data yang digunakan dalam penelitian ini sebanyak 240 gambar diperoleh dari *UCI Machine Learning Repository* yang terdiri atas 3 jenis penyakit padi. Sebanyak 210 gambar sebagai data training dan 30 gambar lainnya untuk data uji. Hasil penelitian ini setelah dilakukan 2 kali proses uji, tingkat akurasi tertinggi yang didapatkan sebesar 93,3%.

Pada penelitian (Regita Azzahra dkk., 2023) melakukan klasifikasi untuk membedakan daun herbal dengan membandingkan metode *convolutional neural network* dan *naïve bayes* untuk mengetahui performa metode yang dihasilkan. Pada prosesnya menggunakan ekstraksi fitur *gray level co-occurrence matrix* dengan memanfaatkan 6 fitur. Penelitian ini memiliki beberapa skenario yaitu menggunakan CNN, dan CNN + GLCM dengan menerapkan kernel *Gaussian*, *Multinomial*, dan *Bernoulli*. Kondisi citra daun herbal yang digunakan diambil pada kondisi siang hari dan malam hari. Dari hasil pengujian yang dilakukan menunjukkan jika penerapan metode CNN tanpa GLCM pada citra daun siang hari menghasilkan nilai akurasi 98%.

Penelitian yang dilakukan (Lesmana dkk., 2022) bertujuan untuk mengidentifikasi penyakit daun tanaman kentang menggunakan metode *convolutional neural network*. Pada penelitian ini memanfaatkan proses konvolusi dimana citra akan dipecah menjadi beberapa citra lebih kecil dengan ukuran yang sama. Data yang digunakan dalam penelitian ini sebanyak 5400 citra daun jagung yang terbagi menjadi 3 kelas. Dari penelitian yang telah dilakukan menghasilkan nilai akurasi diatas 90% pada proses validasi.

## 2.2. Keaslian Penelitian

Tabel 2.1. Matriks literatur review dan posisi penelitian Identifikasi Penyakit Tanaman Jagung Berdasarkan Citra Daun Menggunakan Convolutional Neural Network Dan Support Vector Machine

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
1	Klasifikasi Penyakit Tanaman Tomat Menggunakan Metode Convolutional Neural Network (CNN)	Rendra Sockarta, Nirwana Nurdjan, Ardian Syah, 2022, <i>Insect (Informatics and Security)</i> : Jurnal Teknik Informatika	Penelitian ini bertujuan untuk mengklasifikasi jenis penyakit pada tanaman jagung dengan menggunakan metode <i>convolutional neural network</i> dengan menerapkan arsitektur VGG16	Dari hasil pengujian yang telah dilakukan dalam klasifikasi penyakit daun tanaman jagung dengan menggunakan dataset sebesar 10519 pada data training dan 1100 pada data testing mampu menghasilkan nilai akurasi training sebesar 98% dan pada akurasi testing sebesar 82%.	Penelitian ini masih mampu untuk ditingkatkan terutama pada <i>preprocessing</i> data dimana tidak hanya melakukan <i>resize</i> ukuran citra, dapat mempersingkat waktu pengujian yang dilakukan sehingga waktu pengujian bisa kurang dari 30menit. Diharapkan bisa melakukan komparasi arsitektur pada CNN.	Pada penelitian yang akan dilakukan pada tahap <i>preprocessing</i> dilakukan serangkaian proses seperti mengubah citra ke <i>hsv</i> , <i>greyscale</i> , mengubah ukuran citra, dan ekstraksi fitur GLCM, serta mengkomparasi metode CNN dan SVM untuk mengetahui metode yang paling optimal

Tabel 2.1. Matriks literatur review dan posisi penelitian (lanjutan)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
2	Identifikasi dan Klasifikasi Penyakit Daun Jagung Menggunakan Support Vector Machine	Rivansyah Suhendra, Ilham Juliwardi, Sanusi, 2022, Jurnal Teknologi Informasi	Pada penelitian ini bertujuan untuk melakukan deteksi dini dan klasifikasi penyakit daun tanaman jagung dengan metode <i>support vector machine</i> dengan memanfaatkan fitur warna dan fitur tekstur.	Pengujian yang telah dilakukan dengan menggunakan beberapa variasi pemanfaatan fitur GLCM seperti hanya fitur warna, hanya fitur tekstur, dan fitur gabungan warna dan tekstur menghasilkan akurasi yang paling optimal hingga 90% pada fitur gabungan warna dan tekstur.	Penelitian selanjutnya diharapkan bisa mencoba beberapa fitur ekstraksi lainnya pada GLCM, ataupun mencoba menerapkan metode ekstraksi fitur lainnya.	Pada penelitian yang akan dilakukan menggunakan fitur 6 ekstraksi pada GLCM, serta mengkomparasi metode CNN dan SVM untuk mengetahui metode yang paling optimal.
3	Identifikasi Jenis Penyakit Daun Jagung Menggunakan Deep Learning Pre-Trained Model	Muhammad Imron Rosadi, Moch. Lutfi, 2021, Jurnal Keilmuan dan Aplikasi Teknik Informatika	Penelitian ini bertujuan untuk mendeteksi jenis penyakit pada daun tanaman jagung secara cepat dan akurat dengan menggunakan <i>convolutional neural network</i> .	Berdasarkan penelitian yang telah dilakukan dengan menggunakan data citra berjumlah 1923 pada data <i>training</i> gambar dengan ukuran 150x150 piksel menggunakan <i>epoch</i> 100 menghasilkan tingkat akurasi 84% dan data validasi sebanyak 770 citra dengan ukuran 150x150 piksel menghasilkan akurasi 88%.	Penelitian selanjutnya diharapkan pada tahap <i>preprocessing</i> bisa lebih ditingkatkan, tidak hanya melakukan <i>resize</i> ukuran citra. Mencoba menggunakan arsitektur pada <i>cnn</i> untuk pembanding.	Pada penelitian yang akan dilakukan pada tahap <i>preprocessing</i> dilakukan serangkaian proses seperti mengubah citra ke <i>hsv</i> , <i>greyscale</i> , mengubah ukuran citra, dan ekstraksi fitur GLCM, serta mengkomparasi metode CNN dan SVM untuk mengetahui metode yang paling optimal



Tabel 2.1. Matriks literatur review dan posisi penelitian (lanjutan)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
4	Klasifikasi Tekstur Kematangan Buah Jeruk Manis Berdasarkan Tingkat Kecerahan Warna dengan Metode <i>Deep Learning Convolutional Neural Network</i> .	Budi Yanto, Luth Fimawahib, Asep Supriyanto, B. Herawan Hayadi, Rinanda Rizki Pratama, 2021, Jurnal Inovtek Polbeng - Seri Informatika	Penelitian ini bertujuan untuk mendeteksi tekstur kematangan buah jeruk berdasarkan tingkat kecerahan warna serta menerapkan <i>Laplace of Gaussian</i> untuk mendeteksi garis tepian buah dengan menggunakan metode <i>convolutional neural network</i> .	Berdasarkan penelitian yang telah dilakukan dengan menggunakan data citra berjumlah 100 gambar dengan ukuran citra 64x64 piksel serta menggunakan <i>epoch</i> 50 mampu menghasilkan nilai akurasi hingga 92% pada data training dan pada data testing 92%.	Penelitian selanjutnya diharapkan pada tahap <i>preprocessing</i> bisa mencoba metode ekstraksi fitur lainnya serta dapat mempersingkat waktu pengujian yang dilakukan.	Pada penelitian yang akan dilakukan pada tahap <i>preprocessing</i> dilakukan serangkaian proses seperti mengubah citra ke <i>hsv</i> , <i>greyscale</i> , mengubah ukuran citra, dan ekstraksi fitur GLCM, serta mengkomparasi metode CNN dan SVM untuk mengetahui metode yang paling optimal
5	Identifikasi Hama Dan Penyakit Tanaman Jagung Dengan Menggunakan Metode Klasifikasi <i>Support Vector Machine</i> (SVM)	Bain Khusnul Khotimah, Eko Setiawan, Verdi Sasmeka, Aulya Fridayanti, Ikbar Maulana, Arwinda Mifta Zulfida, 2022, Jurnal Ilmiah NERO	Penelitian ini bertujuan mengidentifikasi hama dan penyakit pada tanaman jagung berdasarkan gejala yang telah diamati dari pengamatan dengan mengkomparasi kernel metode <i>support vector machine</i> .	Dalam penerapan metode SVM dengan kernel <i>Radial Basis Function</i> akurasi dihasilkan sebesar 94,95%, dan pada kernel <i>Polynomial</i> menghasilkan akurasi sebesar 93,53%. Dari pengujian yang telah dilakukan menunjukkan jika kernel <i>Radial Basis Function</i> menghasilkan akurasi paling tinggi.	Penelitian selanjutnya diharapkan pada pembagian dataset mencoba beberapa komposisi seperti 80:20 ataupun 70:30.	Pada penelitian yang akan dilakukan menggunakan ekstraksi fitur GLCM sebagai <i>preprocessing</i> , serta mengkomparasi metode CNN dan SVM untuk mengetahui metode yang paling optimal

Tabel 2.1. Matriks literatur review dan posisi penelitian (lanjutan)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
6	Klasifikasi Penyakit Pada Daun Jagung Menggunakan <i>Convolutional Neural Network</i>	Muhammad Wafa Akhyari, Andi Suyoto, Ferry Wahyu Wibowo, 2021, Jurnal Informa	Penelitian ini bertujuan menerapkan metode <i>Convolutional Neural Network</i> dengan arsitektur VGG-16 untuk mendeteksi penyakit pada tanaman jagung.	Hasil pengujian yang telah dilakukan dengan menerapkan metode <i>Convolutional Neural Network</i> dengan arsitektur VGG-16, menghasilkan akurasi sebesar 98% dan validasi sebesar 97%.	Penelitian selanjutnya diharapkan bisa mencoba dengan menggunakan arsitektur lainnya dan melakukan <i>preprocessing</i> sehingga tidak mengalami <i>overfitting</i> .	Pada penelitian yang akan dilakukan menggunakan fitur 6 ekstraksi pada GLCM, serta mengkomparasi metode CNN dan SVM untuk mengetahui metode yang paling optimal.
7	Klasifikasi Penyakit Daun Kopi Robusta Menggunakan Metode SVM dengan Ekstraksi Ciri GLCM	Agus Stipriyanto, R Rizal Isnanto, Oky Dwi Nurhayati, 2023, Jurnal Nasional Teknik Elektro dan Teknologi Informasi	Penelitian ini bertujuan untuk menerapkan ekstraksi ciri GLCM pada metode <i>support vector machine</i> untuk mengklasifikasi jenis penyakit pada daun kopi dengan menerapkan 3 kernel yang berbeda untuk membandingkan hasil akurasi yang diperoleh	Dari pengujian yang telah dilakukan menunjukkan jika penggunaan kernel RBF Gaussian mampu menghasilkan nilai akurasi tertinggi dari pada penerapan kernel lainnya, nilai akurasi yang diperoleh mencapai 97,5%, presisi 95,24%, recall 100%, dan F1-score 97,56%	Diharapkan pada penelitian selanjutnya bisa mencoba melakukan perbandingan ekstraksi fitur selain penerapan GLCM.	Pada penelitian yang akan dilakukan menggunakan fitur 6 ekstraksi pada GLCM, serta mengkomparasi metode CNN dengan <i>optimizer</i> Adam dan SVM dengan kernel RBF untuk mengetahui metode yang paling optimal.

Tabel 2.1. Matriks literatur review dan posisi penelitian (lanjutan)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
8	Implementasi CNN dan SVM untuk Identifikasi Penyakit Tomat via Daun	Felix, Said Faisal, Theresia F M Butarbutar, Pabala Sirait, 2019, Jurnal SIFO Mikroskil	Penelitian ini bertujuan mengkomparasi metode CNN dan SVM dalam mendeteksi penyakit pada tanaman jagung dengan menerapkan ekstraksi fitur GLCM.	Berdasarkan hasil pengujian yang telah dilakukan dengan tahap <i>preprocessing</i> seperti transformasi warna ke <i>hsv</i> , ke <i>grayscale</i> dan GLCM dengan 2 fitur energi dan entropi, menghasilkan tingkat akurasi pada CNN sebesar 97.5% dan pada SVM 95%.	Penelitian selanjutnya diharapkan bisa menambahkan fitur-fitur lainnya pada GLCM sehingga bisa mendapatkan hasil yang berbeda.	Pada penelitian yang akan dilakukan menggunakan 6 fitur ekstraksi pada GLCM.
9	Evaluasi Pembungunan Sistem Pakar Penyakit Tanaman Sawit dengan Metode <i>Deep Neural Network</i> (DNN)	Errissya Rasywir, Rudolf Sinaga, Yovi Pratama, 2020, Jurnal Media Informatika Budidarma	Penelitian ini bertujuan mengevaluasi metode <i>Deep Neural Network</i> (DNN) dalam implementasi sistem pakar penyakit tanaman sawit.	Dari pengujian yang telah dilakukan dengan implementasi <i>deep neural network</i> dalam mendeteksi 11 kelas penyakit daun tanaman sawit menghasilkan akurasi sebesar 88% dengan rata-rata akurasi 86%.	Penelitian selanjutnya diharapkan bisa lebih diperluas data gejala penyakit daun tanaman sawit.	Pada penelitian yang akan dilakukan menggunakan 6 fitur ekstraksi pada GLCM, serta mengkomparasi metode CNN dan SVM untuk mengetahui metode yang paling optimal.

Tabel 2.1. Matriks literatur review dan posisi penelitian (lanjutan)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
10	Deep learning-based approach for identification of diseases of maize crop	Md. Ashraful Haque, Sudeep Marwaha, Chandan Kumar Deb, Sapna Nigam, Alka Arora, 2022, Scientific Reports	Penelitian ini bertujuan untuk mengidentifikasi penyakit pada tanaman jagung dengan membandingkan model dengan kerangka arsitektur <i>Inception-v3</i> pada metode <i>convolutional neural network</i> .	Dari penelitian yang telah dilakukan, pada model pertama <i>Inception-v3</i> <i>full connected layer</i> menghasilkan tingkat akurasi sebesar 95.42%, pada model yang kedua <i>Inception-v3</i> <i>global average pooling layer</i> mendapatkan akurasi sebesar 95.71%, dan pada model yang ketiga <i>Inception-v3</i> <i>global average pooling layer</i> dengan <i>full connected layer</i> menghasilkan akurasi 95.38%.	Diharapkan pada penelitian selanjutnya mencoba membandingkan arsitektur <i>convolutional neural network</i> yang lain untuk mengetahui metode yang paling optimal, dan dilakukan proses <i>preprocessing</i> data yang lebih baik.	Pada penelitian yang akan dilakukan mencoba membandingkan metode <i>Convolutional Neural Network</i> dan <i>Support Vector Machine</i> untuk mengetahui metode yang paling optimal, dan dilakukan proses <i>preprocessing</i> data yang lebih baik.
11	Klasifikasi penyakit citra daun anggur menggunakan model CNN-VGG16	Moh. Arie Hasan, Yan Riyanto, Dwiza Riiana, 2021, Jurnal Teknologi dan Sistem Komputer	Bertujuan untuk mengklasifikasi jenis penyakit daun tanaman anggur berdasarkan citra daun dengan algoritma <i>K-Means</i> sebagai metode untuk <i>segmentasi</i> citra dan kemudian hasil <i>segmentasi</i> dilakukan ekstraksi fitur menggunakan <i>transfer learning</i> dengan metode VGG16	Dari Penelitian yang telah dilakukan dengan dataset sebesar 4000 citra & 100 citra menghasilkan nilai akurasi pada proses <i>training</i> sebesar 99,5%, sedangkan pada proses <i>testing</i> menghasilkan nilai akurasi 97,25% dan pada pengujian dari citra <i>Google</i> menghasilkan nilai akurasi sebesar 95%.	Pada penerapannya tidak dijelaskan langkah-langkah penggunaan fungsi algoritma <i>K-Means</i> sebagai metode <i>segmentasi</i> pada citra daun anggur	Pada penelitian yang akan dilakukan menggunakan fitur 6 ekstraksi pada <i>GLCM</i> , serta membandingkan metode <i>Convolutional Neural Network</i> dengan <i>optimizer Adam</i> dan <i>Support Vector Machine</i> dengan kernel <i>RBF</i> untuk mengetahui metode yang paling optimal.

Tabel 2.1. Matriks literatur review dan posisi penelitian (lanjutan)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
12	Implementasi Gray Level Co Occurrence Matrix (GLCM) Untuk Klasifikasi Penyakit Daun Padi	Arif Akbarul Huda, Bayu Setaji, Fajar Rosyid Hidayat, 2022, Jurnal Pseudocode	Penelitian ini melakukan identifikasi jenis penyakit menggunakan metode klasifikasi KNN berdasarkan ekstraksi fitur GLCM dengan mengubah citra asli menjadi citra keabu-abuan ( <i>grayscale</i> )	Dari pengujian yang telah dilakukan dengan menggunakan dataset berjumlah 240 gambar serta dengan memanfaatkan fitur GLCM mampu menghasilkan tingkat akurasi tertinggi yang didapatkan sebesar 93,3%	Diharapkan pada penelitian selanjutnya bisa mencoba melakukan ekstraksi fitur atau dengan mencoba menambahkan beberapa metode untuk membandingkan kinerja model.	Pada penelitian yang akan dilakukan menggunakan fitur 6 ekstraksi pada GLCM, serta mengkomparasi metode CNN dengan <i>optimizer</i> Adam dan SVM dengan kernel RBF untuk mengetahui metode yang paling optimal.
13	Klasifikasi Daun Herbal Menggunakan Metode CNN dan Naive Bayes dengan Fitur GLCM	Adela Regita Azzahra, Purnawansyah, Herdianti Darwis, Dewi Widyawati, 2023, Indonesian Journal of Computer Science	Penelitian ini membandingkan beberapa metode yaitu <i>convolutional neural network</i> , <i>convolutional neural network + Gray Level Co-occurrence Matrix</i> , <i>naive bayes</i> dengan menerapkan beberapa kernel seperti <i>gaussian</i> , <i>multinomial</i> , dan <i>bernoulli</i> . Model citra yang digunakan yaitu citra kondisi terang, dan kondisi gelap.	Dengan menggunakan dataset citra sebanyak 480 data dan memanfaatkan fitur GLCM seperti <i>contrast</i> , <i>energy</i> , <i>correlation</i> , <i>homogeneity</i> , <i>dissimilarity</i> , dan <i>ASM</i> pada penelitian ini mampu menghasilkan kinerja model pada metode CNN sebesar 98%.	Untuk dataset bisa ditingkatkan sehingga dalam proses training bisa menghasilkan model yang lebih optimal	Pada penelitian yang akan dilakukan menggunakan fitur 6 ekstraksi pada GLCM, serta mengkomparasi metode CNN dengan <i>optimizer</i> Adam dan SVM dengan kernel RBF untuk mengetahui metode yang paling optimal.

Tabel 2.1. Matriks literatur review dan posisi penelitian (lanjutan)

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
14	Identifikasi Penyakit pada Citra Daun Kentang Menggunakan Convolutional Neural Network (CNN)	Alang Mulya Lesmana, Ronna Putri Pädhillah, Chaerur Rozikin, 2022, Jurnal Sains dan Informatika	Penelitian ini bertujuan untuk mengklasifikasi penyakit daun tanaman kentang dengan menggunakan metode <i>convolutional neural network</i> . Penelitian ini melakukan perbandingan rasio pembagian data training dan data testing yaitu 90:10, 80:20 dan 70:20	Dari pengujian yang dilakukan dengan menggunakan data citra sebanyak 5400 data yang terbagi menjadi 3 kelas menghasilkan nilai akurasi sebesar diatas 90% dengan menerapkan metode <i>convolutional neural network</i>	Diharapkan pada penelitian selanjutnya bisa dilakukannya proses <i>preprocessing</i> .	Pada penelitian yang akan dilakukan menggunakan fitur 6 ekstraksi pada GLCM, serta mengkomparasi metode CNN dengan <i>optimizer</i> Adam dan SVM dengan kernel RBF untuk mengetahui metode yang paling optimal.

## 2.3. Landasan Teori

### 2.3.1. Citra Digital

Citra merupakan kombinasi antara titik, garis dan warna untuk menciptakan suatu imitasi dari sebuah objek. Citra bisa berwujud gambar dua dimensi, seperti lukisan, foto, dan berwujud tiga dimensi, seperti patung. Citra terbagi 2 yaitu ada citra yang bersifat analog dan ada citra yang bersifat digital. Citra analog tidak dapat direpresentasikan dalam komputer, sehingga tidak bisa diproses oleh komputer secara langsung. Citra analog harus dikonversi menjadi citra digital terlebih dahulu agar dapat diproses dikomputer (Sutojo dkk., 2017).

$$f(x, y) = \begin{bmatrix} f(0,0) & f(0,1) & \dots & f(0, N-1) \\ f(1,0) & f(1,1) & \dots & f(1, N-1) \\ \vdots & \vdots & \vdots & \vdots \\ f(M-1,0) & f(M-1,1) & \dots & f(M-1, N-1) \end{bmatrix}$$

Gambar 2.1. Matriks Citra Digital

Pada Gambar 2.1 merupakan contoh penulisan citra digital ke dalam suatu matriks. Sebuah gambar dapat didefinisikan sebagai fungsi dua dimensi  $f(x, y)$  di mana  $x$  dan  $y$  adalah koordinat, dan amplitudo dari setiap pasangan koordinat  $(x, y)$  disebut intensitas atau skala keabuan dari bayangan pada titik tersebut. Jika nilai  $x$ ,  $y$  dan intensitas  $f$  semuanya berhingga, besaran diskrit, kita menyebutnya bayangan itu sebagai bayangan digital (Gonzalez & Woods, 2008).

### 2.3.2. Pengolahan Citra Digital

Pengolahan citra digital atau bisa disebut *image processing* merupakan proses pengolahan pada suatu citra dengan hasil keluaran berupa citra juga (Nafi'iyah & Mujilahwati, 2018). Pada tujuan awalnya, pengolahan citra digunakan untuk memperbaiki sebuah citra. Namun dengan seiring perkembangan zaman bersama dengan perkembangan teknologi, pengolahan citra semakin berkembang dan banyak digunakan untuk berbagai kebutuhan. Seiring perkembangannya, pengolahan citra memiliki tujuan sebagai berikut:

- a. Perbaikan kualitas yang dimiliki citra, dimana keluaran dari hasil pengolahan citra mampu memberikan informasi pada citra secara lebih jelas.
- b. Ekstraksi ciri dari suatu citra, hasil keluaran dari proses pengolahan ini adalah berupa informasi citra dimana mendapatkan informasi ciri dari citra secara numerik atau dengan kata lain komputer melakukan interpretasi informasi yang ada pada citra melalui besaran data yang dapat dibedakan secara jelas.

### 2.3.3. Citra HSV

HSV merupakan representasi warna yang terdiri dari 3 komponen yaitu *Hue* merupakan skala yang mewakili warna dari 0 sampai 360°. *Saturation* menggambarkan seberapa variasi warna, semakin berwarna semakin tinggi nilainya. *Value* menunjukkan nilai pencahayaan warna, namun pada nilai yang sangat rendah akan sulit untuk membedakan warna (Fadholi dkk., 2019). Citra HSV



merupakan warna yang diturunkan dari citra RGB, sehingga untuk mendapatkan citra HSV diperlukan untuk mengonversi dari citra RGB (Saputro & Purnamasari, 2022). Untuk mendapatkan ruang warna pada citra HSV, perlunya untuk menganalisis nilai warna RGB pada setiap piksel citra sesuai setiap fitur yang diinginkan dengan nilai toleransi warna HSV (Chandra & Yoannita, 2023). Persamaan *Hue Saturation Value* dapat digambarkan pada persamaan berikut:

$$\theta = \cos^{-1} \left\{ \frac{\frac{1}{2}[(R-G) + (R+B)]}{\sqrt{[(R-G)^2 + (R-B)(G-B)]^{\frac{1}{2}}}} \right\} \quad (1)$$

Menghitung nilai *Hue*:

$$H = \begin{cases} \theta & \text{jika } B \leq G \\ 360 - \theta & \text{jika } B > G \end{cases} \quad (2)$$

Menghitung nilai *Saturation*:

$$S = \begin{cases} 0 & \text{jika } V = 0 \\ 1 - \frac{\min(r,g,b)}{V} & \text{jika } V > 0 \end{cases} \quad (3)$$

Menghitung nilai *Value*:

$$V = \max(r, g, b) \quad (4)$$

#### 2.3.4. Citra Grayscale

Sebuah citra dalam format RGB pada dasarnya terdiri dari tiga komponen warna yaitu *Red*, *Green*, dan *Blue* (Sunardi dkk., 2018). Setiap komponen warna memiliki tingkat intensitas yang direpresentasikan oleh angkut bulat antara 0 hingga 255. Sedangkan pada citra *greyscale*, hanya satu jenis warna yang digunakan untuk merepresentasikan gambar. Warna pada *greyscale* diubah menjadi skala abu-abu atau tingkat kecerahan yang beragam, berkisar dari 0 hingga 255. Angka 0 menggambarkan warna hitam, sedangkan angka 255 menggambarkan warna putih.

Citra dalam format RGB dapat dikonversikan menjadi citra *grayscale* menggunakan perasamaan berikut:


$$\text{Grayscale} = 0,299 R + 0,587 G + 0,144 B \quad (5)$$

### 2.3.5. Gray Level Co-occurrence Matrix

*Gray Level Co-occurrence Matrix* (GLCM) merupakan metode identifikasi karakteristik yang digunakan dalam mengambil informasi seperti tekstur dan warna pada citra dengan menganalisis hubungan antara piksel-piksel yang saling berdekatan (Zalvadila dkk., 2023). Metode GLCM hanya mampu mendeteksi citra warna *grayscale*, karna itu citra harus dirubah menjadi *grayscale* terlebih dahulu (Ullu dkk., 2022). GLCM mampu menggambarkan hubungan antara dua piksel tetangga yang memiliki intensitas keabuan, jarak, dan sudut tertentu (Rohman dkk., 2021). Sudut pola yang dihasilkan dari piksel matriks dimensi 8x8 membentuk empat interval sudut yaitu  $0^\circ$ ,  $45^\circ$ ,  $90^\circ$ , dan  $135^\circ$  dengan menggunakan dua piksel yang berjajar. Operasi perhitungan dilakukan terhadap nilai dua piksel yang berjajar melalui proses normalisasi.

Menurut (Ihsan dkk., 2022) dengan menerapkan sudut  $0^\circ$ ,  $45^\circ$ ,  $90^\circ$ ,  $135^\circ$  dalam mengekstraksi citra menggunakan fitur-fitur metode GLCM akan mendapatkan hasil akhir akurasi yang baik. Sudut  $0^\circ$ ,  $45^\circ$ ,  $90^\circ$ ,  $135^\circ$  merupakan posisi dari citra, dimana sudut  $0^\circ$  merupakan posisi awal citra yang akan dilakukan perhitungan ke arah kanan secara (*horizontal*), kemudian sudut  $45^\circ$  yaitu posisi citra dilakukan ke arah kanan bagian atas. Sedangkan sudut  $90^\circ$  diputar secara (*vertical*), dan pada  $135^\circ$  merupakan sudut ketika gambar diputar pada posisi miring ke arah

kiri bagian atas. Sudut  $0^\circ$ ,  $45^\circ$ ,  $90^\circ$ ,  $135^\circ$  dapat ditampilkan pada gambar 2.2 sebagai berikut.



Gambar 2.2. Sudut *Gray Level Co-occurrence Matrix*

Dari piksel dengan berbagai sudut tersebut terbentuk matrik ko-okurensi untuk pembentukan citra *grayscale* yang dapat diidentifikasi dengan menggunakan 6 fitur ekstraksi pada GLCM sebagai berikut:

a. *Contrast*

*Contrast* merupakan ukuran perhitungan yang berkaitan dengan jumlah keberagaman intensitas keabuan dalam citra. Rumus menghitung *contrast* ditunjukkan pada persamaan 6:

$$\text{Contrast} = \sum_{i,j} (i - j)^2 P_{(i,j)} \quad (6)$$

Keterangan:

$i$  = Nilai pada baris

$j$  = Nilai pada Kolom

$P_{(i,j)}$  = Nilai piksel pada koordinat  $i,j$  GLCM matriks

b. *Dissimilarity*

*Dissimilarity* merupakan perhitungan untuk mengukur perbedaan rata-rata nilai piksel yang berdekatan dalam sebuah citra. Semakin tinggi nilainya

maka semakin kasar tekstur sebuah citra. Rumus perhitungan *dissimilarity* ditunjukkan pada persamaan 7.

$$Dissimilarity = \sum_{i,j} |i - j| P_{(i,j)} \quad (7)$$

Keterangan:

$i$  = Nilai pada baris

$j$  = Nilai pada Kolom

$P_{(i,j)}$  = Nilai piksel pada koordinat  $i,j$  GLCM matriks

$|i-j|$  = nilai jarak antara  $i$  dan  $j$

c. *Homogeneity*

*Homogeneity* merupakan mengukur keseragaman distribusi nilai piksel dalam citra. Semakin tinggi nilainya, semakin seragam tekstur citranya.

Rumus perhitungan *homogeneity* ditunjukkan pada persamaan 8.

$$Homogeneity = \sum_{i,j} \frac{1}{1+|i-j|} P_{(i,j)} \quad (8)$$

Keterangan:

$i$  = Nilai pada baris

$j$  = Nilai pada Kolom

$P_{(i,j)}$  = Nilai piksel pada koordinat  $i,j$  GLCM matriks

$|i-j|$  = nilai jarak antara  $i$  dan  $j$

d. *Correlation*

*Correlation* mengukur hubungan linear antara nilai piksel yang berdekatan dalam citra grayscale. Semakin tinggi nilai korelasi, semakin teratur tekstur citranya. Rumus perhitungan *correlation* ditunjukkan pada persamaan 9.

$$\text{Correlation} = \sum_{i,j} \frac{(i-\mu)(j-\mu)P_{(i,j)}}{\sigma_i\sigma_j} \quad (9)$$

Keterangan:

$i$  = Nilai pada baris

$j$  = Nilai pada Kolom

$\mu$  = Jumlah Nilai  $i,j$

$\sigma$  = Standard deviasi

$P_{(i,j)}$  = Nilai piksel pada koordinat  $i,j$  GLCM matriks

e. *Angular Second Moment (ASM)*

ASM termasuk kedalam kelompok pengukuran tekstur *ordelines* yang membantu perhitungan ekstraksi energi dan membantu nilai tertinggi beraturan. Rumus perhitungan ASM ditunjukkan pada persamaan 10.

$$\text{ASM} = \sum_{i,j} P_{(i,j)}^2 \quad (10)$$

Keterangan:

$i$  = Nilai pada baris

$j$  = Nilai pada Kolom

$P_{(i,j)}$  = Nilai piksel pada koordinat  $i,j$  GLCM matriks

f. *Energy*

*Energy* berfungsi untuk menghitung jumlah variasi intensitas abu-abu dalam suatu citra. Jika mendapatkan fitur ASM, energi diperoleh dari akar nilai ASM. Rumus perhitungan *energy* ditunjukkan pada persamaan 11.

$$\text{Energy} = \sqrt{\text{ASM}} \quad (11)$$


### 2.3.6. Klasifikasi

Klasifikasi atau *classification* merupakan proses untuk mengetahui fungsi sebuah model yang dapat mengenali sebuah kelas atau label data dengan tujuan untuk memprediksi kelas yang tidak diketahui sebelumnya (Yendra dkk., 2020). Klasifikasi sering digunakan dalam berbagai hal, di antaranya untuk deteksi penggunaan masker, deteksi kematangan buah, identifikasi penyakit, dan masih banyak lainnya. Dalam proses klasifikasi, memiliki 2 tahap yakni proses *training* dan proses *testing*. Pada proses *training*, membangun sebuah model dari data sampel suatu objek yang telah diketahui labelnya. Sedangkan pada proses *testing*, model yang telah dibangun dilakukan pengujian dalam mendefinisikan setiap label pada objek untuk mengetahui tingkat keakuratan sebuah model.

### 2.3.7. Convolutional Neural Network

*Convolutional Neural Network* (CNN) merupakan hasil pengembangan dari *Multilayer Perception* (MLP) yang dirancang untuk mengolah data skala besar dan diaplikasikan untuk mengolah citra tiga dimensi (Segal-Rozenhaimer dkk., 2020). Metode CNN merupakan metode pemrosesan gambar yang digunakan untuk mengidentifikasi benda atau mendeteksi suatu objek (Qian dkk., 2020). Metode CNN banyak digunakan dalam mengklasifikasikan dan pengenalan citra yang sudah diberi label dengan menggunakan metode *supervised learning*. Pada *Supervised learning* terdapat data yang dilatih dan variabel yang ditargetkan sehingga tujuan dari metode ini adalah mengelompokkan suatu data ke data yang sudah ada. Pada arsitektur CNN dapat menangkap informasi kontekstual yang

terkandung di dalam data seperti piksel yang saling berdekatan pada sebuah citra, yang berarti model CNN dapat melakukan ekstraksi ciri pada sebuah citra secara mandiri. Adapun arsitektur umum yang sering dijumpai pada CNN dapat dilihat pada Gambar 2.3.



Gambar 2.3. Arsitektur *Convolutional Neural Network*

Pada metode *convolutional neural network* pada dasarnya terdiri dari beberapa layer yang digunakan untuk proses klasifikasi, diantaranya :

a. *Layer Input*

Pada lapisan layer ini merupakan dimana citra yang akan digunakan sebagai dataset dimasukkan untuk proses klasifikasi ke dalam model klasifikasi.

b. *Layer Convolutional*

Lapisan Konvolusi (*Layer Convolution*) memiliki tugas untuk mengurangi kompleksitas perhitungan sesuai dengan prinsip *sliding window* dan *weight sharing* (Putra, 2020). Tujuan konvolusi pada data citra adalah untuk mengekstraksi fitur dari citra *input*. Konvolusi akan menghasilkan transformasi linear dari data *input* sesuai informasi spasial pada data. Bobot pada *layer* tersebut menspesifikasikan kernel konvolusi yang digunakan, sehingga kernel konvolusi dapat dilatih berdasarkan *input* pada CNN.

c. *Layer ReLu*

Layer ini merupakan fungsi aktivasi dari output layer sebelumnya. Pada metode *Convolutional Neural Network*, fungsi aktivasi terletak pada perhitungan akhir keluaran *feature map* atau sesudah proses perhitungan konvolusi atau *pooling* untuk menghasilkan suatu pola fitur. Pada fungsi ReLU atau *Rectified Linear Unit* melakukan *threshold* dari 0 hingga *infinity*, dalam artian fungsi ini masukan dari neuron-neuron berupa bilangan negatif, maka fungsi ini akan menerjemahkan nilai tersebut ke dalam nilai 0, dan jika masukan bernilai positif maka *output* dari *neuron* adalah nilai aktivasi itu sendiri.

d. *Layer Pooling*

*Pooling Layer* merupakan lapisan yang dimasukkan di antara lapisan konvolusi untuk mengurangi ukuran *volume output* pada *feature map* sehingga akan mampu mengendalikan *overfitting*. *Pooling layer* berfungsi untuk mengambil nilai maksimal (*max-pooling*) atau nilai rata-rata (*average pooling*) dari bagian piksel pada sebuah citra. *Max-pooling* digunakan untuk membagi nilai *output* dari *convolution layer* menjadi beberapa *grid* lalu mengambil nilai maksimal dari setiap *grid* untuk menyusun matriks citra yang telah direduksi. Fungsi utama *pooling layer* bertujuan untuk mengurangi ukuran citra sehingga dapat dengan mudah digantikan dengan sebuah *convolution layer* dengan *stride* yang sama dengan *pooling layer* yang digunakan.




e. *Layer Full Connected*

*Fully Connected Layer* merupakan lapisan dimana semua neuron aktivasi dari lapisan sebelumnya terhubung semua dengan neuron di lapisan selanjutnya. *Fully connected layer* digunakan dalam penerapan *Multi Layer Perceptron* (MLP) dengan bertujuan untuk melakukan transformasi pada dimensi data agar dapat diklasifikasikan secara linear.

### 2.3.8. Support Vector Machine

*Support Vector Machine* (SVM) merupakan sistem model pembelajaran yang menggunakan ruang hipotesis berupa fungsi-fungsi *linier* dalam sebuah ruang fitur (*feature space*) berdimensi tinggi, dilatih dengan metode pembelajaran yang didasarkan pada teori optimasi dengan mengimplementasikan *learning* bias yang berasal dari teori pembelajaran statistik (Cristianini & Taylor, 2000). Metode SVM banyak digunakan untuk menganalisis data, terutama dibidang pengolahan gambar, SVM berfungsi sebagai model *classifier* atau sebagai model referensi untuk memberikan informasi yang bermakna dengan menganalisis data input.

SVM digunakan untuk mencari *hyperplane* terbaik dengan memaksimalkan jarak antar kelas. *Hyperplane* merupakan sebuah metode yang dapat digunakan untuk pemisah antar kelas. Dalam 2-D fungsi yang digunakan untuk klasifikasi antar kelas disebut sebagai *line whereas*, fungsi yang digunakan untuk klasifikasi antar kelas dalam 3-D disebut *plane similarly*, sedangkan fungsi yang digunakan untuk klasifikasi di dalam ruang kelas dimensi yang lebih tinggi disebut *hyperplane* (Cristianini & Taylor, 2013).



Gambar 2.4. SVM berusaha menemukan *hyperplane* terbaik

Pada gambar 2.4 menunjukkan jika *hyperplane* berada ditengah-tengah di antara dua kelas, artinya jarak antara *hyperplane* dengan objek-objek data berbeda dengan kelas yang berdekatan (terluar) yang diberikan tanda kotak dan lingkaran. Dalam SVM objek data terluar yang paling dekat dengan *hyperplane* dan *support vector*. Objek yang disebut *support vector* paling sulit diklasifikasikan dikarenakan posisi yang hampir tumpang tindih (*overlap*) dengan kelas lain. Mengingat sifatnya yang kritis, hanya *support vector* inilah yang diperhitungkan untuk menemukan *hyperplane* yang paling optimal oleh SVM. Untuk mendapatkan garis *hyperplane* yang optimal untuk memisahkan data dari dua kelas, digunakan perhitungan batas *hyperplane* dan dicari titik maksimumnya. Cara mendapatkan *hyperplane* pada *support vector* menggunakan persamaan:

$$(w \cdot x_i) + b = 0 \quad (12)$$

Jika didalam data  $x_i$ , yang termasuk pada kelas -1 dapat dirumuskan seperti persamaan :

$$(w \cdot x_i) + b \leq 1, y_i = -1 \quad (13)$$

Jika didalam data  $x_i$ , yang termasuk pada kelas +1 dapat dirumuskan seperti persamaan :

$$(w \cdot x_i) + b \leq 1, y_i = 1 \quad (14)$$

### 2.3.9. Confusion Matrix

Metode *confusion matrix* merupakan metode pengujian untuk mengetahui kinerja pada suatu model pada metode klasifikasi. Metode ini berupa matriks yang berisikan label hasil prediksi dari metode klasifikasi dan label data sesungguhnya (Iswantoro & Handayani UN, 2022). Saat mengukur kinerja dengan *confusion matrix*, terdapat 4 (empat) *term* yang mewakili hasil proses klasifikasi. Keempat suku tersebut adalah *true positive* (TP), *true negative* (TN), *false positive* (FP), dan *false negative* (FN). Pada tabel 2.1 merupakan tabel dari *confusion matrix*.

Tabel 2.1. Rumus *Confusion Matrix*

	<i>Positive</i>	<i>Negative</i>
<i>Positive</i>	<i>TP (True Positive)</i>	<i>FP (False Positive)</i>
<i>Negative</i>	<i>TN (True Negative)</i>	<i>FN (False Negative)</i>

Keterangan:

- True Positive* (TP) merupakan data yang diprediksikan dengan tepat sebagai keluaran positif atau benar.
- True Negative* (TN) merupakan data yang diprediksikan tepat sebagai keluaran negatif atau salah
- False Positive* (FP) merupakan data prediksi yang kurang tepat apabila keluaran positif atau benar.

- d. *False Negative* (FN) merupakan data yang diprediksikan kurang tepat apabila keluaran negatif atau salah.

Dalam mengukur kinerja sebuah model klasifikasi, ada beberapa model kinerja pada *confusion matrix* yang biasanya digunakan diantaranya akurasi, *recall*, dan presisi (Harani dkk., 2019).

- a. Akurasi

Akurasi merupakan gambaran seberapa akurat model dalam mengklasifikasi data dengan sesuai dan tepat. Persamaan nilai akurasi sebagai berikut:

$$Akurasi = \frac{TP+TN}{TP+TN+FN+FP} \quad (15)$$

- b. Presisi

Presisi merupakan gambaran dari tingkat keakuratan dari data yang diminat dengan hasil prediksi yang diberikan oleh model. Persamaan nilai presisi sebagai berikut:

$$Presisi = \frac{TP}{TP+FP} \quad (16)$$

- c. Recall

Recall merupakan gambaran perhitungan kebenaran negatif dibandingkan keseluruhan data negatif. Persamaan nilai recall sebagai berikut:

$$Recall = \frac{TN}{TN+TP} \quad (17)$$

## **BAB III**

### **METODE PENELITIAN**

#### **3.1. Jenis, Sifat, dan Pendekatan Penelitian**

Jenis penelitian yang digunakan pada penelitian ini bersifat eksperimental, dimana melakukan beberapa skenario percobaan guna menghasilkan akurasi yang tinggi. Eksperimen yang dilakukan adalah penerapan perbandingan metode klasifikasi dalam mendeteksi penyakit daun tanaman jagung dengan memanfaatkan ekstraksi fitur *Gray Level Co-occurrence Matrix* (GLCM), dengan menggunakan metode *Convolutional Neural Network* (CNN) dan *Support Vector Machine* (SVM). Dari penerapan kedua metode ini, akan dilakukan pengujian untuk mengetahui metode mana yang lebih akurat dan tepat dalam mengidentifikasi penyakit daun pada tanaman jagung.

Sifat penelitian pada penelitian ini adalah deskriptif, karena untuk mengetahui perbandingan tingkat nilai akurasi, presisi, dan recall pada identifikasi penyakit daun tanaman jagung menggunakan metode CNN dan SVM. Pendekatan pada penelitian ini adalah kuantitatif yaitu suatu proses yang dilakukan untuk menggali data berupa angka sebagai alat yang nantinya akan dianalisis untuk mengetahui temuan-temuan setelah proses pengujian berlangsung.

#### **3.2. Metode Pengumpulan Data**

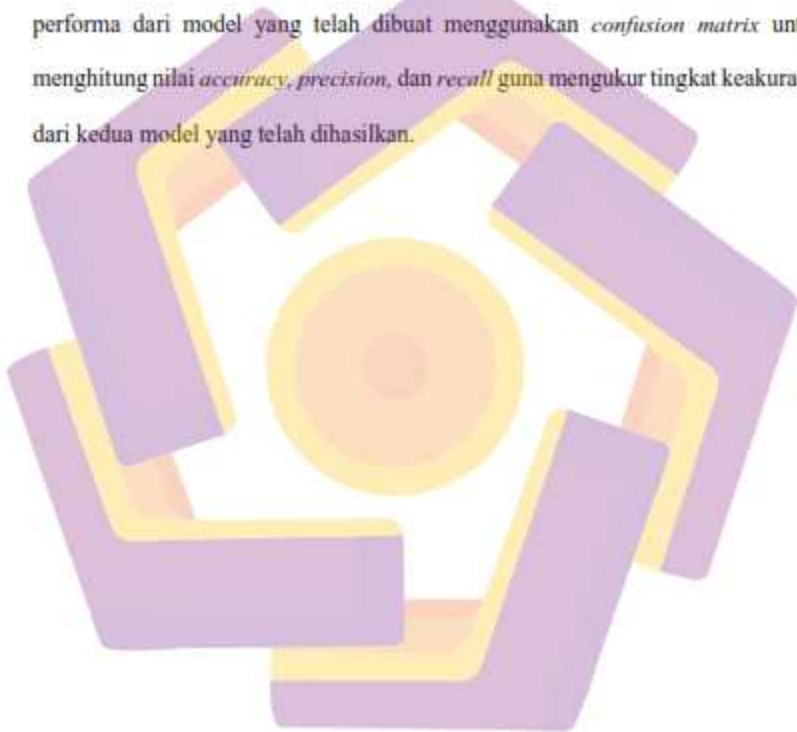
Data yang digunakan dalam penelitian ini memanfaatkan layanan penyedia data bersifat publik sehingga setiap orang dapat mengakses dan melakukan

penelitian dari sumber tersebut. Situs layanan penyedia data publik yang digunakan adalah *www.kaggle.com*. Data yang digunakan berupa gambar atau citra digital daun jagung, yang di bersumber situs *Kaggle* dengan judul *Corn or Maize Leaf Disease Dataset* yang dikontribusikan oleh Smaranjit Ghose. Data penelitian ini telah digunakan di beberapa penelitian sebelumnya yaitu (Singh dkk., 2019) dengan judul *PlanDoc: A Dataset For Visual Plant Diseases Dataset* dan (Geetharamani & J., 2019) dengan judul *Identification of Plant Leaf Diseases Using a 9-layer Deep Convolutional Neural Network*. Data citra daun jagung yang digunakan terbagi ke dalam 4 kelas yaitu 1 jenis daun sehat dan 3 jenis daun berpenyakit yaitu *Blight*, *Common Rust*, dan *Grey Leaf Spot*.

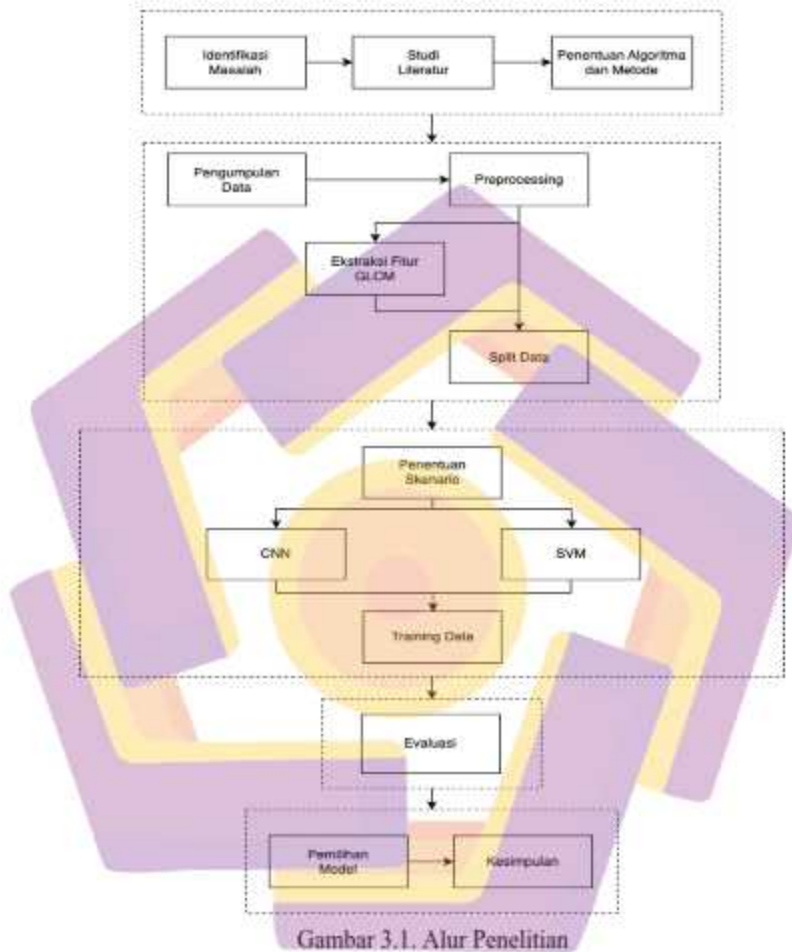
### 3.3. Metode Analisis Data

Metode analisis data merupakan tahapan pengolahan data untuk mendapatkan hasil yang paling optimal dari permasalahan yang telah dirumuskan. Metode analisis yang digunakan pada penelitian ini berupa analisis kuantitatif menggunakan *Convolutional Neural Network (CNN)* dan *Support Vector Machine (SVM)*. Citra daun jagung yang telah diperoleh dari proses pengumpulan data akan dilakukan *preprocessing* sebelum dilakukan klasifikasi. Dalam penelitian ini menerapkan dua skenario pada tahap *preprocessing* yaitu menerapkan ekstraksi fitur citra menggunakan *Gray Level Co-occurrence Matrix (GLCM)* dan tanpa menggunakan ekstraksi fitur citra *GLCM*. Pada *preprocessing* data ada beberapa tahapan yaitu mengubah semua citra menjadi citra *HSV (Hue Saturation Value)*, kemudian mengubah citra *HSV* menjadi citra *grayscale*, menyeragamkan ukuran

piksel semua citra dan melakukan ekstraksi fitur menggunakan Gray Level Co-occurrence Matrix (GLCM). Pada tahap selanjutnya yaitu merancang 2 skenario percobaan dengan menggunakan metode CNN dan metode SVM. Dalam skenario percobaan, penelitian ini menerapkan proporsi pembagian data sebesar 80% untuk data *training* dan 20% untuk data *testing*. Selanjutnya, dilakukan pengujian performa dari model yang telah dibuat menggunakan *confusion matrix* untuk menghitung nilai *accuracy*, *precision*, dan *recall* guna mengukur tingkat keakuratan dari kedua model yang telah dihasilkan.



### 3.4. Alur Penelitian



Dalam menyelesaikan penelitian identifikasi penyakit pada daun tanaman jagung, terdapat beberapa tahapan-tahapan yang dilakukan secara bertahap. Alur metode penelitian yang akan dilakukan ditunjukkan pada Gambar 3.1. Tahapan-tahapan penelitian ini dapat dijelaskan lebih lanjut sebagai berikut:



a. Identifikasi Masalah

Dalam tahap ini dilakukannya mencari topik permasalahan yang berada dilapangan maupun dari sumber informasi yang dapat dipercaya, seperti artikel maupun jurnal, kemudian mengidentifikasi masalah untuk dijadikan topik utama.

b. Studi Literatur

Pada tahap selanjutnya, dilakukannya mencari informasi terkait topik masalah yang diambil dari berbagai sumber karya ilmiah yang berkaitan dan relevan. Proses ini juga digunakan sebagai acuan menentukan metode dan algoritma yang akan digunakan.

c. Penentuan Algoritma dan Metode

Setelah mengumpulkan informasi dari sumber terkait, maka perlunya menentukan algoritma dan metode yang paling cocok digunakan untuk menyelesaikan permasalahan yang ada. Dalam penelitian ini, algoritma yang digunakan adalah *Convolutional Neural Network (CNN)* dan *Support Vector Machine (SVM)* dengan menggunakan metode ekstraksi fitur GLCM.

d. Pengumpulan Data

Pada tahap berikutnya adalah mengumpulkan *dataset* yang diperlukan dan relevan dari topik permasalahan yang diangkat. Data yang digunakan dalam penelitian ini berupa citra atau gambar yang bersumber dari situs penyedia data publik yang dapat diakses oleh umum.

e. Preprocessing

Pada tahap ini dilakukannya proses *preprocessing* dimana data citra penyakit daun jagung yang telah dikumpulkan dilakukan serangkaian tahapan diantaranya mengubah citra RGB menjadi citra HSV, mengubah hasil citra HSV menjadi citra *greyscale*, dan mengubah semua citra *greyscale* kedalam ukuran piksel yang sama.

f. Ekstraksi Fitur GLCM

Setelah data citra penyakit daun tanaman jagung dilakukan proses *preprocessing*, selanjutnya dilakukannya proses ekstraksi fitur teksur pada semua citra menggunakan metode GLCM. Dari proses ini akan menghasilkan 6 fitur seperti *energy*, *ASM*, *contrast*, *correlation*, *homogeneity*, dan *dissimilarity*.

g. Split Data

Setelah tahap ekstraksi fitur GLCM, maka dilakukannya proses pembagian hasil ekstraksi fitur GLCM menjadi dua bagian yaitu data *training* dan data *testing*, dengan pembagian 80% data *training* dan 20% data *testing*.

h. Skenario Penelitian

Pada tahap berikutnya ialah menentukan langkah skenario penelitian yang akan dilakukan. Pada penelitian ini dilakukannya perbandingan metode klasifikasi untuk mencari akurasi tertinggi. Metode yang digunakan pada penelitian ini adalah *Convolutional Neural Network (CNN)* dan *Support Vector Machine (SVM)*.

i. Training Data

Setelah menentukan skenario penelitian, kemudian dilakukannya percobaan dengan menggunakan hasil ekstraksi fitur dan tanpa ekstraksi fitur GLCM pada citra daun tanaman jagung. Pada tahap training data bertujuan untuk melatih metode klasifikasi.

j. Evaluasi

Pada tahap ini dilakukannya evaluasi model klasifikasi yang telah dibuat menggunakan metode *confusion matrix* untuk mengetahui nilai *accuracy*, *precision*, dan *recall*.

k. Kesimpulan

Setelah mendapatkan hasil evaluasi setiap model klasifikasi, selanjutnya membuat kesimpulan dengan menganalisis hasil perbandingan setiap model untuk menentukan metode dengan tahap *preprocessing* mana yang menghasilkan nilai akurasi tertinggi.

## BAB IV

### HASIL PENELITIAN DAN PEMBAHASAN

#### 4.1. Pengumpulan Data

Pada penelitian ini menggunakan data yang bersifat sekunder yaitu data yang bersumber dari situs penyedia data publik yang dapat diakses oleh semua orang. Data yang digunakan pada penelitian ini berupa gambar atau citra penyakit daun jagung yang bersumber dari situs *kaggle* dengan judul *Corn or Maize Leaf Disease Dataset* yang dikontribusikan oleh Smaranjit Ghose pada tahun 2019 dengan alamat situs yang spesifik [www.kaggle.com/datasets/smaranjitghose/corn-or-maize-leaf-disease-dataset](http://www.kaggle.com/datasets/smaranjitghose/corn-or-maize-leaf-disease-dataset). Dataset ini telah digunakan pada beberapa penelitian sebelumnya seperti yang dilakukan oleh (Singh dkk., 2019) dan (Geetharamani & J., 2019). Data citra daun jagung yang digunakan pada penelitian ini berjumlah 4188 citra yang terbagi ke dalam 4 kelas yaitu 1 jenis daun sehat dan 3 jenis daun berpenyakit yaitu *blight*, *common rust*, dan *grey leaf spot*. Pembagian jumlah citra berdasarkan setiap kelasnya dapat dilihat pada tabel 4.1 sebagai berikut.

Tabel 4.1. Jumlah Data Citra Daun Jagung

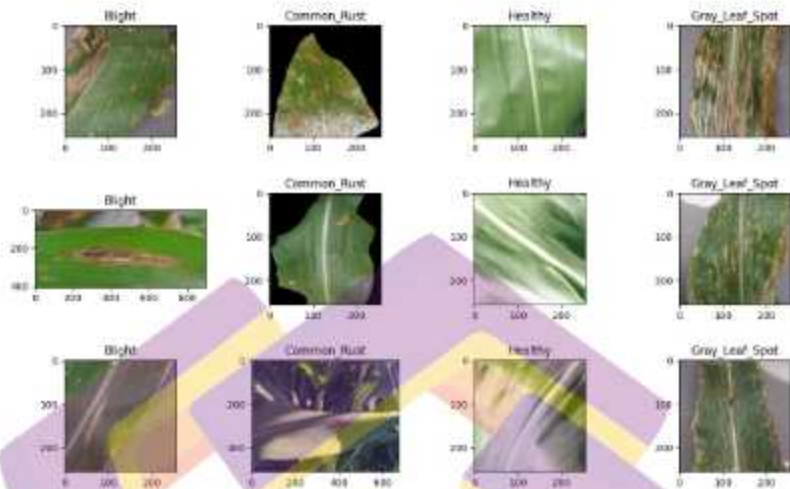
Kelas	Jumlah	Persentase (%)
<i>Blight</i>	1146	27%
<i>Common Rust</i>	1306	31%
<i>Grey Leaf Spot</i>	574	14%
<i>Healthy</i>	1162	28%
<b>Jumlah</b>	<b>4188</b>	<b>100%</b>

Merujuk pada tabel 4.1 menunjukkan jumlah dataset yang digunakan memiliki nilai yang tidak seimbang, terutama pada kelas penyakit *Grey Leaf Spot* yang hanya berjumlah 574 citra atau sebesar 14% dari keseluruhan dataset. Dalam mengatasi ketidakseimbangan data yang terjadi, diperlukan suatu teknik *augmentasi* data yang bertujuan untuk memperluas kompleksitas data dengan menambahkan jumlah sampel dalam dataset atau memodifikasi citra juga membuat proses training menjadi lebih kompleks, sehingga akan meningkatkan kinerja model yang lebih baik & akurat dalam memprediksi atau mengklasifikasikan jenis data tertentu (Gracia Moisés dkk., 2023). Pada penelitian ini menerapkan proses *augmentasi* data pada kelas penyakit *Grey Leaf Spot* menggunakan beberapa teknik seperti *rotate clockwise*, *vertical flip*, dan *blurring image*. Jumlah dataset yang telah dilakukan *augmentasi* data dapat dilihat pada tabel 4.2 sebagai berikut.

Tabel 4.2. Jumlah Dataset Augmentasi

Kelas	Jumlah	Persentase (%)
<i>Blight</i>	1146	24%
<i>Common Rust</i>	1306	27%
<i>Grey Leaf Spot</i>	1148	24%
<i>Healthy</i>	1162	25%
<b>Jumlah</b>	<b>4762</b>	<b>100%</b>

Pada Gambar 4.1 menunjukan contoh citra penyakit daun jagung berdasarkan setiap kelas yang digunakan dalam penelitian ini.

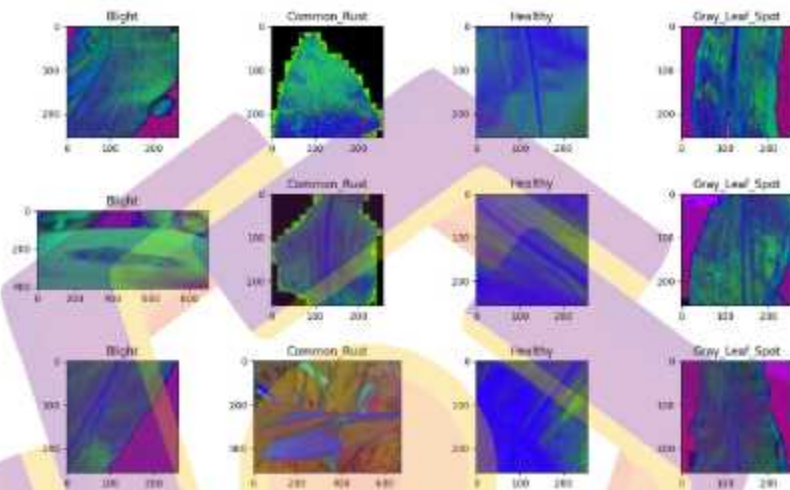


Gambar 4.1. Contoh Citra Daun Jagung

#### 4.2. Preprocessing Data


Tahap *preprocessing* data merupakan langkah yang digunakan untuk memproses citra daun jagung untuk menghindari data yang tidak ideal atau bias sehingga menghasilkan data yang optimal untuk digunakan dalam model klasifikasi sehingga akan menghasilkan performa yang tinggi dan akurat. Pada penelitian ini menerapkan beberapa langkah yang digunakan pada *preprocessing* data diantaranya yaitu mengubah semua citra RGB menjadi citra HSV (*Hue Saturation Value*), kemudian mengubah semua citra HSV menjadi citra *greyscale* atau menjadi citra skala keabuan, dan pada langkah terakhir yaitu mengubah semua citra *greyscale* kedalam ukuran piksel yang sama.

Pada langkah pertama, tahapan *preprocessing* data yaitu mengubah semua citra RGB menjadi Citra HSV yang dapat ditampilkan pada gambar 4.2 sebagai berikut.



Gambar 4.2. Tranformasi Citra RGB ke HSV


Berdasarkan pada gambar 4.2 menunjukkan proses transformasi warna yang semulanya citra RGB menjadi citra HSV (*Hue Saturation Value*). Semua citra dari semua kelas akan ditransformasi menjadi citra HSV, proses ini bertujuan untuk meningkatkan analisis warna yang lebih baik dan pemrosesan citra menjadi lebih efisien dengan mengisolasi warna tertentu atau mengubah warna dengan lebih presisi. Setelah melakukan langkah pertama, pada langkah berikutnya yaitu melakukan transformasi warna dari citra HSV menjadi citra *greyscale*. Hasil dari tranformasi citra ke *greyscale* dapat ditampilkan pada gambar 4.3 sebagai berikut.



Gambar 4.3. Transformasi Citra HSV ke *Grayscale*.

Pada gambar 4.3 diatas merupakan langkah mengubah semua citra HSV menjadi citra *greyscale* atau citra dengan skala keabuan. Proses ini bertujuan untuk mengurangi kompleksitas citra dan mengubahnya menjadi citra dengan satu skala warna keabuan. Dengan melakukan transformasi ini, memudahkan proses mengidentifikasi perbedaan tingkat kecerahan dalam analisis citra, tanpa terganggu oleh variasi warna yang mungkin tidak relevan dalam konteks tertentu sehingga memudahkan dalam proses ekstraksi menjadi lebih baik. Kemudian pada langkah selanjutnya yaitu mengubah semua citra *greyscale* kedalam ukuran piksel yang sama. Langkah ini dapat ditampilkan pada gambar 4.4 sebagai berikut.





Gambar 4.4. Menyamakan Ukuran Pixel Semua Citra.

Pada gambar 4.4 merupakan langkah untuk mengubah semua citra *greyscale* menjadi citra dengan ukuran pixel yang sama, yaitu 256x256 piksel. Tujuan dari langkah ini adalah untuk memastikan konsistensi setiap citra memiliki ukuran pixel yang sama sehingga mengurangi masalah ketidakseimbangan data saat citra dilakukan proses training oleh sistem.

#### 4.3. Ekstraksi Fitur GLCM

Pada tahap proses ekstraksi fitur pada citra daun tanaman jagung dengan menggunakan metode GLCM (*Gray Level Co-Occurrence Matrix*). Dengan menggunakan metode GLCM akan menghasilkan fitur tekstur *dissimilarity*, *correlation*, *homogeneity*, *contrast*, *ASM*, dan *energy*. Setiap fitur saling berkaitan satu sama lain untuk menghasilkan nilai ekstraksi yang baik dan akurat. Dalam menghitung tekstur gambar terdapat empat fitur yang wajib ada pada metode

GLCM yaitu *contrast* yang berfungsi untuk menghitung jumlah keberagaman intensitas keabuan dalam citra, *correlation* yaitu berfungsi mengukur hubungan linier antara piksel dan sudut lainnya, *energy* yang berfungsi untuk menghitung jumlah variasi intensitas abu-abu dalam suatu citra, dan *homogeneity* yang berfungsi mengukur nilai kesamaan variasi dari intensitas citra. Dalam penelitian ini menambahkan dua fitur lainnya yaitu *dissimilarity* dan ASM yang akan membantu dalam meningkatkan hasil ekstraksi fitur lebih akurat. Pada fitur *dissimilarity* berfungsi menghitung nilai peningkatan kualitas citra, dan pada fitur ASM berfungsi mengukur nilai *homogeneity* pada sebuah citra. Metode GLCM mempresentasikan hubungan 2 piksel yang bertetangga yang memiliki nilai intensitas keabuan, jarak, dan sudut. Terdapat empat sudut yang digunakan yaitu  $0^\circ$ ,  $45^\circ$ ,  $90^\circ$ ,  $135^\circ$ . Pada tabel 4.3 merupakan salah satu hasil ekstraksi fitur pada citra daun jagung.

Tabel 4.3. Hasil Ekstraksi Fitur GLCM

	<i>Dissimilarity - 0°, 45°, 90°, 135°</i>			
	25.87448643	28.48877236	27.47436815	27.58895503
	<i>correlation - 0°, 45°, 90°, 135°</i>			
	0.616858403	0.5593425481	0.5835245341	0.5820933792
	<i>homogeneity - 0°, 45°, 90°, 135°</i>			
	0.06810777915	0.05954077064	0.06500988899	0.065334603
	<i>Contrast - 0°, 45°, 90°, 135°</i>			
	1444.036121	1662.285006	1577.417782	1576.518125
	<i>ASM - 0°, 45°, 90°, 135°</i>			
	0.0001225118416	0.0001086493408	0.0001277168225	0.0001206302233
	<i>Energy - 0°, 45°, 90°, 135°</i>			
	0.01106850674	0.01042349945	0.01130118678	0.01098317911

Pada tabel 4.2 merupakan contoh hasil ekstraksi fitur dari salah satu kelas citra daun tanaman jagung menggunakan metode GLCM dan menghasilkan 24 fitur yang dihasilkan dari 4 variasi sudut dengan 6 variasi fitur.

Berikut merupakan proses perhitungan metode GLCM (*Gray Level Co-Occurrence Matrix*) dengan menerapkan 4 sudut yaitu  $0^\circ$ ,  $45^\circ$ ,  $90^\circ$ ,  $135^\circ$  terhadap pada masing-masing fitur yaitu *dissimilarity*, *correlation*, *homogeneity*, *contrast*, *ASM*, dan *energy*, yang menghasilkan 24 data fitur tekstur. Langkah-langkah perhitungan GLCM dapat dijelaskan lebih lanjut sebagai berikut.

#### 1. *Import* data citra kedalam program python

Pada langkah pertama yaitu melakukan *import* folder data citra daun tanaman jagung yang telah dikumpulkan dan telah diberikan label sesuai kelasnya. Langkah ini dapat dilihat pada gambar 4.5.

##### ▸ Import Dataset

```
[3] path_folder = "/content/drive/MyDrive/Kuliah 52/Tesis/dataset/data/"
diseases_class = os.listdir(path_folder)

[] nums = {}
for i in diseases_class:
    nums[i] = len(os.listdir(path_folder + i))

table = pd.DataFrame(columns = ['Kelas', 'Jumlah'])
table['Kelas'] = diseases_class
table['Jumlah'] = nums.values()

table
```

	Kelas	Jumlah
0	Blight	1146
1	Common_Rust	1308
2	Healthy	1162
3	Gray_Leaf_Spot	574

Gambar 4.5. Potongan Kode Import dan Menampilkan Jumlah Data

Pada gambar 4.5 merupakan potongan kode yang digunakan untuk *import* folder data citra daun tanaman jagung dengan menggunakan library *OS*, dan menampilkan jumlah data setiap kelas dalam bentuk tabel dengan menggunakan library *pandas*.

## 2. Menentukan sudut dan fitur yang akan digunakan

Pada langkah berikutnya yaitu menentukan sudut dan fitur-fitur GLCM yang akan digunakan, pada variable *angles* digunakan untuk menentukan sudut yang digunakan, dan variable *properties* digunakan untuk menentukan fitur-fitur GLCM yang digunakan. Potongan kode ini dapat ditampilkan pada gambar 4.6 sebagai berikut.

### - Set GLCM Extraction Angles and Features

```
[ ] angles = ['0', '45', '90', '135']
      properties = ['dissimilarity', 'correlation', 'homogeneity', 'contrast', 'ash', 'energy']
```

Gambar 4.6. Potongan Kode Menentukan sudut dan fitur

## 3. Menghitung nilai matrik pada fitur dan sudut yang telah ditentukan

Pada langkah berikutnya yaitu menghitung nilai matriks setiap fitur pada setiap citra yang telah melewati tahap *preprocessing* dengan sudut yang telah ditentukan dengan menggunakan fungsi *graycomatrix()* dan *graycoprops()* pada library *scikit-image*. Dari langkah ini akan menghasilkan 24 fitur data berdasarkan 4 sudut dan 6 fitur matriks yang digunakan. Pada langkah implementasi ini dapat ditampilkan pada gambar 4.7.

#### - Extraction Features GLCM

```

1 | def calc_glcml_all_angles(img, angle, contrast, entropy, mean_of_means, homogeneity, texture, gcm_features):
2 |     glcm = graycomatrix(
3 |         img,
4 |         contrast=contrast,
5 |         entropy=entropy,
6 |         mean_of_means=mean_of_means,
7 |         homogeneity=homogeneity)
8 |
9 |     features = []
10 |    glcm_angle = lambda: glcm if angle in [contrast, entropy, mean_of_means]
11 |    for angle in gcm_angles:
12 |        features.append(float(
13 |            glcm_angle()))
14 |
15 |    return features
16 |
17 |
18 | def calc_glcml_all_angles(img):
19 |     for img in img:
20 |         glcm_all_angles =
21 |             calc_glcml_all_angles(
22 |                 img, label, contrast, entropy)
23 |
24 |     return []
25 |
26 |
27 |
28 |
29 |
30 |
31 |
32 |
33 |
34 |
35 |
36 |
37 |
38 |
39 |
40 |
41 |
42 |
43 |
44 |
45 |
46 |
47 |
48 |
49 |
50 |
51 |
52 |
53 |
54 |
55 |
56 |
57 |
58 |
59 |
60 |
61 |
62 |
63 |
64 |
65 |
66 |
67 |
68 |
69 |
70 |
71 |
72 |
73 |
74 |
75 |
76 |
77 |
78 |
79 |
80 |
81 |
82 |
83 |
84 |
85 |
86 |
87 |
88 |
89 |
90 |
91 |
92 |
93 |
94 |
95 |
96 |
97 |
98 |
99 |
100|

```

Gambar 4.7. Menghitung nilai matriks setiap fitur

Dari gambar 4.7 terdapat fungsi `calc_glcml_all_angles()` yang digunakan untuk menghasilkan 24 fitur data dari sudut  $0^\circ$ ,  $45^\circ$ ,  $90^\circ$ ,  $135^\circ$ . Hasil dari perhitungan 24 fitur disimpan dalam variable `glcm_features` dan mengubah format data dari format list menjadi *Dataframe* menggunakan library *pandas*.

#### 4. Simpan file kedalam format .csv

Pada langkah terakhir yaitu menyimpan hasil perhitungan matriks semua fitur GLCM kedalam format `.csv` dengan menggunakan library *pandas*. Hasil dari langkah ini akan digunakan untuk melakukan proses klasifikasi menggunakan metode *Convolutional Neural Network* dan *Support Vector Machine*. Pada langkah ini dapat ditampilkan pada gambar 4.8 sebagai berikut.

#### - Save to .CSV

```

1 | glcm_df = pd.DataFrame(
2 |     glcm_all_angles,
3 |     columns = columns
4 | )
5 |
6 | glcm_df.to_csv('content/drive/MyDrive/Kuliah 52/Tesis/dataset_glcml.csv')

```

Gambar 4.8. Menyimpan hasil perhitungan GLCM

Dari proses ekstraksi fitur GLCM diatas akan menghasilkan 24 data fitur tekstur yang disimpan dalam bentuk .csv. Berikut ini merupakan hasil dari keseluruhan ekstraksi fitur yang dapat ditampilkan pada gambar 4.9 sebagai berikut.

	disialarity_3	disialarity_4	disialarity_8	disialarity_16	correlatio_3	correlatio_4	correlatio_8	correlatio_16	homogenity_3	homogenity_4	...	contrast_16
0	0.87446	0.48773	0.47038	0.10880	0.00058	0.00069	0.00025	0.00080	0.00138	0.00091	...	157.11830
1	0.40386	0.40709	0.07941	0.01702	0.70148	0.74024	0.00134	0.10847	0.00094	0.00046	...	10.00178
2	0.00430	0.00449	0.40074	0.07022	0.00023	0.00031	0.00021	0.00076	0.00419	0.24389	...	10.10464
3	0.00197	0.00091	0.01780	0.00071	0.00008	0.00017	0.00004	0.00010	0.00010	0.00011	...	0.00084
4	7.00000	7.00000	0.01981	7.00000	0.00000	0.00004	0.00000	0.00040	0.00040	0.00040	...	0.00000
5	0.00772	0.00001	7.00000	0.00000	0.00000	0.00000	0.00000	0.00000	0.00000	0.00000	...	0.00000
6	0.00430	0.00000	0.00000	0.00000	0.00000	0.00000	0.00000	0.00000	0.00000	0.00000	...	0.00000

Gambar 4.9. Hasil Ekstraksi Fitur GLCM

#### 4.4. Split Data

Pengelompokan data sangat perlu diperhatikan untuk menentukan data yang digunakan untuk proses *training* dan *testing* dalam membangun model pelatihan pada metode klasifikasi. *Data training* digunakan untuk melatih model klasifikasi, kemudian *data validation* digunakan untuk melihat apakah hasil pelatihan model klasifikasi sudah baik atau memiliki kendala, dan pada *data testing* digunakan untuk menguji model klasifikasi yang telah dilatih untuk mengetahui performa yang dihasilkan. Dalam penerapannya pembagian dataset tidak ada patokan yang pasti. Seorang peneliti boleh menentukan sendiri besaran perbandingan permbagian data untuk penelitiannya. Dalam penelitian ini menerapkan proprorsi pembagian dataset sejumlah 80% data training, 10% data validation, dan 10% data testing. Pada tabel 4.4. menunjukkan hasil pembagian dataset pada penelitian yang digunakan sebagai berikut.

Tabel 4.4. Pembagian Data

Keterangan	Jumlah	Persentase (%)
<i>Data Training</i>	3810	80%
<i>Data Validation</i>	476	10%
<i>Data Testing</i>	476	10%
<b>Jumlah</b>	<b>4762</b>	<b>100%</b>

#### 4.5. Skenario Penelitian

Langkah selanjutnya adalah menentukan skenario penelitian yang akan digunakan pada proses klasifikasi, dimana data citra daun jagung akan dikelompokkan kedalam suatu label yang sama berdasarkan pada label yang sudah ditentukan. Untuk menghasilkan model klasifikasi yang diharapkan, penelitian ini akan dibuat dengan membandingkan metode *Convolutional Neural Network* dengan *Support Vector Machine* dalam mengklasifikasi penyakit tanaman jagung berdasarkan citra daun.

Tabel 4.5. Skenario Penelitian

No.	Skenario	Metode	Dataset
1	S1	<i>Convolutional Neural Network</i>	Tanpa GLCM
2	S2		GLCM
3	S3	<i>Support Vector Machine</i>	Tanpa GLCM
4	S4		GLCM

Berdasarkan pada tabel 4.5 menunjukkan terdapat 2 skenario penelitian dari masing-masing metode yang digunakan, dimana masing-masing metode klasifikasi

akan menerapkan dua skenario pengolahan dataset yang telah melalui proses *preprocessing data* yaitu penerapan ekstraksi fitur dan tanpa penerapan ekstraksi fitur *Gray Level Co-Occurrence Matrix* (GLCM). Pengujian ini bertujuan untuk mengetahui pengaruh penerapan GLCM terhadap performa klasifikasi.

#### **4.5.1. Convolutional Neural Network**

Pada skenario penelitian pertama, penelitian ini menggunakan metode *Convolutional Neural Network* (CNN) dengan menerapkan beberapa pengolahan dataset yang berbeda yang bertujuan untuk mengetahui pengaruh penerapan ekstraksi fitur *Gray Level Co-Occurrence Matrix* (GLCM) terhadap hasil performa klasifikasi jenis penyakit tanaman jagung dengan lebih baik dan akurat.

Metode CNN mampu mengekstraksi fitur-fitur yang relevan dari data gambar, termasuk tekstur, pola, dan bentuk yang penting dalam mengklasifikasi jenis penyakit tanaman jagung berdasarkan citra daun sehingga dapat menghasilkan performa yang tinggi dalam pengenalan pola dan mempertahankan informasi penting yang terkandung di dalamnya. Hal ini ditunjukkan dalam penelitian (Haque dkk., 2022) yang berjudul *Deep Learning-based Approach For Identification Of Diseases Of Maize Crop*, dengan penerapan metode CNN mampu menghasilkan akurasi sebesar 95%. Sementara itu, pada penerapan ekstraksi fitur GLCM bertujuan untuk menangkap pola tekstur pada citra daun tanaman jagung setelah proses *preprocessing data*. Hal ini dikarenakan tekstur daun dapat menjadi salah satu ciri khas yang membedakan antara keadaan sehat dan terserang penyakit. Penggunaan CNN untuk memproses citra daun setelah ekstraksi fitur GLCM



memungkinkan model melakukan otomatisasi ekstraksi fitur secara hierarki yang relevan, sehingga model dapat mempelajari pola-pola kompleks dan abstrak yang sulit dideteksi secara manual. Penelitian yang dilakukan oleh (Yogeshwari & Thailambal, 2021) yang berjudul *Automatic Feature Extraction And Detection Of Plant Leaf Disease Using GLCM Features And Convolutional Neural Networks* menunjukkan bahwa kombinasi CNN dan GLCM dapat menghasilkan akurasi yang cukup tinggi, yaitu sekitar 97.43%. Temuan ini menegaskan bahwa penerapan metode CNN dan GLCM merupakan metode yang efektif untuk klasifikasi penyakit tanaman jagung.

Penerapan susunan model *learning architecture* pada metode CNN yang digunakan dapat ditampilkan pada gambar 4.10 dan gambar 4.11 sebagai berikut.

Model: "sequential\_1"

Layer (type)	Output Shape	Param #
conv2d_5 (Conv2D)	(None, 254, 254, 32)	896
max_pooling2d_5 (MaxPooling 2D)	(None, 127, 127, 32)	0
conv2d_6 (Conv2D)	(None, 125, 125, 64)	18496
max_pooling2d_6 (MaxPooling 2D)	(None, 62, 62, 64)	0
flatten_1 (Flatten)	(None, 246016)	0
dense_2 (Dense)	(None, 64)	15745088
dense_3 (Dense)	(None, 4)	260

---

Total params: 15,764,740  
 Trainable params: 15,764,740  
 Non-trainable params: 0

Gambar 4.10. Model Arsitektur Metode CNN

Model: "sequential"

Layer (type)	Output Shape	Param #
conv2d (Conv2D)	(None, 3, 3, 32)	320
max_pooling2d (MaxPooling2D)	(None, 1, 1, 32)	0
flatten (Flatten)	(None, 32)	0
dense (Dense)	(None, 128)	4224
dense_1 (Dense)	(None, 4)	516

---

Total params: 5060 (19.77 KB)  
 Trainable params: 5060 (19.77 KB)  
 Non-trainable params: 0 (0.00 Byte)

Gambar 4.11. Model Arsitektur Metode CNN + GLCM

Pada gambar 4.10. terlihat struktur arsitektur CNN yang dibangun menggunakan berbagai lapisan, termasuk 2 *convolutional layer* (Conv2D) dengan kernel input berukuran 256x256 piksel dan 32 unit kernel. Dilanjutkan dengan *pooling layer* (MaxPooling2D) berukuran 2x2 untuk melakukan down sampling terhadap dimensi spasial volume input. Setelah itu, terdapat *flatten layer* yang berfungsi untuk menyusun ulang input menjadi matriks satu dimensi, memindahkannya dari lapisan konvolusional dan pooling ke lapisan *fully connected*. Lapisan *fully connected* (Dense) memiliki 64 unit, yang bertugas memproses fitur-fitur yang telah diekstrak sebelumnya.

Selanjutnya, pada gambar 4.11. terdapat arsitektur model CNN + GLCM. Model ini juga menggunakan *convolutional layer* (Conv2D) dengan kernel input tertentu dan 32 unit kernel, diikuti oleh *pooling layer* (MaxPooling2D) berukuran 2x2 untuk melakukan down sampling. Lapisan flatten kemudian menyusun ulang input menjadi matriks satu dimensi sebelum diarahkan ke lapisan *fully connected*.

Lapisan *fully connected* (Dense) dengan 64 unit bertugas memproses fitur-fitur hasil konvolusi dan pooling. Model ini menggabungkan informasi dari GLCM dengan konvolusi untuk meningkatkan kinerja dalam tugas klasifikasi daun.

Skenario penelitian ini akan dilakukan *training data* dengan menggunakan 25 *epoch*. *Epoch* merupakan proses *training* dan *testing* dalam membangun model CNN yang berperan sebagai *hyperparameter* bertujuan untuk menentukan berapa kali proses *training* ini bekerja melewati seluruh dataset baik secara *forward* maupun *backward*.

#### 4.5.2. Support Vector Machine

Pada skenario penelitian kedua, penelitian ini menggunakan metode *Support Vector Machine* (SVM) dengan beberapa pengolahan dataset yang berbeda dari sumber yang sama yaitu dataset tanpa pengolahan ekstraksi fitur dan dataset dengan pengolahan ekstraksi fitur *Gray Level Co-Occurrence Matrix* (GLCM). Pada skenario penelitian ini menerapkan Kernel *Radial Basis Function* (RBF) yang digunakan untuk menentukan *feature space* dimana fungsi klasifikasi akan diidentifikasi.

Pemilihan kernel RBF dikarenakan secara *nonlinier* memetakan sampel ke dalam ruang berdimensi lebih tinggi dan *multiclass*, tidak seperti pada kernel *linier*. Kemudian kernel RBF ini memiliki *hyperparameter* yang lebih sedikit dibandingkan kernel *polynomial* juga memiliki tingkat kesulitan *numerik* yang minim (Srivastava dkk., 2010). Selanjutnya, penerapan metode SVM juga dilakukan oleh (Khotimah dkk., 2022) dengan judul Identifikasi Hama dan Penyakit

Tanaman Jagung dengan Menggunakan Metode Klasifikasi *Support Vector Machine* (SVM), dari hasil penelitian yang telah dilakukan menunjukkan metode SVM menghasilkan akurasi sebesar 94%, dan pada penelitian (Supriyanto dkk., 2023) dengan judul *Robusta Coffee Leaf Disease Classifications Using SVM Method and GLCM Feature Extraction*, hasil dari penelitian ini menunjukkan metode klasifikasi SVM dengan kernel RBF menghasilkan akurasi 97.5%.

### ✓ Create Modeling SVM

```
[ ] model = SVC(kernel='rbf')
    model.fit(X_train, y_train)
```

Gambar 4.12. Model Arsitektur Metode SVM

Pada gambar 4.12 merupakan penggunaan kernel RBF, kernel RBF bekerja secara efektif menghindari *overfitting* dengan memilih nilai yang tepat untuk parameter  $C$  dan  $\gamma$ , parameter  $C$  atau *Cost* berfungsi mengendalikan *trade-off* antara *margin* dan *classification error*. Semakin besar nilai  $C$ , maka semakin besar *penalty* yang dikenakan terhadap setiap *classification error* (Nugroho, 2007). Sedangkan apabila nilai  $C$  bernilai kecil, maka akan memberikan *error* yang lebih tinggi pada *data training* dan memiliki nilai *margin* yang besar dimana model dapat dikatakan lebih baik & kuat. Selain nilai  $C$  ada juga nilai *gamma* ( $\gamma$ ) yang berfungsi mengontrol nilai standar deviasi. Semakin banyak nilai *gamma*, maka semakin kecil *hypersphere*.

#### 4.6. Analisis Hasil Klasifikasi


Proses klasifikasi penyakit pada daun tanaman jagung dalam penelitian ini menerapkan beberapa skenario penelitian yang telah ditentukan sebelumnya untuk membandingkan metode *Convolutional Neural Network* dengan *Support Vector Machine*. Hasil klasifikasi yang telah dilakukan akan dianalisis dan diuji untuk mengukur kinerja suatu model yang telah dibuat. Dengan mengukur kinerja suatu model klasifikasi, dapat membantu para peneliti untuk mengevaluasi dan memahami sejauh mana model yang telah dibuat mampu dalam memprediksikan kelas target dengan akurat dan tepat. Dalam mengukur kinerja suatu model dapat direpresentasikan dengan menggunakan metode *Confusion Matrix*.

Metode *Confusion Matrix* digunakan untuk mengukur seberapa baik model klasifikasi dalam memprediksikan kelas target dengan benar dari data yang ada. Dalam memberikan gambaran seberapa baik model dalam mengklasifikasi yaitu dengan membandingkan hasil prediksi yang benar dengan yang salah yang dimuat dalam bentuk tabel. Pada penerapannya, *confusion matrix* memiliki 4 nilai penting saat digunakan yaitu yaitu *true positive* (TP), *true negative* (TN), *false positive* (FP), dan *false negative* (FN). Dengan menerapkan metode ini tidak hanya dapat menunjukkan nilai akurasi dari model klasifikasi, namun mampu memberikan nilai *precision*, *recall*, *f1-score*, dan *support* yang bisa digunakan untuk analisa lainnya. Nilai *Precision* digunakan untuk mengukur seberapa akurat model dalam mengklasifikasi nilai positif. Nilai *Recall* atau bisa disebut *sensitivity* yaitu mengukur sejauh mana model mampu mendeteksi semua nilai instans positif. Nilai *F1-score* merupakan nilai rata-rata antara nilai *precision* dan *recall*. Dan nilai

*Support* yaitu memberikan informasi seberapa banyak data yang termasuk kedalam kelas tertentu.

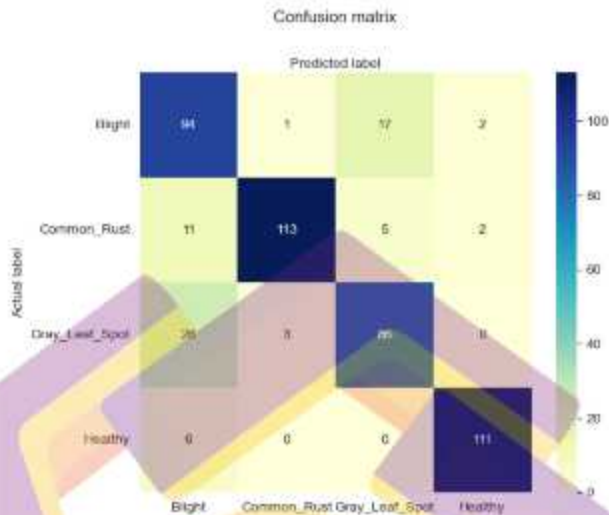
#### 4.6.1. Convolutional Neural Network

Skenario pertama pada pengujian ini menerapkan metode *Convolutional Neural Network* dengan menggunakan dataset tanpa pengolahan ekstraksi fitur. Hasil dari proses pengujian *training* dan *testing* dapat ditampilkan pada gambar 4.13.



Gambar 4.13. Grafik Akurasi dan Loss Metode CNN

Pada gambar 4.13 memperlihatkan proses *training* dan *testing* dari *epoch* pertama hingga 50, dimana pada proses *training* menghasilkan akurasi mencapai 0.9470 dan nilai *loss rate* 0.1386, namun pada proses *testing* nilai akurasi mengalami penurunan menjadi 0.8427 dan nilai *loss rate* mencapai 0.6128 dengan waktu pengujian 2902 detik. Dari model yang telah terbentuk akan dilakukan evaluasi menggunakan *confusion matrix*.



Gambar 4.14. *Confusion Matrix* Metode CNN

Gambar 4.14 merupakan representasi hasil pengujian dengan menggunakan *confusion matrix* pada metode CNN dengan pengolahan dataset tanpa ekstraksi fitur. Pada penelitian ini menggunakan 477 citra sebagai data *testing* yang terdiri dari kelas *blight* sebesar 114 citra, *common rust* 131 citra, *gray leaf spot* 115 citra, dan *healthy* 117 citra. Klasifikasi penyakit daun tanaman jagung memiliki 4 kelas, maka dalam pengujian yang dilakukan menggunakan metode *confusion matrix for multi-class* dimana untuk mendapatkan nilai *precision* dan *recall* yaitu dengan menghitung masing-masing kelas. Berikut merupakan proses perhitungan *accuracy*, *precision*, dan *recall*.

#### 1. Accuracy

Untuk mendapatkan nilai akurasi yaitu dengan menjumlahkan nilai *true positif* dari masing-masing kelas. Kemudian hasil penjumlahan nilai *true positif* dibagi

dengan jumlah data testing, lalu dikalikan 100%. Maka perhitungan nilai akurasi pada metode CNN sebagai berikut.

$$Akurasi = \frac{94+113+86+111}{477} * 100\% = 85\%$$

## 2. Precision

Nilai *precision* pada *confusion matrix for multi-class* dihasilkan dengan menghitung nilai *precision* pada masing-masing kelas terlebih dahulu dengan menghitung nilai *true positif* dibagi dengan nilai *true positif* ditambahkan nilai *false positif*.

### a. Kelas *Blight*

$$Precision = 94 / (94+11+26+6) = 94 / 137 = 69\%$$

### b. Kelas *Common Rust*

$$Precision = 113 / (113+1+3+0) = 113 / 117 = 97\%$$

### c. Kelas *Gray Leaf Spot*

$$Precision = 86 / (86+17+5+0) = 86 / 108 = 80\%$$

### d. Kelas *Healthy*

$$Precision = 111 / (111+2+2+0) = 111 / 115 = 97\%$$

Kemudian untuk memperoleh nilai *precision* keseluruhan dengan menjumlahkan semua nilai *precision* pada masing-masing kelas, kemudian dibagi dengan jumlah kelas. Maka perhitungan nilai *precision* pada metode CNN sebagai berikut.

$$Precision = \frac{69+97+80+97}{4} * 100\% = 85\%$$



### 3. Recall

Nilai *recall* pada *confusion matrix for multi-class* dihasilkan dengan menghitung nilai *recall* pada masing-masing kelas terlebih dahulu dengan menghitung nilai *true positif* dibagi dengan nilai *true positif* ditambahkan nilai *false positif*.

a. Kelas *Blight*

$$\text{Recall} = 94 / (94+1+17+2) = 94 / 114 = 82\%$$

b. Kelas *Common Rust*

$$\text{Recall} = 113 / (113+11+5+2) = 113 / 131 = 86\%$$

c. Kelas *Gray Leaf Spot*

$$\text{Recall} = 86 / (86+26+3+0) = 86 / 115 = 75\%$$

d. Kelas *Healthy*

$$\text{Recall} = 111 / (111+6+0+0) = 111 / 117 = 95\%$$

Kemudian untuk memperoleh nilai *recall* keseluruhan dengan menjumlahkan semua nilai *recall* pada masing-masing kelas, kemudian dibagi dengan jumlah kelas. Maka perhitungan nilai *recall* pada metode CNN sebagai berikut.

$$\text{Recall} = \frac{82+86+75+95}{4} * 100\% = 85\%$$


Classification Report:				
	precision	recall	f1-score	support
Blight	0.69	0.82	0.75	114
Common_Rust	0.97	0.86	0.91	131
Gray_Leaf_Spot	0.80	0.75	0.77	115
Healthy	0.97	0.95	0.96	117
accuracy			0.85	477
macro avg	0.85	0.85	0.85	477
weighted avg	0.86	0.85	0.85	477

Gambar 4.15. *Classification Report* Metode CNN

Dari perhitungan manual yang telah dilakukan untuk mendapatkan nilai *accuracy*, *precision*, dan *recall* pada metode *confusion matrix for multi-class*, mendapatkan hasil yang sama dengan perhitungan menggunakan program *python*. Hasil ini dapat ditampilkan pada gambar 4.15.


#### 4.6.2. Convolutional Neural Network + GLCM

Skenario kedua pada pengujian ini menerapkan metode *Convolutional Neural Network* dengan menggunakan pengolahan ekstraksi fitur GLCM. Hasil dari proses pengujian *training* dan *testing* dapat ditampilkan pada gambar 4.16.



Gambar 4.16. Grafik Akurasi dan Loss Metode CNN + GLCM

Pada gambar 4.16 memperlihatkan proses *training* dan *testing* dari *epoch* pertama hingga 50, dimana pada proses *training* menghasilkan akurasi mencapai 0.9669 dengan nilai *loss rate* 0.0972, kemudian pada proses *testing* mengalami peningkatan mencapai 0.9789 pada nilai akurasi dengan nilai *loss rate* 0.0486 dengan waktu pengujian 42 detik. Dari model yang telah terbentuk kemudian akan dilakukan evaluasi menggunakan *confusion matrix*.



Gambar 4.17. *Confusion Matrix* Metode CNN + GLCM

Gambar 4.17 merupakan representasi hasil pengujian dengan menggunakan *confusion matrix* pada metode CNN dengan pengolahan ekstraksi fitur GLCM pada dataset. Pada penelitian ini menggunakan 476 citra sebagai data *testing* yang terdiri dari kelas *blight* sebesar 125 citra, *common rust* 128 citra, *gray leaf spot* 104 citra, dan *healthy* 119 citra. Klasifikasi penyakit daun tanaman jagung memiliki 4 kelas, maka dalam pengujian yang dilakukan menggunakan metode *confusion matrix for multi-class* dimana untuk mendapatkan nilai *precision* dan *recall* yaitu dengan menghitung masing-masing kelas. Berikut merupakan proses perhitungan *accuracy*, *precision*, dan *recall*.

#### 1. Accuracy

Untuk mendapatkan nilai akurasi yaitu dengan menjumlahkan nilai *true positif* dari masing-masing kelas. Kemudian hasil penjumlahan nilai *true positif* dibagi

dengan jumlah data testing, lalu dikalikan 100%. Maka perhitungan nilai akurasi pada metode CNN + GLCM sebagai berikut.

$$\text{Akurasi} = \frac{122+123+104+117}{476} * 100\% = 98\%$$

## 2. Precision

Nilai *precision* pada *confusion matrix for multi-class* dihasilkan dengan menghitung nilai *precision* pada masing-masing kelas terlebih dahulu dengan menghitung nilai *true positif* dibagi dengan nilai *true positif* ditambahkan nilai *false positif*.

### a. Kelas *Blight*

$$\text{Precision} = 122 / (112+0+0+0) = 112 / 112 = 100\%$$

### b. Kelas *Common Rust*

$$\text{Precision} = 123 / (123+3+0+0) = 123 / 126 = 98\%$$

### c. Kelas *Gray Leaf Spot*

$$\text{Precision} = 104 / (104+5+2+0) = 104 / 111 = 94\%$$

### d. Kelas *Healthy*

$$\text{Precision} = 117 / (117+0+0+0) = 117 / 117 = 100\%$$

Kemudian untuk memperoleh nilai *precision* keseluruhan dengan menjumlahkan semua nilai *precision* pada masing-masing kelas, kemudian dibagi dengan jumlah kelas. Maka perhitungan nilai *precision* pada metode CNN + GLCM sebagai berikut.

$$\text{Precision} = \frac{100+99+94+100}{4} * 100\% = 98\%$$

### 3. Recall

Nilai *recall* pada *confusion matrix for multi-class* dihasilkan dengan menghitung nilai *recall* pada masing-masing kelas terlebih dahulu dengan menghitung nilai *true positif* dibagi dengan nilai *true positif* ditambahkan nilai *false positif*.

a. Kelas *Blight*

$$Recall = 122 / (122+3+0+0) = 122 / 125 = 98\%$$

b. Kelas *Common Rust*

$$Recall = 123 / (123+5+0+0) = 123 / 128 = 96\%$$

c. Kelas *Gray Leaf Spot*

$$Recall = 104 / (104+0+0+0) = 104 / 104 = 100\%$$

d. Kelas *Healthy*

$$Recall = 117 / (117+2+0+0) = 117 / 119 = 98\%$$

Kemudian untuk memperoleh nilai *recall* keseluruhan dengan menjumlahkan semua nilai *recall* pada masing-masing kelas, kemudian dibagi dengan jumlah kelas. Maka perhitungan nilai *recall* pada metode CNN + GLCM sebagai berikut.

$$Recall = \frac{98+96+100+98}{4} * 100\% = 98\%$$

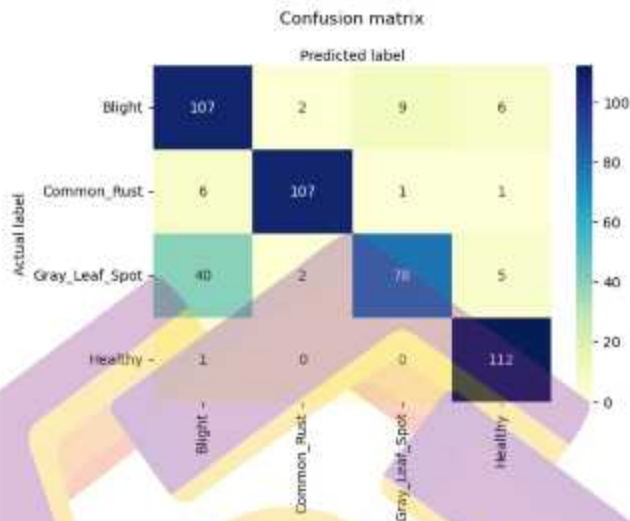
Classification Report:				
	precision	recall	f1-score	support
Blight	1.00	0.98	0.99	125
Common_Rust	0.98	0.96	0.97	128
Gray_Leaf_Spot	0.94	1.00	0.97	104
Healthy	1.00	0.98	0.99	119
accuracy			0.98	476
macro avg	0.98	0.98	0.98	476
weighted avg	0.98	0.98	0.98	476

Gambar 4.18. *Classification Report* Metode CNN + GLCM

Dari perhitungan manual yang telah dilakukan untuk mendapatkan nilai *accuracy*, *precision*, dan *recall* pada metode *confusion matrix for multi-class*, mendapatkan hasil yang sama dengan perhitungan menggunakan program *python*. Hasil ini dapat ditampilkan pada gambar 4.18.

#### 4.6.3. Support Vector Machine

Skenario ketiga pada pengujian ini menerapkan metode *Support Vector Machine* dengan pengolahan dataset tanpa ekstraksi fitur, menggunakan kernel *Radial Basis Function* (RBF) untuk menghasilkan *feature map* yang digunakan untuk mengklasifikasi penyakit tanaman jagung berdasarkan daun jagung. Pada proses pelatihan model ini membutuhkan waktu 4860 detik, dan pengujian dilakukan dalam waktu 607 detik. Untuk mengukur kinerja model yang dihasilkan, maka peneliti melakukan pengujian menggunakan *confusion matrix*.



Gambar 4.19. *Confusion Matrix* Metode SVM

Gambar 4.19 merupakan representasi hasil pengujian dengan menggunakan *confusion matrix* pada metode SVM dengan pengolahan dataset tanpa ekstraksi fitur. Pada penelitian ini menggunakan 477 citra sebagai data *testing* yang terdiri dari kelas *blight* sebesar 124 citra, *common rust* 115 citra, *gray leaf spot* 125 citra, dan *healthy* 113 citra. Klasifikasi penyakit daun tanaman jagung memiliki 4 kelas, maka dalam pengujian yang dilakukan menggunakan metode *confusion matrix for multi-class* dimana untuk mendapatkan nilai *precision* dan *recall* yaitu dengan menghitung masing-masing kelas. Berikut merupakan proses perhitungan *accuracy*, *precision*, dan *recall*.

#### 1. *Accuracy*

Untuk mendapatkan nilai akurasi yaitu dengan menjumlahkan nilai *true positif* dari masing-masing kelas. Kemudian hasil penjumlahan nilai *true positif* dibagi

dengan jumlah data testing, lalu dikalikan 100%. Maka perhitungan nilai akurasi pada metode SVM sebagai berikut.

$$\text{Akurasi} = \frac{107+107+78+112}{477} * 100\% = 85\%$$

## 2. Precision

Nilai *precision* pada *confusion matrix for multi-class* dihasilkan dengan menghitung nilai *precision* pada masing-masing kelas terlebih dahulu dengan menghitung nilai *true positif* dibagi dengan nilai *true positif* ditambahkan nilai *false positif*.

### a. Kelas *Blight*

$$\text{Precision} = 107 / (107+6+40+1) = 107 / 154 = 69\%$$

### b. Kelas *Common Rust*

$$\text{Precision} = 107 / (107+2+2+0) = 107 / 111 = 96\%$$

### c. Kelas *Gray Leaf Spot*

$$\text{Precision} = 78 / (78+9+1+0) = 78 / 88 = 89\%$$

### d. Kelas *Healthy*

$$\text{Precision} = 112 / (112+6+1+5) = 112 / 124 = 90\%$$

Kemudian untuk memperoleh nilai *precision* keseluruhan dengan menjumlahkan semua nilai *precision* pada masing-masing kelas, kemudian dibagi dengan jumlah kelas. Maka perhitungan nilai *precision* pada metode SVM sebagai berikut.

$$\text{Precision} = \frac{69+96+89+90}{4} * 100\% = 86\%$$



### 3. Recall

Nilai *recall* pada *confusion matrix for multi-class* dihasilkan dengan menghitung nilai *recall* pada masing-masing kelas terlebih dahulu dengan menghitung nilai *true positif* dibagi dengan nilai *true positif* ditambahkan nilai *false positif*.

a. Kelas *Blight*

$$\text{Recall} = 107 / (107+2+9+6) = 107 / 124 = 86\%$$

b. Kelas *Common Rust*

$$\text{Recall} = 107 / (107+6+1+1) = 234 / 115 = 93\%$$

c. Kelas *Gray Leaf Spot*

$$\text{Recall} = 78 / (78+40+2+5) = 78 / 125 = 62\%$$

d. Kelas *Healthy*

$$\text{Recall} = 112 / (112+1+0+0) = 112 / 113 = 99\%$$

Kemudian untuk memperoleh nilai *recall* keseluruhan dengan menjumlahkan semua nilai *recall* pada masing-masing kelas, kemudian dibagi dengan jumlah kelas. Maka perhitungan nilai *recall* pada metode SVM sebagai berikut.

$$\text{Recall} = \frac{86+93+62+99}{4} * 100\% = 85\%$$

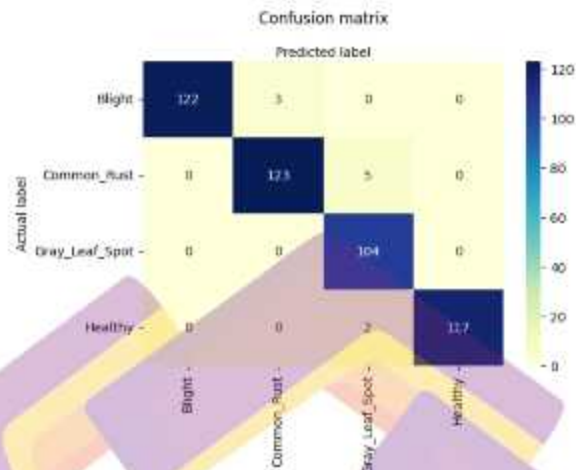
Classification Report:				
	precision	recall	f1-score	support
Blight	0.69	0.86	0.77	124
Common_Rust	0.96	0.93	0.95	115
Gray_Leaf_Spot	0.89	0.62	0.73	125
Healthy	0.90	0.99	0.95	113
accuracy			0.85	477
macro avg	0.86	0.85	0.85	477
weighted avg	0.86	0.85	0.84	477

Gambar 4.20. *Classification Report* Metode SVM

Dari perhitungan manual yang telah dilakukan untuk mendapatkan nilai *accuracy*, *precision*, dan *recall* pada metode *confusion matrix for multi-class*, mendapatkan hasil yang sama dengan perhitungan menggunakan program *python*. Hasil ini dapat ditampilkan pada gambar 4.20.

#### 4.6.4. Support Vector Machine + GLCM

Skenario ketiga pada pengujian ini menerapkan metode *Support Vector Machine* dengan pengolahan ekstraksi fitur GLCM pada dataset, menggunakan kernel *Radial Basis Function (RBF)* untuk menghasilkan *feature map* yang digunakan untuk mengklasifikasi penyakit tanaman jagung berdasarkan daun jagung. Pada proses pelatihan model ini membutuhkan waktu 1.4351 detik, dan pengujian dilakukan dalam waktu 0.0993 detik. Untuk mengukur kinerja model yang dihasilkan, maka peneliti melakukan pengujian menggunakan *confusion matrix*.



Gambar 4.21. *Confusion Matrix* Metode SVM + GLCM

Gambar 4.21 merupakan representasi hasil pengujian dengan menggunakan *confusion matrix* pada metode SVM dengan pengolahan ekstraksi fitur pada dataset. Pada penelitian ini menggunakan 476 citra sebagai data *testing* yang terdiri dari kelas *blight* sebesar 125 citra, *common rust* 128 citra, *gray leaf spot* 104 citra, dan *healthy* 119 citra. Klasifikasi penyakit daun tanaman jagung memiliki 4 kelas, maka dalam pengujian yang dilakukan menggunakan metode *confusion matrix for multi-class* dimana untuk mendapatkan nilai *precision* dan *recall* yaitu dengan menghitung masing-masing kelas. Berikut merupakan proses perhitungan *accuracy*, *precision*, dan *recall*.

#### 1. *Accuracy*

Untuk mendapatkan nilai akurasi yaitu dengan menjumlahkan nilai *true positif* dari masing-masing kelas. Kemudian hasil penjumlahan nilai *true positif* dibagi

dengan jumlah data testing, lalu dikalikan 100%. Maka perhitungan nilai akurasi pada metode SVM + GLCM sebagai berikut.

$$\text{Akurasi} = \frac{104+120+80+115}{476} * 100\% = 88\%$$

## 2. Precision

Nilai *precision* pada *confusion matrix for multi-class* dihasilkan dengan menghitung nilai *precision* pada masing-masing kelas terlebih dahulu dengan menghitung nilai *true positif* dibagi dengan nilai *true positif* ditambahkan nilai *false positif*.

### a. Kelas *Blight*

$$\text{Precision} = 104 / (104+1+22+2) = 104 / 129 = 81\%$$

### b. Kelas *Common Rust*

$$\text{Precision} = 120 / (120+1+1+0) = 120 / 122 = 98\%$$

### c. Kelas *Gray Leaf Spot*

$$\text{Precision} = 80 / (80+19+5+2) = 80 / 106 = 75\%$$

### d. Kelas *Healthy*

$$\text{Precision} = 115 / (115+1+2+1) = 115 / 119 = 97\%$$

Kemudian untuk memperoleh nilai *precision* keseluruhan dengan menjumlahkan semua nilai *precision* pada masing-masing kelas, kemudian dibagi dengan jumlah kelas. Maka perhitungan nilai *precision* pada metode SVM + GLCM sebagai berikut.

$$\text{Precision} = \frac{81+98+75+97}{4} * 100\% = 88\%$$

### 3. Recall

Nilai *recall* pada *confusion matrix for multi-class* dihasilkan dengan menghitung nilai *recall* pada masing-masing kelas terlebih dahulu dengan menghitung nilai *true positif* dibagi dengan nilai *true positif* ditambahkan nilai *false positif*.

#### a. Kelas *Blight*

$$Recall = 104 / (104+1+19+1) = 104 / 258 = 83\%$$

#### b. Kelas *Common Rust*

$$Recall = 120 / (120+1+5+2) = 120 / 128 = 94\%$$

#### c. Kelas *Gray Leaf Spot*

$$Recall = 80 / (80+22+1+1) = 80 / 104 = 77\%$$

#### d. Kelas *Healthy*

$$Recall = 115 / (115+2+0+2) = 115 / 119 = 97\%$$

Kemudian untuk memperoleh nilai *recall* keseluruhan dengan menjumlahkan semua nilai *recall* pada masing-masing kelas, kemudian dibagi dengan jumlah kelas. Maka perhitungan nilai *recall* pada metode SVM + GLCM sebagai berikut.

$$Recall = \frac{83+94+77+97}{4} * 100\% = 88\%$$

Classification Report:				
	precision	recall	f1-score	support
Blight	0.81	0.83	0.82	125
Common_Rust	0.98	0.94	0.96	128
Gray_Leaf_Spot	0.75	0.77	0.76	104
Healthy	0.97	0.97	0.97	119
accuracy			0.88	476
macro avg	0.88	0.88	0.88	476
weighted avg	0.88	0.88	0.88	476

Gambar 4.22. *Classification Report* Metode SVM + GLCM

Dari perhitungan manual yang telah dilakukan untuk mendapatkan nilai *accuracy*, *precision*, dan *recall* pada metode *confusion matrix for multi-class*, mendapatkan hasil yang sama dengan perhitungan menggunakan program *python*. Hasil ini dapat ditampilkan pada gambar 4.22.

#### 4.6.5. Perbandingan Hasil Klasifikasi

Setelah dilakukannya serangkaian proses klasifikasi serta pengujian metode *Convolutional Neural Network* dan *Support Vector Machine* dengan beberapa skenario pengolahan dataset yang berbeda, peneliti akan menyajikan hasil pengujian masing-masing skenario penelitian yang telah dilakukan yang bertujuan untuk mengetahui seberapa baik kinerja suatu model yang telah dibuat. Berikut merupakan hasil pelatihan dan pengujian setiap skenario penelitian yang dapat ditampilkan pada tabel 4.5 sebagai berikut.

Tabel 4.6. Perbandingan Hasil Pengujian

No	Metode	Dataset	Training Accuracy	Testing Accuracy	Precision	Recall
1	CNN	Tanpa GLCM	94%	85%	85%	85%
2		GLCM	96%	98%	98%	98%
3	SVM	Tanpa GLCM	90%	85%	86%	85%
4		GLCM	84%	88%	88%	88%

Dari tabel 4.6 menunjukkan perbandingan hasil pengujian setiap metode dengan beberapa skenario pengolahan dataset. Dari pengujian yang telah dilakukan, dapat terlihat dengan memanfaatkan proses ekstraksi fitur *Gray Level Co-Occurrence Matrix* (GLCM) pada dataset yang digunakan mampu menghasilkan nilai akurasi yang lebih baik dibandingkan tanpa menerapkan ekstraksi fitur GLCM, dimana nilai akurasi pada metode *Convolutional Neural Network* dari 85% meningkat menjadi 98%, serta pada metode *Support Vector Machine* dari 85% meningkat menjadi 88%. Terdapat juga temuan dimana pada pengolahan dataset tanpa ekstraksi fitur GLCM menghasilkan nilai akurasi training yang jauh lebih tinggi dibandingkan nilai akurasi testing. Hal ini menunjukkan bahwa metode CNN dan SVM yang dibangun cenderung mengalami *overfitting*, yang dibuktikan dengan nilai *loss rate* tinggi dan waktu pengujian yang lebih lama.

Dalam pengujian metode klasifikasi, dilakukan perbandingan hasil performa yang diperoleh dengan menggunakan metode *confusion matrix* berdasarkan pada perhitungan nilai *accuracy*, *precision*, dan *recall* dari metode *Convolutional Neural Network* dan *Support Vector Machine* pada setiap skenario pengolahan dataset. Berikut merupakan grafik nilai *accuracy*, *precision*, dan *recall*

untuk masing-masing metode klasifikasi yang telah dilakukan yang disajikan pada gambar 4.23.



Gambar 4.23. Perbandingan Hasil Performa

Pada gambar 4.23 memperlihatkan perbandingan nilai persentase dari *accuracy*, *precision*, dan *recall* dari setiap skenario penelitian yang telah dilakukan. Berdasarkan grafik diatas menunjukkan jika metode *Convolutional Neural Network* dengan pengolahan ekstraksi fitur GLCM menghasilkan nilai *accuracy*, *precision*, dan *recall* tertinggi sedangkan pada metode *Support Vector Machine* menghasilkan nilai *accuracy*, *precision*, dan *recall* terendah.



## BAB V

### PENUTUP

#### 5.1. Kesimpulan

Berdasarkan hasil dari pengujian dan analisis yang telah dilakukan, maka dapat diambil kesimpulan sebagai berikut :

1. Setelah dilakukannya serangkaian pengujian dari masing-masing skenario penelitian pada metode CNN dan SVM, mendapatkan hasil bahwa metode CNN dengan nilai *accuracy* 85%, *precision* 85%, dan *recall* 85%, kemudian pada metode CNN + GLCM menghasilkan nilai *accuracy* 98%, *precision* 98%, dan *recall* 98%. Sedangkan pada metode SVM menghasilkan nilai *accuracy* 85%, *precision* 86%, dan *recall* 85%, serta pada metode SVM + GLCM menghasilkan nilai akurasi *accuracy* 88%, *precision* 88%, dan *recall* 88%
2. Kinerja metode terbaik pada penelitian ini yang bertujuan untuk identifikasi penyakit tanaman jagung berdasarkan citra daun adalah metode CNN dengan penerapan ekstraksi fitur GLCM dengan menghasilkan nilai *accuracy* 98%, *precision* 98%, dan *recall* 98%
3. Dengan memanfaatkan ekstraksi fitur GLCM tidak hanya meningkatkan kinerja metode CNN dan SVM, namun mampu mempersingkat waktu pengujian *training* dan *testing*, serta mengurangi kecenderungan terjadinya *overfitting*.

## 5.2. Saran

Pada bagian ini memuat beberapa saran atau usulan dari peneliti untuk dijadikan pedoman dalam pengembangan penelitian selanjutnya, sebagai berikut:

1. Melakukan perbandingan dengan metode lainnya selain metode yang telah digunakan, atau mencoba menggabungkan metode seperti CNN dengan SVM.
2. Menggunakan metode ekstraksi fitur lainnya sehingga akan mendapatkan hasil perbandingan dengan metode ekstraksi fitur yang digunakan peneliti saat ini.
3. Menerapkan proporsi data *training* dan data *testing* yang berbeda dengan yang telah dilakukan oleh peneliti saat ini.
4. Performa kinerja dapat ditingkatkan dengan melakukan perbaikan teknik *preprocessing data*.



## DAFTAR PUSTAKA

### PUSTAKA BUKU

- Cristianini, N., & Taylor, J. S. (2000). *An Introduction to Support Vector Machines*. Cambridge University Press.
- Cristianini, N., & Taylor, J. S. (2013). *An Introduction to Support Vector Machines and Other Kernel-based Learning Methods*. Cambridge University Press.
- Gonzalez, R. C., & Woods, R. E. (2008). *Digital Image Processing* (3rd edition). Prentice Hall.
- Nafi'iyah, N., & Mujilawati, S. (2018). *Buku Ajar Citra Binarisasi Dan Enhancement*. Deepublish.
- Nugroho, A. S. (2007). *Pengantar Support Vector Machine*. <http://asnugroho.net>
- Putra, J. W. G. (2020). *Pengenalan Konsep Pembelajaran Mesin dan Deep Learning*.
- Sudjono, M. S. (2018). *Penyakit Jagung dan Pengendaliannya*.
- Sutarman. (2017). *Dasar-Dasar Ilmu Penyakit Tanaman*. UMSIDA PRESS.
- Sutojo, T E Mulyanto, & V Suhartono. (2017). *Teori Pengolahan Citra Digital*. Universitas Dian Nuswantoro.

### PUSTAKA MAJALAH, JURNAL ILMIAH ATAU PROSIDING

- Chandra, M. M., & Yoannita. (2023). Klasifikasi Jenis Bunga Menggunakan Metode SVM Berdasarkan Citra Dengan Fitur HSV. *Jurnal Indonesia Sosial Teknologi*, 4, 255–264.
- Fadholi, R., Sari, Y. A., & Abdurrachman Bachtiar, F. (2019). Pengenalan Citra Makanan Tradisional menggunakan Fitur Hue Saturation Value dan Fuzzy k-Nearest Neighbor. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, 3(7), 6556–6566. <http://j-ptiik.ub.ac.id>

- Felix, Faisal, S., Butarbutar, T. F. M., & Sirait, P. (2019). Implementasi CNN dan SVM untuk Identifikasi Penyakit Tomat via Daun. *OKTOBER 2019 IJCCS*, 20, 1–5.
- Geetharamani, G., & J., A. P. (2019). Identification of plant leaf diseases using a nine-layer deep convolutional neural network. *Computers & Electrical Engineering*, 76, 323–338. <https://doi.org/10.1016/J.COMPELECENG.2019.04.011>
- Gracia Moisés, A., Vitoria Pascual, I., Imas González, J. J., & Ruiz Zamarréno, C. (2023). Data Augmentation Techniques for Machine Learning Applied to Optical Spectroscopy Datasets in Agrifood Applications: A Comprehensive Review. *Sensors*, 23(20), 8562. <https://doi.org/10.3390/s23208562>
- Haq, M. A., Marwaha, S., Deb, C. K., Nigam, S., Arora, A., Hooda, K. S., Soujanya, P. L., Aggarwal, S. K., Lall, B., Kumar, M., Islam, S., Panwar, M., Kumar, P., & Agrawal, R. C. (2022). Deep learning-based approach for identification of diseases of maize crop. *Scientific Reports*, 12(1). <https://doi.org/10.1038/s41598-022-10140-z>
- Harami, N. H., Prianto, C., & Hasanah, M. (2019). Deteksi Objek Dan Pengenalan Karakter Plat Nomor Kendaraan Indonesia Menggunakan Metode Convolutional Neural Network (CNN) Berbasis Python. *Jurnal Teknik Informatika*, 11(3).
- Hasan, Moh. A., Riyanto, Y., & Riiana, D. (2021). Grape leaf image disease classification using CNN-VGG16 model. *Jurnal Teknologi dan Sistem Komputer*, 9(4), 218–223. <https://doi.org/10.14710/jtsiskom.2021.14013>
- Huda, A. A., Setiaji, B., & Hidayat, F. R. (2022). Implementasi Gray Level Co-occurrence Matrix (GLCM) Untuk Klasifikasi Penyakit Daun Padi. *Jurnal Pseudocode*, 9. [www.ejournal.unib.ac.id/index.php/pseudocode](http://www.ejournal.unib.ac.id/index.php/pseudocode)
- Ihsan, M. F., Sunyoto, A., & Arief, M. R. (2022). Gray Level Co-Occurrence Matrix Algorithm and Backpropagation Neural Networks for Herbal Plants Identification. *2022 5th International Conference on Information and Communications Technology (ICOIACT)*, 373–378. <https://doi.org/10.1109/ICOIACT55506.2022.9972087>

- Iswantoro, D., & Handayani UN, D. (2022). Klasifikasi Penyakit Tanaman Jagung Menggunakan Metode Convolutional Neural Network (CNN). *Jurnal Ilmiah Universitas Batanghari Jambi*, 22(2), 900. <https://doi.org/10.33087/jiubj.v22i2.2065>
- Khotimah, B. K., Setiawan, E., Sasmeka, V., Fridayanti, A., Maulana, I., & Zulfida, A. M. (2022). Identifikasi Hama dan Penyakit Tanaman Jagung dengan Menggunakan Metode Klasifikasi Support Vector Machine (SVM). *Jurnal Ilmiah NERO*, 7(1).
- Lesmana, A. M., Fadhillah, R. P., & Rozikin, C. (2022). Identifikasi Penyakit pada Citra Daun Kentang Menggunakan Convolutional Neural Network (CNN). *Jurnal Sains dan Informatika*, 8(1), 21–30. <https://doi.org/10.34128/jsi.v8i1.377>
- Maria, E., Fadlin, F., & Taruk, M. (2020). Diagnosis Penyakit Tanaman Padi Menggunakan Metode Promethee. *Jurnal Ilmiah Ilmu Komputer*, 15(1), 27–31. <https://doi.org/10.30872/jim.v15i1.2844>
- Nurchayati, A. D., Makhfuddin Akbar, R., & Zahara, S. (2022). Klasifikasi Citra Penyakit Pada Daun Jagung Menggunakan Deep Learning Dengan Metode Convolution Neural Network (CNN). 2(2), 43–51. <http://ejournal.unim.ac.id/index.php/submit>
- Qian, L., Hu, L., Zhao, L., Wang, T., & Jiang, R. (2020). Sequence-Dropout Block for Reducing Overfitting Problem in Image Classification. *IEEE Access*, PP, 1. <https://doi.org/10.1109/ACCESS.2020.2983774>
- Rasywir, E., Sinaga, R., & Pratama, Y. (2020). Evaluasi Pembangunan Sistem Pakar Penyakit Tanaman Sawit dengan Metode Deep Neural Network (DNN). *JURNAL MEDIA INFORMATIKA BUDIDARMA*, 4, 1206–1215. <https://doi.org/10.30865/mib.v4i4.2518>
- Regita Azzahra, A., Purnawansyah, Darwis, H., & Widyawati, D. (2023). Klasifikasi Daun Herbal Menggunakan Metode CNN dan Naïve Bayes dengan Fitur GLCM. *Indonesian Journal of Computer Science Attribution*, 12(4), 2183–2194.

- Rohman, M. A., Mudjirahardjo, P., & Muslim, M. A. (2021). Implementansi Metode Convolutional Neural Network Dan Ekstraksi GLCM Pada Klasifikasi Kanker Paru. *Jurnal Ilmiah Teknik Elektro*, 23(4).
- Rosadi, M. I., Lutfi, M., & Artikel, S. (2021). *Identifikasi Jenis Penyakit Daun Jagung Menggunakan Deep Learning Pre-Trained Model*. <https://doi.org/10.35891/explorit>
- Rozaqi, A. J., Sunyoto, A., & Arief, R. (2021). Deteksi Penyakit pada Daun Kentang Menggunakan Pengolahan Citra dengan Metode Convolutional Neural Network. *Citec Journal*.
- Sapitri, A., Raharjo, J., & Rizal, S. (2022). Identifikasi Penyakit Jagung Dengan Menerapkan Metode Gray Level Co-Occurrence Matrix (GLCM) Dan Support Vector Machine (SVM) Melalui Citra Daun. *e-Proceeding of Engineering*, 8(6), 2963–2971.
- Saputro, A. K., & Purnamasari, D. N. (2022). Identifikasi Jenis Plastik Berdasarkan Reflektansi Cahaya Menggunakan Transformasi Ruang Warna HSV Identification Of Plastic Type Based on Light Reflection In HSV Colorspace Conversion. *Jurnal Simantec*, 11(1).
- Segal-Rozenhaimer, M., Li, A., Das, K., & Chirayath, V. (2020). Cloud detection algorithm for multi-modal satellite imagery using convolutional neural networks (CNN). *Remote Sensing of Environment*, 237, 111446. <https://doi.org/https://doi.org/10.1016/j.rse.2019.111446>
- Singh, D., Jain, N., Jain, P., Kayal, P., Kumawat, S., & Batra, N. (2019). *PlantDoc: A Dataset for Visual Plant Disease Detection*. <https://doi.org/10.1145/3371158.3371196>
- Soekarta, R., Nurdjan, N., & Syah, A. (2023). Klasifikasi Penyakit Tanaman Tomat Menggunakan Metode Convolutional Neural Network (CNN). *Insect (Informatics and Security): Jurnal Teknik Informatika*, 8(2).
- Srivastava, D., Bhambhu, L., & Srivastava, D. K. (2010). Data classification using support vector machine. Dalam *Article in Journal of Theoretical and Applied Information Technology*. [www.jatit.org](http://www.jatit.org)

- Suhendra, R., Juliwardi, I., & Sususi. (2022). *Identifikasi dan Klasifikasi Penyakit Daun Jagung Menggunakan Support Vector Machine*. 1(1), 29–35. <http://jurnal.utu.ac.id/JTI>
- Sunardi, S., Yudhana, A., & Saifullah, S. (2018). Identification of Egg Fertility Using Gray Level Co-Occurrence Matrix and Backpropagation. *Advanced Science Letters*, 24, 9151–9156. <https://doi.org/10.1166/asl.2018.12115>
- Supriyanto, A., Rizal Isnanto, R., & Nurhayati, O. D. (2023). Robusta Coffee Leaf Disease Classifications Using SVM Method and GLCM Feature Extraction. *Jurnal Nasional Teknik Elektro Dan Teknologi Informasi*, 4, 241–248.
- Syahriani, I., Evelyn, C., Istiqomah, D., Noviyanti, E., Adila, H., Rahayu, R. P., & Priyanti. (2021). Identifikasi Penyakit pada Batang Tanaman Jagung (Zea Mays) di Kecamatan Panyabungan Kabupaten Mandailing Natal, Sumatera Utara. *Prosiding SEMNAS BIO*.
- Ulhaq, M. A., & Masnilah, R. (2019). Pengaruh Penggunaan Beberapa Varietas dan Aplikasi *Pseudomonas fluorescens* untuk Mengendalikan Penyakit Bulai (*Peronosclerospora maydis*) pada Tanaman Jagung (*Zea mays L.*). *Jurnal Pengendalian Hayati*, 2(1), 1. <https://doi.org/10.19184/jph.v2i1.17131>
- Ullu, H. H., Baso, B., Risald, Manek, P. G., & Chrisinta, D. (2022). Ekstraksi Fitur Berbasis Tekstur Pada Citra Tenun Timor Menggunakan Metode Gray Level Co-occurrence Matrix. *Journal of Information and Technology (JITU)*, 2(2).
- Wafa Akhyari, M., Suyoto, A., & Wahyu Wibowo, F. (2021). *Klasifikasi Penyakit Pada Daun Jagung Menggunakan Convolutional Neural Network*.
- Yanto, B., Fimawahib, L., Supriyanto, A., Herawan Hayadi, B., Rizki Pratama, R., Pasir Pengaraian, U., Tuanku Tambusai, J., Hilir, R., Hulu, R., Hazarin, U., & Ahmad Yani, J. (2021). Klasifikasi Tekstur Kematangan Buah Jeruk Manis Berdasarkan Tingkat Kecerahan Warna dengan Metode Deep Learning Convolutional Neural Network. *JURNAL INOVTEK POLBENG*, 6(2), 259–268.
- Yendra, R., Marifni, L., Suryani, I., Matematika, J., Sains dan Teknologi, F., Sultan Syarif Kasim Riau Jl Soebrantas No, U. H., & Baru, S. (2020). Klasifikasi Data Mining Untuk Seleksi Penerimaan Calon Pegawai Negeri Sipil Tahun

2017 Menggunakan Metode Naïve Bayes. *Jurnal Sains Matematika dan Statistika*, 6(1).

Yogeshwari, M., & Thailambal, G. (2021). Automatic feature extraction and detection of plant leaf disease using GLCM features and convolutional neural networks. *Materials Today: Proceedings*, 81(2), 530–536. <https://doi.org/10.1016/j.matpr.2021.03.700>

Zalvadila, A., Syafie, L., & Darwis, H. (2023). Klasifikasi Penyakit Tanaman Bawang Merah Menggunakan Metode SVM dan CNN. *Jurnal Informatika: Jurnal pengembangan IT (JPIT)*, 8(3).

