

DISERTASI

**Pemodelan Sistem Deteksi Penyakit Tanaman
Jagung Menggunakan *Deep Learning***

*(Modeling of Corn Plant Disease Detection System Using Deep
Learning)*

MOHAMAD ILYAS ABAS

D053201015



**PROGRAM STUDI DOKTOR ILMU TEKNIK ELEKTRO
DEPARTEMEN TEKNIK ELEKTRO
FAKULTAS TEKNIK
UNIVERSITAS HASANUDIN
GOWA
2024**

PENGAJUAN DISERTASI

**Pemodelan Sistem Deteksi Penyakit Tanaman
Jagung Menggunakan Deep Learning**

Disertasi

Sebagai Salah Satu Syarat untuk Mencapai Gelar Doktor

Program Studi Ilmu Teknik Elektro

Disusun dan diajukan oleh

MOHAMAD ILYAS ABAS

D053201015



Kepada

**FAKULTAS TEKNIK
UNIVERSITAS HASANUDIN
GOWA
2024**

DISERTASI

PEMODELAN SISTEM DETEKSI PENYAKIT TANAMAN JAGUNG MENGGUNAKAN DEEP LEARNING

MOHAMAD ILYAS ABAS

NIM: D053201015

Telah dipertahankan di hadapan Panitia Ujian Disertasi yang dibentuk dalam rangka penyelesaian studi pada Program Doktor Teknik Elektro Fakultas Teknik Universitas Hasanuddin pada tanggal 30 Agustus 2024 dan dinyatakan telah memenuhi syarat kelulusan

Menyetujui
Promotor



Prof. Dr. Ir. H. Syafruddin Syarif, MT
NIP.196111251 199802 1 001

Ko-Promotor



Dr. Ir. Ingrid Nurtanio, MT
NIP.19610813 198811 2 001

Ko-Promotor



Dr. Ir. Zulkifli Tahir, ST., M.Sc
NIP.19840403 201012 1 004

Dekan Fakultas Teknik
Universitas Hasanuddin



Prof. Dr. Eng. Ir. Muhammad Isran Ramli, S.T., M.T., IPM., ASEAN Eng.
NIP.19730926 200012 1 002

Ketua Program Studi S3
Teknik Elektro



Prof. Dr. Ir. H. Andani Achmad, M.T.
NIP.19601231 198703 1 022

PERNYATAAN KEASLIAN DISERTASI DAN PELIMPAHAN HAK CIPTA

Yang bertanda tangan di bawah ini:

Nama : Mohamad Ilyas Abas

NIM : D053201015

Program Studi : S3 Teknik Elektro

Dengan ini menyatakan bahwa, disertasi berjudul “Pemodelan Sistem Deteksi Penyakit Tanaman Jagung Menggunakan Deep Learning” adalah benar karya saya dengan arahan dari komisi pembimbing (Prof. Dr. Ir. H. Syafruddin Syarif, MT., sebagai promotor, Dr. Ir. Ingrid Nurtanio, MT sebagai co-promotor-1 dan Dr. Ir. Zulkifli Tahir, ST, M.Sc.). Karya ilmiah ini belum diajukan dan tidak sedang diajukan dalam bentuk apapun kepada perguruan tinggi manapun. Sumber informasi yang berasal atau dikutip dari karya yang diterbitkan maupun tidak diterbitkan dari penulis lain telah disebutkan dalam teks dan dicantumkan dalam Daftar Pustaka disertasi ini. Sebagian dari isi disertasi ini telah dipublikasikan di prosiding (The International Conference on Computer Science and Engineering Technology) Sebagai artikel prosiding dengan judul “Detection Of Corn Plant Diseases Using Convolutional Neural Network: A Review” kemudian di Jurnal Register (Scientific Journal of Information System Technology, Vol.10, No.1, 2024) sebagai artikel dengan judul “Comparison of Convolutional Neural Network Methods for the Classification of Maize Plant Diseases”, dan terakhir Jurnal (Buletin of Electrical Engineering and Informatics) sebagai artikel dengan judul “Improved EfficientNet with Hyperparameter Tuning for Detecting in Corn Leaf Disease”.

Dengan ini saya melimpahkan hak cipta dari karya tulis saya berupa disertasi ini kepada Universitas Hasanuddin

Gowa, Agustus 2024
Yang menyatakan



Mohamad Ilyas Abas

KATA PENGANTAR

Dengan memanjatkan puji syukur kehadiran Tuhan Yang Maha Esa, yang atas rahmat dan karunianya sehingga penulisan penelitian disertasi dengan judul **“Pemodelan Sistem Deteksi Penyakit Tanaman Jagung Menggunakan Deep Learning”** dapat penulis susun dan selesaikan dengan baik.

Dalam proses penyusunan disertasi ini yang penuh tantangan dalam mewujudkan gagasan-gagasan ke dalam sebuah penyusunan disertasi yang lengkap, penulis banyak mendapatkan dukungan dari berbagai pihak yang telah membantu penulis dalam menyusun disertasi yang sesuai dengan kaidah-kaidah keilmiahan yang dipersyaratkan. Untuk itu secara khusus penulis menyampaikan apresiasi dan terima kasih secara tertulis kepada:

1. Bapak Prof. Dr.Ir. Jamaluddin Jompa, M.Sc, selaku Rektor Universitas Hasanuddin Makassar
2. Bapak Prof. Dr.Ir. H. Syafruddin Syarif, M.T., selaku promotor, Ibu Dr. Ir. Ingrid Nurtanio, M.T, Selaku co-promotor 1 dan Bapak Dr. Ir. Zulkifli Tahir, ST, M.Sc., selaku co-promotor 2 yang telah meluangkan waktu, tenaga dan pikiran dalam membimbing dan memberi saran yang konstruktif sehingga disertasi ini dapat tersusun dengan baik dan terstruktur.
3. Bapak Prof. Dr. Ir. Indrabayu, ST., MT., M.Bus, Sys., IPM., ASEAN.Eng., Bapak Dr. Ir. Amil Ahmad Ilham, ST., M.IT, Bapak Dr. Ir. Adnan, ST., MT, Bapak Prof. Dr. Indra Budi, S.Kom., M.Kom selaku komisi penguji yang telah berkontribusi dalam memberikan saran dan masukan untuk penyusunan disertasi ini.
4. Rektor Universitas Hasanuddin, Bapak Prof. Dr. Ir. Jamaluddin Jompa, M.Sc., Dekan Fakultas Teknik, Bapak Prof. Dr.Eng. Ir. Muhammad Isran Ramli, S.T., M.T., IPM., ASEAN Eng., Ketua Departemen Teknik Elektro, Ibu Dr. Eng. Ir. Dewiani, M.T., IPM, Ketua Program Studi S3 Teknik Elektro, Bapak Prof. Dr. Ir. H. Andani Achmad, M.T., dan seluruh dosen serta staf S3 program studi Teknik Elektro yang telah memberikan dukungan dan layanan terbaik selama proses studi penulis
5. Ketua Badan Pembina Harian Perguruan Tinggi Universitas Muhammadiyah Gorontalo, Bapak Drs. Yusnan Ekie, M.Pd dan seluruh Jajaran BPH UMGO.
6. Rektor Universitas Muhammadiyah Gorontalo, Bapak Prof. Dr. Abd. Kadim Masaong, M.Pd, beserta wakil rektor dan seluruh jajaran pimpinan, Dekan Fakultas Sains dan Ilmu Komputer, Jurusan Informatika dan seluruh teman sejawat Program Studi Ilmu Komputer yang telah mendukung penulis selama dalam melaksanakan studi.
7. Balai Standarisasi Instrumen Pertanian sebagai mitra dalam pengumpulan data dan ujicoba data penyakit tanaman jagung.

8. Para sahabat, Teman seangkatan S3 Elektro UNHAS tahun 2020 dan Seluruh Mahasiswa S3 Teknik Elektro UNHAS. Terima kasih atas bantuan dan dukungannya selama ini kepada penulis.

Ucapan terima kasih yang sebesar-besarnya dan setinggi-tingginya kepada kedua orang tua, istri, anak dan beserta seluruh keluarga yang telah memberikan semangat dan dukungan moril kepada penulis selama menempuh studi.

Meskipun dalam penyusunan dan penulisan disertasi ini penulis telah berusaha maksimal namun tidak menutup kemungkinan masih terdapat berbagai kekurangan baik dari aspek penulisan maupun substansinya. Oleh karena itu saran, masukan dan kritik yang membangun sangat penulis harapkan demi perbaikan ke arah yang lebih baik lagi.

Akhir kata penulis mengucapkan terima kasih dan mohon maaf atas segala kekurangan yang ada. Semoga rahmat Tuhan Yang Maha Esa selalu menyertai kita semua.

Makassar, Agustus 2024

Penulis

ABSTRAK

MOHAMAD ILYAS ABAS. Pemodelan Sistem Deteksi Penyakit Tanaman Jagung Menggunakan Deep Learning (dibimbing oleh Syafruddin Syarif, Ingrid Nurtanio, Zulkifli Tahir)

Penelitian ini mengusulkan model deteksi dini melalui pendekatan Deep Learning CNN untuk tujuan klasifikasi penyakit tanaman jagung. Model deteksi ini bertujuan untuk meningkatkan akurasi dan kinerja model dalam membedakan berbagai penyakit yang umum terjadi pada tanaman jagung. Pendekatan ini memanfaatkan teknik tuning hyperparameter yang cermat dan terarah, termasuk metode pencarian grid dan pencarian acak, untuk menemukan kombinasi parameter yang optimal. Dataset yang digunakan yakni dataset public melalui Kaggle yang pengujiannya menggunakan dataset private yang diambil langsung pada tanaman jagung di Gorontalo. Hasil eksperimen menunjukkan bahwa pendekatan ini mampu mencapai tingkat akurasi yang signifikan dibandingkan dengan pendekatan tuning hyperparameter konvensional. Model deteksi dengan metode tuning hyperparameter yang diusulkan menunjukkan efektivitasnya dalam menemukan parameter yang optimal, memungkinkan CNN untuk mengidentifikasi penyakit tanaman jagung dengan tingkat keakuratan yang tinggi. Hasil penelitian ini menunjukkan bahwa model yang dibuat dapat melakukan deteksi penyakit tanaman jagung dengan akurasi sebesar 96.55% dan di implementasikan ke dalam sebuah sistem.

Kata Kunci : CNN, Deep Learning, Model Sistem Deteksi penyakit jagung, Hyperparameter tuning, Klasifikasi.

ABSTRACT

MOHAMAD ILYAS ABAS. Modeling of Corn Plant Disease Detection System Using Deep Learning (mentored by Syafruddin Syarif, Ingrid Nurtanio, Zulkifli Tahir)

This research proposes an early detection model through Deep Learning CNN approach for the purpose of corn plant disease classification. This detection model aims to improve the accuracy and performance of the model in distinguishing various diseases common to corn plants. This approach utilizes careful and targeted hyperparameter tuning techniques, including grid search and random search methods, to find the optimal combination of parameters. The dataset used is a public dataset through Kaggle which is tested using a private dataset taken directly on corn plants in Gorontalo. The experimental results show that this approach is able to achieve a significant level of accuracy compared to the conventional hyperparameter tuning approach. The detection model with the proposed hyperparameter tuning method shows its effectiveness in finding the optimal parameters, allowing CNN to identify corn plant diseases with a high level of accuracy. The results of this study show that the model created can perform corn plant disease detection with an accuracy of 96.55% and implemented into a system.

Keywords: CNN, Deep Learning, Corn disease detection system model, Hyperparameter tuning, Classification.

DAFTAR ISI

HALAMAN JUDUL	
PENGAJUAN DISERTASI	
PERSETUJUAN DISERTASI	
PERNYATAAN KEASLIAN DISERTASI	
KATA PENGANTAR	i
ABSTRAK.....	iii
ABSTRACT	iv
DAFTAR ISI	v
DAFTAR TABEL	vii
DAFTAR GAMBAR	viii
DAFTAR LAMPIRAN	x
BAB I PENDAHULUAN	1
1.1. Latar Belakang.....	1
1.2. Rumusan Masalah	8
1.3. Tujuan Penelitian.....	8
1.4. Batasan Masalah	8
1.5. Manfaat Penelitian.....	9
1.6. Ruang Lingkup Penelitian	9
BAB II KERANGKA KONSEPTUAL DAN HIPOTESIS PENELITIAN... 11	
2.1 Kerangka Konseptual.....	11
2.2 Hipotesis Penelitian.....	15
BAB III DETEKSI PENYAKIT TANAMAN JAGUNG MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK: SUATU TINJAUAN	55
3.1 Abstrak	55
3.2 Pendahuluan.....	55
3.3 Metodologi Penelitian	57
3.4 Hasil dan Pembahasan	59
3.5 Kesimpulan.....	68
BAB IV PERBANDINGAN METODE CONVOLUTIONAL NEURAL NETWORK UNTUK KLASIFIKASI PENYAKIT TANAMAN JAGUNG .69	
4.1 Abstrak	69
4.2 Pendahuluan.....	69

4.3 Metodologi Penelitian	73
4.3 Metode.....	76
4.4 Hasil dan Pembahasan	80
4.5 Kesimpulan	86
BAB V PEMODELAN SISTEM DETEKSI PENYAKIT TANAMAN JAGUNG MENGGUNAKAN DEEP LEARNING	88
5.1 Abstrak	88
5.2 Pendahuluan	89
5.3 Metodologi Penelitian	95
5.4 Hasil dan Pembahasan	104
5.5 Kesimpulan	110
BAB VI PEMBAHASAN UMUM.....	112
6.1 Detection Of Corn Plant Diseases Using Convolutional Neural Network: A Review	113
6.2 Perbandingan Metode Convolutional Neural Network Untuk Klasifikasi Penyakit Tanaman Jagung	115
6.3 Pemodelan Sistem Deteksi Penyakit Tanaman Jagung Menggunakan Deep Learning	117
BAB VII PENUTUP	119
7.1 Kesimpulan	119
DAFTAR PUSTAKA	122
LAMPIRAN	136
Detection Of Corn Plant Diseases Using Convolutional Neural Network: A Review	151

DAFTAR TABEL

Tabel 1. State of the art penelitian terkait.....	Error! Bookmark not defined.
Tabel 2. Studi literatur CNN	59
Tabel 3. Model ResNet50	82
Tabel 4. Model ResNet101	82
Tabel 5. Model Xception	83
Tabel 6. Hasil perbandingan akurasi	83
Tabel 7. Model ENet	84
Tabel 8. Data split.....	103
Tabel 9. Perbandingan Algoritma pada penelitian sebelumnya	104
Tabel 10. Perbandingan pada penelitian yang dilakukan	104
Tabel 11. Hasil pengujian Enet dengan algoritma optimizer dan Learning Rate	106
Tabel 12. Pengujian Yolo8 + Optimizer.....	109

DAFTAR GAMBAR

Gambar 1. Masukkan citra dapat digunakan sebagai pencarian jenis tanaman hias (Abdul Kadir, 2013)	16
Gambar 2. Arsitektur CNN (Sumit Saha, 2018)	19
<u>Gambar 3. Ilustrasi proses konvolusi</u>	<u>20</u>
Gambar 4. Small neural network	21
Gambar 5. Proses array CNN	21
Gambar 6. Pooling layer	22
Gambar 7. Prediksi model CNN	22
Gambar 8. Arsitektur CNN	23
Gambar 9. Layar konvolusi	23
Gambar 10. Feature map	24
Gambar 11. Max Pooling	26
Gambar 12. Gambar Proses Konvolusi	27
Gambar 13. Gambar Dropout	29
Gambar 14. Gambar Ilustrasi jaringan backpropagation	30
Gambar 15. Confusion Matriks	31
Gambar 16. Mind Map Penelitian	11
Gambar 17. Kerangka pikir penelitian	11
Gambar 18. Fishbone diagram	12
Gambar 19. Milestone dan luaran penelitian	13
Gambar 20. Konstruksi penelitian dan hipotesis	16
Gambar 21. Kerangka penyakit tanaman jagung	57
Gambar 22. Struktur dasar CNN	58
Gambar 23. Kumpulan dataset	78
Gambar 24. Tahapan penelitian	79
Gambar 25. Model VGG16	80
Gambar 26. Model plot VGG16	81
Gambar 27. Model grafik Accuracy dan Loss VGG16	81
Gambar 28. Grafik perbandingan Accuracy dan Loss Model ResNet50, ResNet101 dan Xception	83
Gambar 29. Grafik model Accuracy dan Loss ENet	85
Gambar 30. Confusion matriks	85
Gambar 31. Representasi skema EfficientNet (Atila et al., 2021).	96
Gambar 32. Tahapan penelitian	96
Gambar 33. Sampel dataset	102
Gambar 34. Diagram tahapan penelitian	102
Gambar 35. Hasil pengujian adam dan adamax optimizer	105

Gambar 36. Hasil pengujian Rmsprop dan SGD optimizer	105
Gambar 37. Grafik model akurasi dan loss pada setiap penambahan epoch.....	107
Gambar 38. Implementasi mobile web.....	107
Gambar 39. Confusion matriks Yolo8.....	108
Gambar 40. Pengolahan data menggunakan Yolo8	109
Gambar 41. Hasil testing lapangan menggunakan Yolo8	110

DAFTAR LAMPIRAN

Lampiran 1. Dokumentasi perizinan dan wawancara.....	136
Lampiran 2. Pengambilan data	137
Lampiran 3. Rekam jejak publikasi	138
Lampiran 4. Publikasi jurnal 1	140
Lampiran 5. Publikasi jurnal 2	145
Lampiran 6. Biodata	147

BAB I

PENDAHULUAN

1.1. Latar Belakang

Hyperparameter tuning adalah proses penyetelan parameter-parameter yang tidak dipelajari secara otomatis oleh model, tetapi mempengaruhi kinerja keseluruhan model (Ottoni et al., 2024). Pada penerapannya melibatkan pencarian kombinasi terbaik dari nilai-nilai hyperparameter untuk meningkatkan kinerja dan kecocokan model terhadap data yang ada. Dalam konteks Convolutional Neural Network (CNN), hyperparameter seperti tingkat pembelajaran, jumlah lapisan, ukuran kernel, dan fungsi aktivasi dapat disesuaikan untuk mencapai tingkat akurasi yang lebih tinggi dan mengurangi overfitting atau underfitting. Proses ini dapat dilakukan secara manual dengan mencoba berbagai kombinasi secara empiris, atau menggunakan teknik otomatis seperti pencarian grid, pencarian acak, atau optimasi bayesian untuk menemukan konfigurasi yang optimal secara efisien. Hyperparameter tuning memainkan peran kunci dalam meningkatkan kinerja model yang kompleks seperti CNN dan telah menjadi bagian integral dari pengembangan model machine learning yang efektif.

Klasifikasi penyakit pada tanaman, khususnya tanaman jagung, merupakan aspek penting dalam pertanian modern yang berkelanjutan. Tanaman jagung, sebagai salah satu tanaman pangan utama di seluruh dunia, sering kali terkena serangan penyakit yang dapat mengurangi hasil panen secara signifikan. Identifikasi penyakit secara dini dan akurat menjadi kunci dalam upaya mengendalikan penyebaran penyakit dan mengurangi kerugian yang ditimbulkannya. Dalam konteks ini, penggunaan teknologi kecerdasan buatan, seperti Convolutional Neural Network (CNN), telah menarik perhatian sebagai alat yang potensial untuk mengklasifikasikan penyakit pada tanaman berdasarkan gambar daun atau bagian tanaman lainnya. Meskipun pendekatan ini menjanjikan, tantangan utama terletak pada pengaturan parameter atau hyperparameter yang

optimal untuk meningkatkan akurasi dan kehandalan model. Oleh karena itu, penelitian yang fokus pada optimasi hyperparameter untuk CNN dalam klasifikasi penyakit tanaman jagung memiliki relevansi yang besar dalam meningkatkan produktivitas pertanian dan ketahanan pangan secara global. Dengan pendekatan yang tepat, teknologi kecerdasan buatan dapat menjadi alat yang efektif dalam mendukung upaya pencegahan dan pengendalian penyakit tanaman, yang pada gilirannya dapat berkontribusi pada pertanian yang lebih berkelanjutan dan berdaya saing.

Seiring berjalannya waktu memang jagung merupakan komoditas unggulan pada tiap daerah yang perlu ditingkatkan dan mendapatkan perhatian lebih dari pemerintah. Oleh sebab itu, peneliti ingin melakukan penelitian tentang jagung khususnya dalam rangka peningkatan produksi jagung yang menjadi keinginan Presiden RI yakni menjadi sentra produksi utama jagung nasional. Target pemerintah sangat besar untuk kemajuan produksi jagung. Oleh sebab itu, perlu adanya edukasi terhadap petani, pelatihan kepada petani dan juga tata cara penanaman dan lain sebagainya.

Kondisi iklim di Indonesia termasuk kategori tidak menentu hal ini dapat memicu yang namanya hama dan penyakit. Dalam usaha peningkatan dan pengembangan tanaman jagung memang tidak luput dari gangguan hama dan penyakit pada tanaman jagung. Banyak strategi yang dilakukan untuk mengendalikan hama dan penyakit ini antara lain pemberian pupuk, pemilihan varietas, melakukan introduksi dan lain sebagainya. Tetapi tentunya hal yang dilakukan belumlah maksimal. Hama dan penyakit ini harus menjadi perhatian pemerintah melalui dinas pertanian dan juga balai pengendalian hama dan penyakit apabila ingin memberikan edukasi dan juga pencegahan dini terhadap penyakit tanaman jagung. Salah satu solusi yang ditawarkan yakni dengan mengidentifikasi hama dan penyakit dari gejala yang timbul baik pada daunnya dan pelepah tanaman jagung dengan menggunakan sebuah teknologi yang dapat mengklasifikasi hal tersebut. Beberapa hama dan penyakit yang cukup potensial dan sering muncul di areal lahan jagung di lapangan adalah, hama penggerek

batang jagung *Ostrinia furnacalis*, hama belalang kembara *Locusta migratoria*, sedangkan penyakit yaitu, penyakit bulai *Peronosclerospora maydis*, penyakit bercak daun *Curvularia sp.*, penyakit hawar daun *Helmistorporium sp.*, penyakit hawar pelepah *Rhizoktonia solani Khun*, dan penyakit karat daun *Puccinia sorghi Schwin*. Serangan hama dan penyakit yang terjadi pada tanaman jagung harusnya dapat diantisipasi sebelum meluas dan tentunya akan menyebar ke segala area tanaman jagung (Ilham et al., 2015). Umumnya penyakit tanaman jagung itu akan menunjukkan gejala secara kasat mata yang dapat terlihat dari tanaman jagung itu sendiri baik tahapan ringan dengan tingkat penyebaran sedikit sampai pada tingkat penyebaran yang banyak biasanya bisa diklasifikasikan dalam 3 sampai 10 minggu. Hal ini terkadang diabaikan oleh petani jagung karena ketidaktahuan dan menganggap bahwa gejala tersebut merupakan hal yang biasa terjadi serta tidak segera mengantisipasinya. Sehingga, akan membuat penyebaran akan terus meluas dan tentu akan sulit untuk dikendalikan.

Oleh karena itu, penyakit tanaman jagung secara citra dapat dipelajari sehingga perlu dianalisis menggunakan salah satu ilmu dalam ilmu komputer (*deep learning*) yakni klasifikasi citra. Untuk klasifikasi citra seperti penyakit tanaman jagung sendiri telah banyak algoritma yang digunakan untuk melakukan klasifikasi dengan baik salah satunya yakni menggunakan *CNN*. *CNN* dikenal memiliki akurasi terbaik untuk klasifikasi citra baik untuk penggunaan di dunia medis bahkan untuk mengklasifikasi penyakit sebuah tanaman.

Penelitian tentang citra memang hal yang paling sering dilakukan peneliti pada saat ini terkhusus untuk melakukan deteksi citra biji jagung (Syarief & Setiawan, 2020a) dan juga deteksi penyakit tanaman jagung menggunakan *CNN* (Hidayat et al., 2019). Untuk penggunaan algoritma *CNN* sendiri karena memiliki akurasi yang tinggi juga banyak digunakan peneliti sebelumnya menggunakan *ECNN* (R. Agarwal & Sharma, 2021a). Peluang riset memang terbuka untuk diagnosa penyakit jagung ini terlebih pada penggunaan algoritma *CNN*. Bahkan penelitian sebelumnya menyarankan untuk peningkatan dan penggabungan klasifikasi *neural network* dengan *Deep Learning* dan juga lebih banyak

kombinasi lagi seperti kelas, ukuran dataset, kecepatan pembelajaran dan lain sebagainya (Adekunle, 2020).

Penelitian-penelitian yang telah dilakukan sebelumnya memiliki berbagai macam kelebihan dari segi algoritma, dataset dan penggunaan berbagai macam dataset. Seperti pada penelitian (R. Agarwal & Sharma, 2021a) menggunakan algoritma *Enhanced Convolutional Neural Network (ECNN)* untuk identifikasi penyakit tanaman jagung. Empat aspek yang digunakan dalam implementasi *ECNN* yakni *framework ECNN*, *fused dilated convolutional layer*, *convolutional layer* dengan satu dimensi dan *ECNN motivation*. Dataset yang digunakan adalah 500 gambar dan diklasifikasikan sebanyak 9 kelas. Parameter yang dianalisis *f-measure*, akurasi, *recall*, dan presisi.

Untuk teknik pengambilan data juga pernah diteliti oleh (Wiesner-Hanks et al., 2018) dengan melakukan anotasi pengambilan data penyakit jagung. Penggunaan kamera genggam, kamera yang dipasang pada *boom* serta menggunakan *UAV* atau yang dikenal sebagai *drone*. Data yang berhasil dikumpulkan dari tiga perangkat tersebut adalah 18.222 gambar. Gambar tersebut berhasil dianotasi menjadi kamera *handheld* sebanyak 1.787 *image* dengan 7.669 anotasi, *Boom* sebanyak 8.788 *image* dengan 55.919 anotasi dan *drone* sebanyak 7.668 dengan 42.117 anotasi.

Kelebihan lainnya dari penelitian (Sladojevic et al., 2016) menggunakan algoritma generasi baru dari *CNN* yakni (CNNs) model yang dikembangkan ini mampu mengenali 13 jenis penyakit tanaman jagung dari daun yang sehat. Dengan kemampuan membedakan daun tanaman dari objek sekitarnya. Bahkan langkah-langkah dari algoritma ini telah divalidasi oleh ahli pertanian. Hasil eksperimen yang dikembangkan mencapai presisi antara 91% dan 98% dengan rata-rata 96,3%.

Penelitian lainnya secara *automatic* telah dilakukan oleh (G. Wang et al., 2017) *preprocessing* data diawali dengan mengubah ukuran gambar menjadi 256x256 piksel untuk jaringan dangkal, 224x224 untuk *VGG16*, *VGG19* dan

ResNet50 serta 299×299 untuk *Inception-V3*. Penelitian ini melakukan pengoptimalan dan model prediksi pada gambar. Dilakukan normalisasi *sample-wise*. Normalisasi dapat secara signifikan meningkatkan efisiensi pelatihan *end-to-end*. Percobaan dilakukan pada *workstation Ubuntu* yang dilengkapi dengan satu *CPU Intel Core i5 6500* (RAM 16GB), dipercepat oleh satu *GPU GeForce GTX TITAN X* (memori 12 GB). Implementasi model didukung oleh kerangka kerja pembelajaran mendalam *Keras* dengan *backend Theano*. Model *VGG16* yang disempurnakan memiliki performa terbaik, mencapai akurasi 90,4% pada set pengujian, menunjukkan bahwa *deep learning* adalah teknologi baru yang menjanjikan untuk klasifikasi keparahan penyakit tanaman yang sepenuhnya otomatis.

Penelitian lainnya juga telah dilakukan oleh (Jayakumar, 2020) deteksi dan klasifikasi jagung menggunakan *machine learning*. Penelitian yang dilakukan bertujuan untuk mengevaluasi kinerja algoritma *XGBoost*, *Gradien Boost*, *CNN* dan arsitekturnya *VGG16* dan *VGG19* yang digabungkan dengan augmentasi data terhadap algoritma *machine learning* tradisional seperti *Support Vector Machine (SVM)*, *Random Forest* serta mengukur keefektifannya dalam mengidentifikasi dan mengklasifikasi penyakit tanaman jagung dalam hal akurasi, presisi, *memory* dan waktu pelatihan. *Database* penyakit sebanyak 4.000 gambar dari model yang dikembangkan, arsitektur *VGG19 CNN* memiliki kinerja yang baik keseluruhan 95%.

Penelitian lainnya tentang *CNN* juga telah dilakukan oleh (Islam, 2020) untuk diagnosa tanaman langkah-langkahnya sebagai berikut: *Image Acquirement-Fundamental Image-Action dataset-Image Expansion-Analytical analysis*. Sistem yang dibuat memberikan tingkat akurasi sebesar 94,29%. Para pembudidaya internasional sangat terbantu dengan sistem yang dibuat. Penelitian ini berhasil melakukan diagnosa terhadap daun yang terserang penyakit seperti anggur, kentang dan *strawberry* sehingga meningkatkan produksi industri pertanian. Proses deteksi dikawal oleh ahli dengan teknik *image processing* sehingga mencapai *milestone* dalam waktu yang sangat singkat. Dalam penelitiannya

disarankan untuk mengembangkan sistem multimedia dan membuat perangkat lunak secara otomatis untuk mendeteksi penyakit tanaman dan memberikan solusinya.

Pada penelitian tentang segmentasi untuk diagnosa penyakit jagung juga telah dilakukan (Z. Wang & Zhang, 2018) dengan algoritma *Fully Convolution Neural Network (FCNN)*. Penelitian ini menunjukkan bahwa metode *FCNN* memiliki efek segmentasi yang lebih baik dengan akurasi 96% dibandingkan dengan metode *N-Cut* dan *SVM*. Di tahun 2021 pengembangan diagnosa penyakit bermuara ke pengembangan *mobile based* (Ahmed, 2021; Picon et al., 2019) dengan mengumpulkan 92.206 gambar dari tanaman yang sehat dan terinfeksi. Akurasi yang berhasil dicapai adalah 94% dalam mengenali 38 kelas penyakit yang paling umum dari 14 spesies tanaman.

Peningkatan kinerja *CNN* dibutuhkan modifikasi pada jaringan-jaringan konvolusi itu sendiri hal itu disebut juga *Hyperparameter Tuning*. *Hyperparameter tuning* dapat meningkatkan kinerja dari *CNN* (Lacerda et al., 2021; Minarno et al., 2021). Parameter yang dioptimalkan yakni *backbone architecture, the number of inception modules, the number of neuron* dan *learning rate*. Bahkan dalam ujicoba yang pernah dilakukan *hyperparameter tuning* dapat meningkatkan akurasi model dan menghilangkan *overfitting* (Motta et al., 2020a). *Hyperparameter tuning* bertujuan untuk menentukan arsitektur lapisan dalam langkah ekstraksi fitur jaringan saraf pada *CNN* (Lee et al., 2018). Oleh sebab itu kinerja *CNN* akan lebih ditingkatkan menggunakan modifikasi parameter dengan teknik *hyperparameter tuning*.

Penyakit jagung sendiri pada dasarnya terdiri dari Hawar Daun (*Leaf Blight*), Bulai (*Downy Mildew*), Hama Belalang (*Locust Pest*) dan Bercak Daun (*Leaf Spot*) (Darusalam & Irmawati, 2019; Harsan et al., 2018). Beberapa penelitian juga telah dilakukan untuk klasifikasi biji jagung (A. Wu et al., 2018). Dalam pemrosesan citra juga dibutuhkan juga fitur untuk mendeteksi warna *RGB*, fitur lokal pada citra seperti *scale-invariant feature transform (SIFT)*, *speeded up*

robust features (SURF), dan *Oriented FAST androtated BRIEF (ORB)*, serta pendeteksi objek seperti histogram gradien berorientasi (HOG) (Kusumo et al., 2019a).

Salah satu keunggulan *CNN* yakni ekstraksi fitur secara otomatis (Brahimi et al., 2017a; Ramcharan et al., 2017) bahkan dapat mengenali sembilan jenis penyakit dan hama yang berbeda (Fuentes et al., 2017). Efektivitas algoritma *CNN* memang sudah terbukti bahkan untuk selain penyakit jagung (Amara et al., 2017). Memilih arsitektur dan set *hyperparameter* terbaik di antara kombinasi mungkin dapat menjadi tantangan yang signifikan. Untuk penelitian tentang *hyperparameter tuning CNN* telah diteliti sebelumnya (Lacerda et al., 2021; Minarno et al., 2021; Rama et al., 2020) optimasi *CNN* yang diterapkan pada *medical image processing*. Bahkan optimasi *hyperparameter CNN* diterapkan untuk *automatic classification* untuk deteksi morfologi nyamuk dengan akurasi mencapai 97,3% (Motta et al., 2020a).

Hyperparameter tuning menggunakan beberapa teknik dalam penerapannya yang terdiri dari *Stochastic Gradient Descent (SGD)*, *Adaptive Momentum (ADAM)*, *Adaptive Max Pooling (AdaMax)*, *Nesterov Adaptive Momentum (Nadam)*, *Root mean square propagation (RMSprop)* (Motta et al., 2020a; Prilianti et al., 2019). Percobaan yang dilakukan dapat menunjukkan kinerja berbeda di berbagai arsitektur *CNN* dan secara optimal menurunkan *Mean Square Error (MSE)*. Dengan melakukan *hyperparameter tuning CNN* dapat mengurangi jumlah bobot dan bias yang perlu dilatih, serta tentu dapat meningkatkan akurasi dalam klasifikasi (Lee et al., 2018).

Deteksi penyakit jagung ini nantinya akan dilakukan analisis dan dibuatkan sistem (Ahmed, 2021; Xie et al., 2016), masalah yang sering terjadi yakni banyak petani mengeluhkan tentang adanya hama dan penyakit yang menyerang jagung sehingga hal itu dapat berpengaruh pada panen setiap petani (Jayakumar, 2020). Oleh sebab itu, peneliti menawarkan model deteksi penyakit tanaman jagung yang dapat mendeteksi penyakit jagung dengan pola citra untuk mengolah data

penyakit yang terdiri dari *Blight*, *Common Rust*, *Gray Leaf Spot* dan *Healthy*. Data-data tentang penyakit jagung perlu dikumpulkan terlebih dahulu melalui data publik sehingga dapat diidentifikasi sebelumnya. Penggunaan algoritma *artificial intelligence* yakni dengan pengoptimalan *Hyperparameter Tuning Convolutional Neural Network*.

Peningkatan *hyperparameter* yang akan dilakukan pada penelitian ini yaitu optimasi dan juga komparasi beberapa algoritma *optimizer* seperti Adam, Adamax, SDG RMSProp. Pada akhir penelitian nanti Model Sistem Deteksi menggunakan *Deep Learning* dan juga algoritma optimasi akan menjadi kebaruan penelitian yang dilakukan sehingga penelitian lebih kompleks serta menghasilkan *novelty* dari penelitian.

1.2. Rumusan Masalah

1. Bagaimana merumuskan model sistem deteksi penyakit tanaman jagung melalui Systematic Literature Review?
2. Bagaimana menemukan model sistem deteksi penyakit tanaman jagung menggunakan hyperparameter tuning CNN?
3. Bagaimana implementasi model sistem deteksi yang didapatkan dari hasil eksperimen ke dalam sebuah sistem?

1.3. Tujuan Penelitian

1. Menemukan model sistem deteksi penyakit tanaman jagung dengan data penyakit tanaman jagung yang dikumpulkan menggunakan komparasi hyperparameter CNN dan juga algoritma optimasi.
2. Mengembangkan sistem deteksi penyakit tanaman jagung dari hasil eksperimen yang didapatkan untuk mengklasifikasi penyakit tanaman jagung.

1.4. Batasan Masalah

Adapun peneliti memiliki batasan masalah sebagai berikut:

1. Penelitian fokus pada deteksi penyakit tanaman jagung, membandingkan beberapa metode Deep Learning, menemukan model terbaik dan melakukan implementasi.
2. Dataset jagung yang digunakan untuk proses training dan testing diambil dari kumpulan dataset *public* yang diujicobakan pada data *private* di lapangan untuk jagung di Gorontalo sebagai lokus penelitian.
3. Penelitian terbatas pada penyakit tanaman jagung.
4. Penelitian dibatasi pada penemuan model deteksi penyakit tanaman jagung yang tepat dari *hyperparameter* algoritma *CNN* dengan menambahkan optimizer dan penerapannya secara implementasi sistem.

1.5. Manfaat Penelitian

1. Menemukan formulasi *hyperparameter tuning* algoritma *CNN* yang di implementasikan ke dalam sebuah sistem.
2. Memudahkan pihak Balai Standarisasi Instrumen Pertanian (BSIP) *Gorontalo* tentang identifikasi penyakit tanaman jagung.
3. Dapat membantu petani dalam mengenali dan memberikan solusi apabila terkena penyakit jagung.
4. Sistem yang dibuat dapat digunakan di segala lokasi untuk mengklasifikasi penyakit tanaman jagung secara *real* langsung di lapangan.

1.6. Ruang Lingkup Penelitian

Ruang lingkup penelitian untuk ketiga penelitian yang telah disebutkan adalah sangat relevan dalam konteks pengembangan solusi kecerdasan buatan untuk mendukung pertanian, khususnya dalam mendeteksi penyakit pada tanaman jagung. Penelitian pertama yang mengulas deteksi penyakit tanaman jagung menggunakan *Convolutional Neural Network (CNN)* memberikan landasan yang kokoh untuk pemahaman tentang bagaimana teknologi kecerdasan buatan dapat diterapkan dalam memperbaiki pertanian modern. Fokus penelitian ini adalah mengevaluasi kinerja berbagai model *CNN* dalam mengidentifikasi gejala penyakit pada tanaman jagung, serta mengidentifikasi tantangan yang dihadapi

dalam menerapkan teknologi ini, seperti keterbatasan data dan transferabilitas model antara kondisi pertanian yang berbeda.

Penelitian kedua, yang membahas perbandingan metode *CNN* untuk klasifikasi penyakit tanaman jagung, memperluas ruang lingkup dengan menyelidiki keunggulan dan kelemahan dari berbagai pendekatan *CNN*. Dengan melakukan perbandingan antara metode *CNN* yang telah ada, penelitian ini memberikan wawasan yang lebih dalam tentang kinerja relatif dan situasi di mana setiap pendekatan dapat memberikan hasil terbaik. Selain itu, penelitian ini menyoroti tantangan yang perlu diatasi dalam menerapkan teknologi *CNN* dalam konteks pertanian, seperti kebutuhan akan dataset yang besar dan representatif.

Sementara itu, penelitian ketiga yang membahas bagaimana membangun model deteksi penyakit tanaman jagung melalui peningkatan algoritma *EfficientNetB2* dengan hyperparameter tuning untuk mendeteksi penyakit tanaman jagung melalui daun dan menambahkan dimensi baru dalam ruang lingkup penelitian dengan mengkaji strategi untuk meningkatkan kinerja model *CNN* secara spesifik. Dalam hal ini, penelitian berfokus pada pembuatan model sistem deteksi penyakit tanaman jagung yang didalamnya mengandung pengoptimalan algoritma dan pengaturan parameter-parameter tertentu melalui teknik tuning hyperparameter. Tujuannya adalah untuk mengevaluasi apakah penyetelan parameter yang tepat dapat menghasilkan peningkatan signifikan dalam akurasi dan efektivitas model sistem deteksi dalam mendeteksi penyakit pada tanaman jagung.

Secara keseluruhan, ruang lingkup penelitian ini mencakup aspek-aspek kunci dalam pengembangan solusi kecerdasan buatan untuk mendukung pertanian, mulai dari pemahaman dasar tentang penggunaan *CNN* dalam mendeteksi penyakit tanaman hingga upaya untuk membangun model deteksi penyakit tanaman jagung dengan mengoptimalkan algoritma dan parameter-parameter model untuk meningkatkan kinerjanya. Dengan menyatukan temuan dari ketiga penelitian ini, diharapkan dapat memperkuat pemahaman dan aplikasi praktis teknologi kecerdasan buatan dalam mendukung ketahanan pangan dan kesejahteraan petani di seluruh dunia.

BAB II

KERANGKA KONSEPTUAL DAN HIPOTESIS PENELITIAN

2.1 Kerangka Konseptual

Permasalahan yang diangkat pada penelitian ini yakni tentang klasifikasi penyakit tanaman jagung. Penyakit pada tanaman jagung merupakan salah satu tantangan utama dalam pertanian modern yang berkelanjutan. Penyakit ini dapat disebabkan oleh berbagai patogen, seperti jamur, bakteri, dan virus, serta faktor lingkungan tertentu yang merugikan tanaman. Gejala penyakit pada tanaman jagung bervariasi tergantung pada jenis patogen yang menyebabkannya, namun umumnya meliputi perubahan warna, tekstur, dan bentuk daun, batang, atau bahkan buah jagung itu sendiri. Contohnya, penyakit seperti hawar daun, karat, dan embun tepung sering terjadi dan dapat menyebabkan kerugian yang signifikan dalam hasil panen. Penyakit-penyakit ini dapat menyebar dengan cepat melalui kontak langsung dengan tanaman yang terinfeksi, angin, air, atau melalui serangga vektor. Oleh karena itu, pengidentifikasian dini dan penanganan yang efektif dari penyakit-penyakit ini menjadi kunci dalam menjaga kesehatan dan produktivitas tanaman jagung. Penelitian ini berfokus pada pengembangan model klasifikasi penyakit tanaman jagung menggunakan Convolutional Neural Network (CNN) dengan optimasi hyperparameter. Pertama, penting untuk memahami berbagai penyakit yang biasa menyerang tanaman jagung, termasuk gejala yang muncul, faktor penyebab, dan dampaknya terhadap hasil panen. Pengetahuan mendalam tentang penyakit-penyakit ini menjadi dasar untuk pengembangan solusi klasifikasi yang efektif. Selanjutnya, CNN dipilih sebagai model yang cocok untuk tugas klasifikasi gambar karena kemampuannya yang terbukti dalam mengenali pola kompleks dalam data visual. Penggunaan CNN dalam konteks ini memerlukan pemahaman yang mendalam tentang struktur, lapisan, dan mekanisme kerjanya.

Pentingnya tuning hyperparameter dalam meningkatkan kinerja model juga menjadi fokus utama dalam penelitian ini. Hyperparameter tuning adalah proses penyetelan parameter-parameter kunci dalam CNN yang tidak dipelajari secara otomatis oleh model. Hal ini termasuk pengaturan seperti tingkat pembelajaran, jumlah lapisan, ukuran kernel, dan lainnya. Tujuan dari tuning hyperparameter adalah untuk meningkatkan akurasi dan keandalan model dalam klasifikasi penyakit tanaman jagung. Dengan menyesuaikan hyperparameter secara tepat, diharapkan model CNN dapat mencapai tingkat kinerja yang optimal.

Jagung merupakan tanaman pangan utama ketiga setelah padi dan terigu di dunia dan menempati posisi kedua setelah padi di Indonesia. Tanaman jagung tumbuh baik di daerah panas dan dingin dengan curah hujan dan irigasi yang cukup. Namun selama satu siklus hidupnya dari benih ke benih, setiap bagian jagung peka terhadap sejumlah penyakit sehingga dapat menurunkan kuantitas dan kualitas hasil. Oleh karena itu, masalah penyakit merupakan salah satu faktor pembatas produksi dan mutu benih. Penyakit itu sendiri merupakan hasil interaksi dari tiga komponen utama yaitu patogen, inang, dan lingkungan. Epidemi penyakit yaitu meningkatnya intensitas dan ekstensitasnya, sangat bergantung kepada besar sumbangan yang diberikan oleh masing-masing komponen tersebut dan berakhir dengan penurunan hasil. Usaha-usaha pengendalian untuk mengatasi masalah penyakit pada dasarnya adalah cara-cara memanfaatkan obat pengendali gulma tersebut untuk memperkecil akibat yang ditimbulkannya sehingga mencapai suatu titik di bawah ambang ekonomi dengan kerugian yang dapat diabaikan (Sudjono, 2018).

1. Penyakit-penyakit pada Daun dan Pelepah

a. Penyakit Bulai (Downy mildew)

Gejala bulai umumnya pada permukaan daun terdapat garis-garis sejajar tulang daun berwarna putih sampai kuning diikuti dengan garis-garis khlorotik sampai coklat bila infeksi makin lanjut. Tanaman terlihat kerdil dan tidak berproduksi, tetapi bila masih sempat berproduksi, ini merupakan hasil infeksi yang terlambat dan biji jagung yang dihasilkan sudah terinfeksi patogen. Jamur

berkembang secara sistemik sehingga bila patogen mencapai titik tumbuh, maka seluruh daun muda yang muncul kemudian mengalami khlorotik; sedangkan daun pertama sampai ke empat masih terlihat sebagian hijau. Ini merupakan ciri-ciri dari infeksi patogen melalui udara, tetapi bila biji jagung sudah terinfeksi, maka bibit muda yang tumbuh memperlihatkan gejala khlorotik pada seluruh daun dan tanaman cepat mati. Di permukaan bawah daun yang terinfeksi, dapat dilihat banyak terbentuk tepung putih yang merupakan spora patogen tersebut. Tanaman jagung yang terinfeksi dan tumbuh selama musim kemarau merupakan sumber inokulum pertama di Indonesia. Jamur dapat bertahan hidup sebagai miselium dalam embrio biji yang terinfeksi. Bila biji ini ditanam, jamurnya ikut berkembang dan menginfeksi bibit, selanjutnya dapat menjadi sumber inokulum (penyakit). Infeksi terjadi melalui stomata daun jagung muda (di bawah umur satu bulan) dan jamur berkembang secara lokal atau sistemik. Sporangia (konidia) dan sporangiofora dihasilkan pada permukaan daun yang basah dan gelap. Sporangia berperan sebagai inokulum sekunder.

b. Hawar Daun *Helminthosporium* (Northern Leaf Blight)

Gejalanya mula-mula terlihat bercak kecil, oval, kebasahan, kemudian bercak memanjang berbentuk elips, menjadi bercak nekrotik (kering) yang luas (hawar), berwarna hijau keabu-abuan atau coklat, dengan panjang hawar 2,5 sampai 15 cm. Bercak-bercak ini pertama kali terdapat pada daun-daun bawah (tua) kemudian berkembang menuju daun-daun atas (muda). Bila infeksi cukup berat, tanaman cepat mati, dengan hawar berwarna abu-abu seperti terbakar atau mengering. Tongkol tidak terinfeksi walaupun hawar dapat terjadi pada kelobot (kulit jagung). Hawar daun ini terjadi secara sporadis (keadaan penyebaran penyakit) di daerah yang sangat lembab. Perkembangan penyakit terjadi pada suhu udara antara 18-27 derajat celsius dan udara berembun. Pada musim kemarau serangan sangat berkurang/ jarang. Bila penyakit ini muncul, sebelum bulu jagung keluar, kehilangan hasil dapat mencapai 50%, dan kehilangan hasil tidak berarti bila infeksi terjadi pada 6 minggu setelah bulu jagung keluar.

c. Bercak Daun *Helminthosporium* (Southern Leaf Blight)

Dikenal dua tipe bercak menurut ras patogennya (organisme kecil penyebab infeksi) yaitu bercak karena ras O berwarna coklat kemerahan dengan panjang 0,6 x 1,2-1,9 cm, sejajar sisi daun dengan pinggiran bercak berwarna kuning tua sampai coklat; sedang bercak karena ras T berwarna coklat kemerahan, lebih besar dengan panjang (0,6-1,2) x (0,6-2,7) cm, berbentuk kumpanan dengan halo yang mengelilinginya berwarna hijau kuning atau khlorotik. Akhirnya bercak menjadi gelap atau coklat kemerahan. Ras O biasanya menyerang daun dan bercaknya lebih sejajar sisi daun, tongkol jarang diserang pada jagung yang bersitoplasma normal, sehingga kerugian oleh ras O ini kurang berarti. Ras T sangat virulen terhadap jagung bersitoplasma jantan mandul. Bibit jagung bila terserang menjadi layu sampai mati dalam waktu 3-4 minggu setelah tanam. Bila tongkol terinfeksi lebih dini, biji-biji akan rusak dan busuk, bahkan tongkol dapat gugur.

Bercak-bercak oleh ras T terdapat di seluruh bagian tanaman: daun, pelepah, batang, tangkai kelobot, bulir, dan tongkol. Permukaan biji yang terinfeksi dilapisi miselium lebar berwarna abu-abu sampai hitam, sehingga dapat menurunkan hasil cukup besar. Semakin banyak bercak-bercak terdapat pada daun, ukuran bercaknya semakin sempit; tetapi bercak membesar, bila jumlah bercak sedikit. Ras T yang menyerang jagung bersitoplasma normal, menghasilkan bercak-bercak kecil berukuran 2-4mm, berwarna coklat kemerahan sampai coklat. Bercak-bercak sudah dapat dilihat pada tanaman muda 2 minggu setelah tanam. Konidia berwarna hijau zaitun; melengkung, tumpul ujungnya, bersekat 3-13 buah, berukuran (10-17) x (30-115). Berkecambah pada kedua ujungnya. Hilum tidak menonjol. Patogen dengan ras O dan ras T sulit dikenali dari gejala daun pada jagung bersitoplasma normal. Ras T sangat virulen pada jagung yang bersitoplasma jantan mandul, dapat menyerang tongkol dan daun. Serangan ras T pada jagung bersitoplasma normal menghasilkan bercak kecil-kecil. Ras T menghasilkan toksin khusus yang hanya dapat mengganggu membran mitokhondria sel-sel jagung bersitoplasma jantan mandul sehingga respirasi

meningkat, gejala penyakit tampak lebih besar dan banyak. Serangan ras O pada kedua jenis jagung tidak menghasilkan reaksi yang berbeda.

d. Busuk Pelepah (Sheath Blight)

Pada tahap awal tampak permukaan pelepah bercak jamur berwarna salmon, kemudian berubah jadi abu-abu pudar. Bercak meluas dan terpisah-pisah seperti gejala panu dan sering diikuti pembentukan sklerotia dengan bentuk tidak beraturan, berkesan seperti cipratan tanah, berwarna putih, salmon sampai coklat gelap. Tanah yang basah dengan cuaca hangat dan lembab merangsang pertumbuhan sklerotia dan miselia istirahat. Pada keadaan tanah yang kering, sklerotia (kumpulan dari miselium) dapat bertahan hidup cukup lama sampai bertahun-tahun dan merupakan sumber inokulum utama. Varietas jagung dengan pelepah daun yang rapat sampai ke tanah paling mudah terinfeksi. Jamur ini dikenal mempunyai banyak ras atau kelompok strainnya.

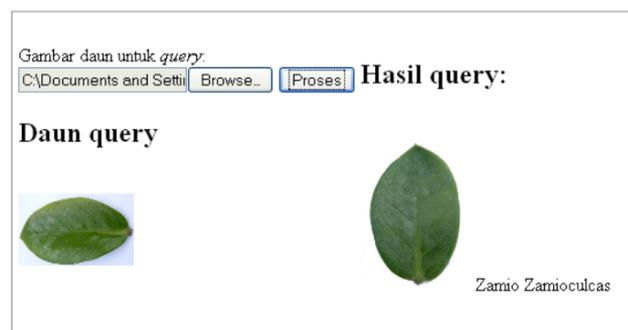
2. Citra Digital

Istilah citra digital sangat populer pada masa kini. Banyak peralatan elektronik yang menghasilkan citra digital; misalnya *scanner*, kamera digital, mikroskop digital, dan *fingerprint reader* (pembaca sidik jari). Perangkat lunak untuk mengolah citra digital juga sangat populer digunakan oleh pengguna untuk mengolah foto atau untuk berbagai keperluan lain. Sebagai contoh, *Adobe Photoshop* dan *GIMP (GNU Image Manipulation Program)* menyajikan berbagai fitur untuk memanipulasi citra digital (Kadir & Susanto, 2013).

Pengolahan citra merupakan bagian penting yang mendasari berbagai aplikasi nyata, seperti pengenalan pola, penginderaan jarak-jauh melalui satelit atau pesawat udara, dan *machine vision*. Pada pengenalan pola, pengolahan citra antara lain berperan untuk memisahkan objek dari latar belakang secara otomatis. Selanjutnya, objek akan diproses oleh pengklasifikasi pola. Sebagai contoh, sebuah objek buah bisa dikenali sebagai jeruk, apel, atau pepaya. Pada penginderaan jarak jauh, tekstur atau warna pada citra dapat dipakai untuk mengidentifikasi objek-objek yang terdapat di dalam citra. Pada *machine vision* (sistem yang dapat “melihat” dan “memahami” yang dilihatnya), pengolahan citra

berperan dalam mengenali bentuk-bentuk khusus yang dilihat oleh mesin. Penggunaan kamera pemantau ruangan merupakan contoh bagian aplikasi pemrosesan citra. Perubahan gerakan yang ditangkap melalui citra dapat menjadi dasar untuk melakukan pelaporan situasi yang terekam.

Pengolahan citra juga dapat dimanfaatkan, misalnya, untuk kepentingan penentuan jenis tanaman hias melalui ciri-ciri citra daun. Seseorang yang ingin tahu mengenai suatu tanaman cukup memasukkan citra daun yang ia miliki dan kemudian mengunggahnya ke sistem berbasis web. Selanjutnya, sistem *web* dapat mencari informasi yang sesuai dengan citra tersebut. Gambar 1 di bawah ini memperlihatkan contoh hasil pencarian jenis tanaman hias.



Gambar 1. Masukkan citra dapat digunakan sebagai pencarian jenis tanaman hias (Abdul Kadir, 2013)

3. *Image Processing*

Image processing adalah suatu metode yang digunakan untuk memproses atau memanipulasi gambar dalam bentuk 2 dimensi. *Image processing* dapat juga dikatakan segala operasi untuk memperbaiki, menganalisa, atau mengubah suatu gambar (Gonzales & Woods, 2002)

Konsep dasar pemrosesan suatu objek pada gambar menggunakan pengolahan citra diambil dari kemampuan indera penglihatan manusia yang selanjutnya dihubungkan dengan kemampuan otak manusia. Dalam sejarahnya, pengolahan citra telah diaplikasikan dalam berbagai bentuk, dengan tingkat kesuksesan cukup besar. Seperti berbagai cabang ilmu lainnya, pengolahan citra

menyangkut pula berbagai gabungan cabang-cabang ilmu, diantaranya adalah optik, elektronik, matematika, fotografi, dan teknologi komputer.

Pada umumnya, objektifitas dari pengolahan citra adalah mentransformasi atau menganalisis suatu gambar sehingga informasi baru tentang gambar dibuat lebih jelas. Ada empat klasifikasi dasar dalam pengolahan citra yaitu *point*, *area*, *geometric*, dan *frame*.

- a. *Point* memproses nilai *pixel* suatu gambar berdasarkan nilai atau posisi dari *pixel* tersebut. Contoh dari proses *point* adalah *adding*, *subtracting*, *contrast stretching* dan lain sebagainya.
- b. *Area* memproses nilai *pixel* suatu gambar berdasarkan nilai *pixel* tersebut beserta nilai *pixel* sekelilingnya. Contoh dari proses *area* adalah *convolution*, dan *blurring*.
- c. *Geometric* digunakan untuk mengubah posisi dari *pixel*. Contoh dari proses *geometric* adalah *scaling*, *rotation*, dan *mirroring*.
- d. *Frame* memproses nilai *pixel* suatu gambar berdasarkan operasi dari 2 buah gambar atau lebih.

4. *Supervised Learning*

Supervised learning mengadopsi konsep pendekatan fungsi, dimana pada dasarnya algoritma dilatih agar dapat memilih fungsi-fungsi yang paling menggambarkan input dimana X tertentu membuat estimasi terbaik dari Y. Namun, pada kenyataannya tidak sedikit orang yang kesulitan menemukan fungsi yang paling cocok. Hal ini karena sebenarnya algoritma bergantung pada asumsi yang digunakan. Jika ada asumsi yang tidak terpenuhi, tidak jarang hasil pengolahan data akan menimbulkan bias. Oleh karena itu, algoritma ini membutuhkan data latih yang benar sehingga sistem dapat mempelajari polanya dan regresi, klasifikasi, *K-NN*, *Naive Bayes*, *Decision Trees*, Regresi linier, *Support Vector Machine*, dan *neural network* (Witten; et al., 2008).

Algoritma *supervised learning* adalah jenis *machine learning* yang paling umum. Dalam bahasa indonesia, *supervised learning* diartikan sebagai pembelajaran diawasi. Istilah "diawasi" ini muncul karena algoritma ini dirancang untuk belajar melalui contoh. *Supervised learning* memiliki beberapa kelebihan

dan kekurangan. Keuntungan pertama, algoritma *supervised learning* adalah proses yang sederhana dan mudah dipahami. Selain itu algoritma ini juga powerfull untuk klasifikasi. Data yang digunakan bukanlah data *real time* sehingga memerlukan data baru untuk memprediksi hasil. Kelemahan dari algoritma ini adalah memerlukan waktu komputasi yang cukup panjang untuk pelatihan dan menggunakan algoritma yang lebih kompleks daripada algoritma *unsupervised learning* karena harus memberi label pada setiap input (Aggarwal, 2015).

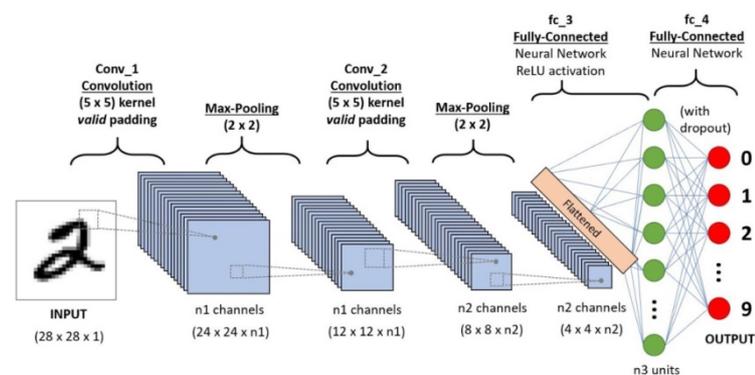
5. *Unsupervised Learning*

Algoritma *unsupervised learning* adalah algoritma yang tidak membutuhkan data berlabel. Pada *unsupervised learning*, algoritma tidak membutuhkan data training. Algoritma ini digunakan dalam mendeteksi pola dan pemodelan deskriptif yang tidak membutuhkan kategori atau *output* berlabel yang menjadi dasar algoritma untuk mencari model yang tepat. Algoritma ini digunakan untuk *clustering* dan *association rule*. Keunggulan dari *unsupervised learning* adalah karena tidak membutuhkan label, algoritma lebih leluasa untuk mencari pola yang mungkin sebelumnya belum diketahui. Sedangkan kekurangan dari algoritma ini adalah sulitnya menemukan informasi dalam data karena tidak ada label dan lebih sulit untuk membandingkan output dengan inputnya. Setelah memahami *supervised* dan *unsupervised learning*, ternyata tidak semua algoritma bisa dikategorikan sebagai *supervised* atau *unsupervised learning*. Algoritma tersebut bisa disebut dengan *semi-supervised learning*.

6. *Convolutional Neural Network*

Convolutional Neural Network (CNN) adalah pengembangan dari *Multilayer Perceptron (MLP)* yang didesain untuk mengolah data dua dimensi. *CNN* termasuk dalam jenis *Deep Neural Network* karena kedalaman jaringan yang tinggi dan banyak diaplikasikan pada data citra. Pada kasus klasifikasi citra, *MLP* kurang sesuai untuk digunakan karena tidak menyimpan informasi spasial dari data citra dan menganggap setiap piksel adalah fitur yang independen sehingga menghasilkan hasil yang kurang baik (H. Wu et al., 2019).

CNN pertama kali dikembangkan dengan nama *NeoCognitron* oleh Kunihiko Fukushima, seorang peneliti dari *NHKBroadcasting Science Research Laboratories*, Kinuta, Setagaya, Tokyo, Jepang. Konsep tersebut kemudian dimatangkan oleh Yann LeChun, seorang peneliti dari *AT&T Bell Laboratories di Holmdel, New Jersey, USA*. Model *CNN* dengan nama *LeNet* berhasil diterapkan oleh LeChun pada penelitiannya 9 mengenai pengenalan angka dan tulisan tangan. Pada tahun 2012, Alex Krizhevsky dengan penerapan *CNN* miliknya berhasil menjuarai kompetisi *ImageNetLarge Scale Visual Recognition Challenge 2012*. Prestasi tersebut menjadi momen pembuktian bahwa metode *Deep Learning*, khususnya *CNN* merupakan metode yang terbukti berhasil mengungguli metode *Machine Learning* lainnya seperti *SVM* pada kasus klasifikasi objek pada citra (Kim et al., 2019). Cara kerja *CNN* memiliki kesamaan pada *MLP*, namun dalam *CNN* setiap *neuron* dipresentasikan dalam bentuk dua dimensi, tidak seperti *MLP* yang setiap *neuron* hanya berukuran satu dimensi (H. Wu et al., 2019).



Gambar 2. Arsitektur *CNN* (Sumit Saha, 2018)

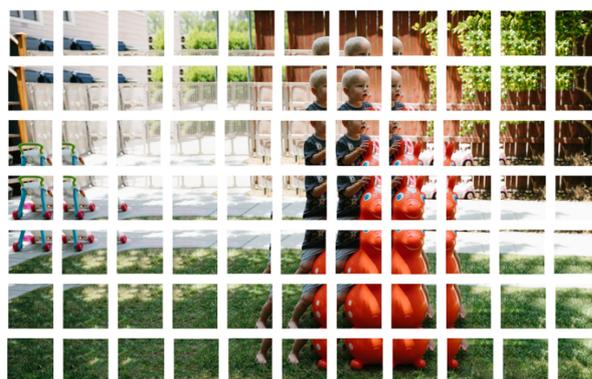
Algoritma *CNN* adalah algoritma *deep learning* yang dapat mengambil gambar input, melakukan pembobotan dan bias untuk berbagai aspek atau objek dalam gambar serta membedakan satu dengan yang lain. *Preprocessing* dalam *CNN* jauh lebih rendah dibandingkan dengan algoritma klasifikasi lainnya. *CNN* adalah jaringan saraf yang banyak digunakan yang terinspirasi oleh mekanisme persepsi visual tubuh makhluk hidup. Sejarahnya dimulai pada pertengahan tahun 90-an dan perkembangan cepat di akhir tahun 1990. Pada tahun 1990, beberapa penulis menerbitkan makalah di mana mereka mengembangkan jaringan saraf

tiruan yang disebut *LENET-5* yang berlapis-lapis yang dibangun untuk mengklasifikasikan angka tulisan tangan. Mampu mengenali pola visual langsung dari piksel rendah dengan sedikit atau tanpa pra-pemrosesan. Sekitar tahun 2010, peneliti mengusulkan arsitektur *CNN* yang dikenal sebagai *AlexNet* yang mirip dengan *LeNet-5* tetapi dengan struktur yang lebih dalam. Setelah kesuksesan *AlexNet*, banyak arsitektur lain yang diusulkan seperti *ZF Net*, *VGG Net*, *Google Net*, dan *ResNet*. Tren evolusi arsitektur *CNN* menunjukkan bahwa jaringan semakin dalam, jaringan dapat mempelajari variabel target dengan lebih akurat dan mendapatkan representasi fitur yang lebih baik karena arsitektur yang lebih dalam.

Secara garis besarnya, *CNN* memanfaatkan proses konvolusi dengan menggerakkan sebuah kernel konvolusi (filter) berukuran tertentu ke sebuah gambar, komputer mendapatkan informasi representatif baru dari hasil perkalian bagian gambar tersebut dengan filter yang digunakan. Berikut beberapa tahapan dalam *CNN* yang dapat dijelaskan sebagai berikut:

Langkah 1: Memecah gambar menjadi gambar yang lebih kecil yang tumpang tindih

Dari gambar seorang anak kecil yang menaiki kuda mainan diatas, hasil dari proses konvolusi dapat diilustrasikan sebagai berikut ini:

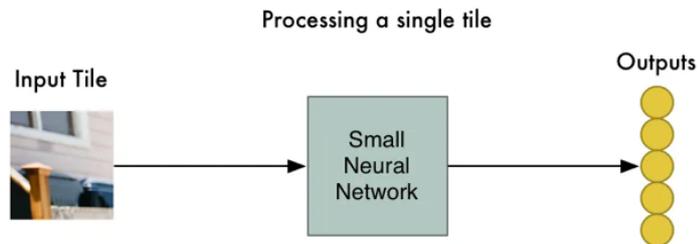


Gambar 3. Ilustrasi proses konvolusi

Dengan ini, gambar asli dari seorang anak kecil diatas menjadi 77 gambar yang lebih kecil dengan konvolusi yang sama.

Langkah 2: Memasukkan setiap gambar yang lebih kecil ke small neural network

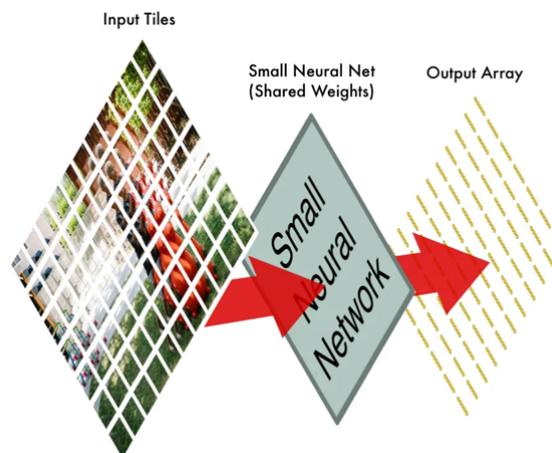
Setiap gambar kecil dari hasil konvolusi tersebut kemudian dijadikan input untuk menghasilkan sebuah representasi fitur. Hal ini memberikan CNN kemampuan mengenali sebuah objek, dimanapun posisi objek tersebut muncul pada sebuah gambar 4.



Gambar 4. Small neural network

Proses ini dilakukan untuk semua bagian dari masing-masing gambar kecilnya, dengan menggunakan filter yang sama. Dengan kata lain, setiap bagian gambar akan memiliki faktor pengali yang sama, atau dalam konteks neural network disebut sebagai weights sharing. Jika ada sesuatu yang tampak menarik di setiap gambarnya, maka akan ditandai bagian itu sebagai object of interest.

Langkah 3: Menyimpan hasil dari masing-masing gambar kecil ke dalam array baru

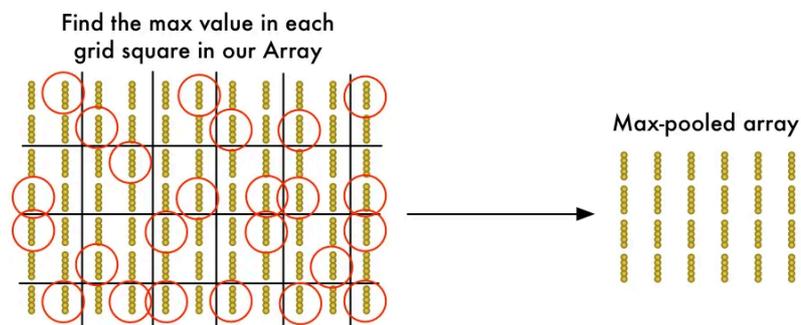


Gambar 5. Proses array CNN

Langkah 4: Downsampling

Pada langkah 3, array masih terlalu besar, maka untuk mengecilkan ukuran array nya digunakan downsampling yang penggunaannya dinamakan max pooling

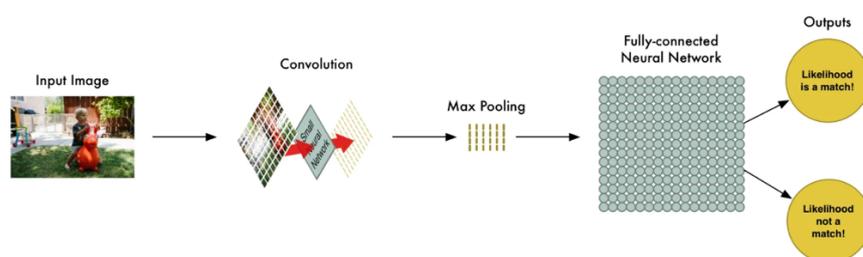
atau mengambil nilai pixel terbesar di setiap pooling kernel. Dengan begitu, sekalipun mengurangi jumlah parameter, informasi terpenting dari bagian tersebut tetap diambil.



Gambar 6. Pooling layer

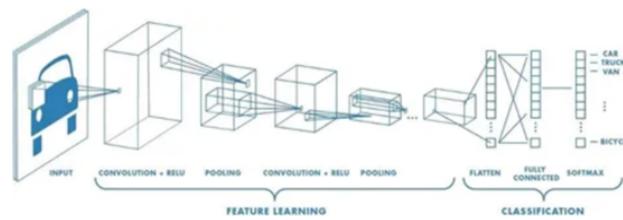
Langkah 5: Membuat Prediksi

Sejauh ini, kita telah merubah dari gambar yang berukuran besar menjadi array yang cukup kecil. Nah, array merupakan sekelompok angka, jadi dengan menggunakan array kecil itu kita bisa inputkan ke dalam jaringan saraf lain. Jaringan saraf yang paling terakhir akan memutuskan apakah gambarnya cocok atau tidak. Untuk memberikan perbedaan dari langkah konvolusi, maka bisa kita sebut dengan “fully connected” network. Secara garis besarnya, langkah-langkah diatas tampak seperti gambar 7 berikut ini:



Gambar 7. Prediksi model CNN

Arsitektur dari CNN dibagi menjadi 2 bagian besar, Feature Extraction Layer dan Fully-Connected Layer (MLP).

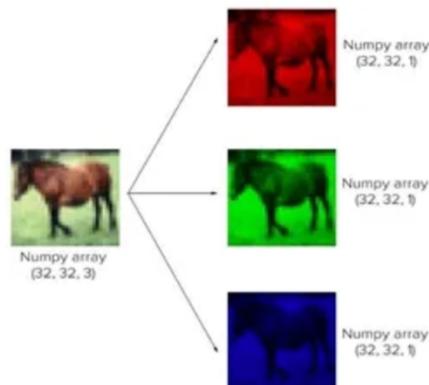


Gambar 8. Arsitektur CNN

Feature Extraction Layer

Proses yang terjadi pada bagian ini adalah melakukan “encoding” dari sebuah image menjadi features yang berupa angka-angka yang merepresentasikan image tersebut (Feature Extraction). Feature extraction layer terdiri dari dua bagian yaitu Convolutional Layer dan Pooling Layer. Namun kadang ada beberapa riset/paper yang tidak menggunakan pooling.

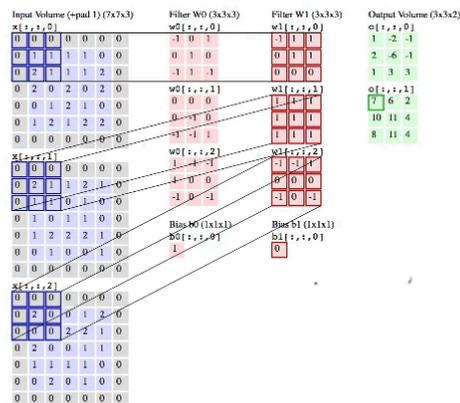
Convolutional Layer (Conv. Layer)



Gambar 9. Layer konvolusi

Gambar tersebut menunjukkan RGB (Red, Green, Blue) gambar berukuran 32x32 pixel yang sebenarnya adalah multidimensional array dengan ukuran 32x32 pixel (3 adalah jumlah channel). Convolutional layer terdiri dari neuron yang tersusun sedemikian rupa sehingga membentuk sebuah filter dengan panjang dan tinggi (pixel). Sebagai contoh, layer pertama pada feature extraction layer adalah conv. layer dengan ukuran 5x5x3. Panjang 5 pixel, tinggi 5 pixel, dan tebal/jumlah 3 buah sesuai dengan channel dari gambar 9 tersebut.

Ketiga filter ini akan digeser keseluruhan bagian dari gambar. Setiap pergeseran akan dilakukan operasi “dot” antara input dan nilai dari filter tersebut sehingga menghasilkan sebuah output atau biasa disebut sebagai activation map atau feature map. Proses dari feature map seperti pada gambar 10 berikut.



Gambar 10. Feature map

Stride

Stride adalah parameter yang menentukan berapa jumlah pergeseran filter. Jika nilai stride adalah 1, maka conv. filter akan bergeser sebanyak 1 pixel secara horizontal lalu vertical. Pada ilustrasi diatas, stride yang digunakan adalah 2. Semakin kecil stride maka akan semakin detail informasi yang kita dapatkan dari sebuah input, namun membutuhkan komputasi yang lebih jika dibandingkan dengan stride yang besar. Namun perlu diperhatikan bahwa dengan menggunakan stride yang kecil kita tidak selalu akan mendapatkan performa yang bagus.

Padding

Padding atau zero padding adalah parameter menentukan jumlah pixel (berisi nilai 0) yang akan ditambahkan di setiap sisi dari input. Hal ini digunakan dengan tujuan untuk memanipulasi dimensi output dari conv. layer (feature map). Dengan menggunakan padding, kita akan dapat mengukur dimensi output agar tetap sama seperti dimensi input atau setidaknya tidak berkurang secara drastis. Sehingga kita bisa menggunakan conv. layer yang lebih dalam sehingga lebih banyak feature yang berhasil di-extract. Meningkatkan performa model karena conv. layer akan fokus pada informasi yang sebenarnya yaitu yang berada diantara zero padding

tersebut. Pada ilustrasi diatas, dimensi dari input sebenarnya adalah 5x5, jika dilakukan convolution dengan filter 3x3 dan stride sebesar 2, maka akan didapatkan feature map dengan ukuran 2x2. Namun jika ditambahkan zero padding sebanyak 1, maka feature map yang dihasilkan berukuran 3x3 (lebih banyak informasi yang dihasilkan). Untuk menghitung dimensi dari feature map kita bisa gunakan rumus sebagai berikut.

$$Output = \frac{W + N + 2P}{S} + 1$$

Keterangan :

W = Panjang/Tinggi Input

N = Panjang/Tinggi Filter

P = Zero Padding

S = Stride

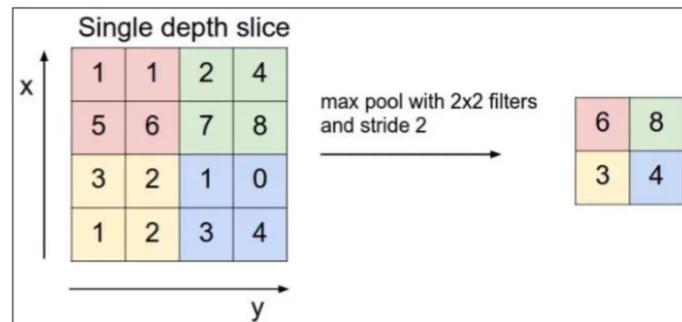
Fungsi aktivasi

Fungsi aktivasi berada pada tahap sebelum melakukan pooling layer dan setelah melakukan proses konvolusi. Pada tahap ini, nilai hasil konvolusi dikenakan fungsi aktivasi atau activation function. Terdapat beberapa fungsi aktivasi yang sering digunakan pada convolutional network, di antaranya tanh() atau reLU. Aktivasi reLU menjadi pilihan bagi beberapa peneliti karena sifatnya yang lebih berfungsi dengan baik.

Fungsi yang digunakan untuk aktivasi pada reLU, fungsi reLU adalah nilai output dari neuron bisa dinyatakan sebagai 0 jika inputnya adalah negatif. Jika nilai input dari fungsi aktivasi adalah positif, maka output dari neuron adalah nilai input aktivasi itu sendiri.

a. Pooling Layer

Pooling layer ditempatkan di antara *convolutional layer*, digunakan untuk mencapai invarian pergeseran yang dicapai dengan mengurangi resolusi peta fitur. Operasi *pooling* yang banyak digunakan adalah *average pooling* dan *max pooling*. Pada dasarnya, mengurangi jumlah koneksi antara lapisan konvolusi, menurunkan beban komputasi pada unit pemrosesan. Jenis *Pooling* terdiri dari *Lp Pooling*, *Max Pooling*, *Average Pooling* dan *Mixed Pooling*.



Gambar 11. Max Pooling

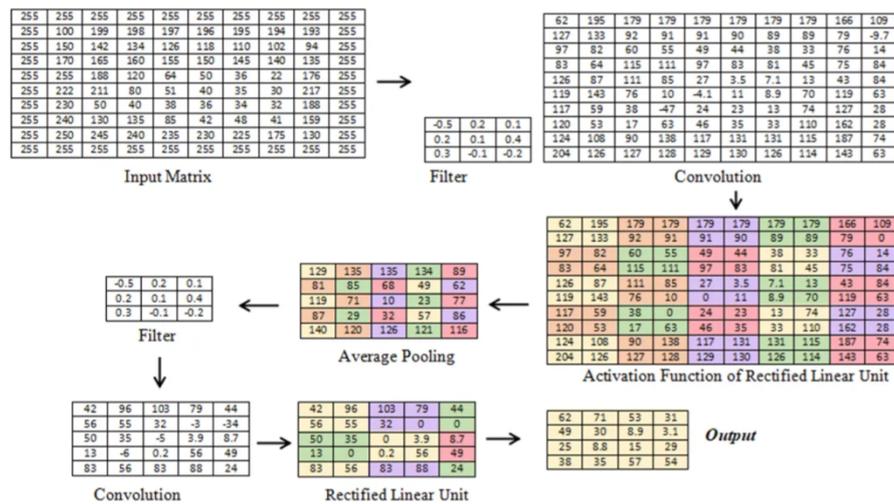
Ilustrasi proses pada Lapisan konvolusi

Lapisan konvolusi yang diaplikasikan untuk mendapatkan feature map. Contoh proses konvolusi dengan input berupa citra satu channel digambarkan seperti pada gambar berikut. Pada gambar tersebut, sebuah citra berukuran 10x10 piksel direpresentasikan sebagai matriks. Matriks awal diproses dengan dua layer konvolusi untuk mendapatkan feature map. Pada layer konvolusi pertama, filter yang digunakan berukuran 3x3 dengan bobot yang telah ditentukan. Hasil dari konvolusi pertama berupa matriks dengan ukuran 9x9.

Setelah melalui proses konvolusi, fungsi aktivasi dikenakan pada hasil konvolusi. Fungsi aktivasi yang digunakan adalah reLu. Output dari fungsi reLu kemudian dikenakan pooling dengan filter berukuran 2x2 dan stride sebesar dua. Sebelum melakukan pooling, dapat digunakan zero padding sehingga matriks hasil pooling berukuran 5x5. Matriks ini kemudian melalui tahap konvolusi kedua dengan ukuran filter sama seperti sebelumnya, tetapi dengan bobot yang berbeda. Dalam hal ini, ukuran tidak harus sama dengan konvolusi tahap pertama dan merupakan parameter yang bisa dioptimalkan. Sementara bobot matriks merupakan nilai yang dicari melalui proses pembelajaran.

Output dari proses konvolusi tahap kedua dikenakan dengan fungsi aktivasi yang sama, yaitu reLu. Pooling yang dikenakan berukuran 2x2 dengan stride satu, sehingga menghasilkan matriks dengan ukuran 4x4. Proses konvolusi bisa dilanjutkan sesuai dengan matriks akhir yang diinginkan. Dalam hal ini, jika konvolusi dihentikan sampai tahap kedua, maka matriks berukuran 4x4 tersebut menjadi input bagi neural network. Jika filter yang digunakan sejumlah n , maka

input bagi neural network adalah $n \times 4 \times 4$ nodes. Pada praktiknya, penggunaan fungsi aktivasi dan pooling bisa dibalik urutannya tanpa mengubah hasil dari konvolusi. Pembalikan ukuran ini bertujuan untuk mengurangi proses yang digunakan sehingga menjadi lebih cepat.



Gambar 12. Gambar Proses Konvolusi

b. *Fully-Connected Layer*

Terdapat beberapa lapisan yang terhubung penuh, setelah sejumlah lapisan konvolusi dan penyatuan. Setiap neuron pada lapisan saat ini terhubung dengan semua *neuron* pada lapisan sebelumnya. Lapisan terakhir *CNN* adalah lapisan keluaran yang membuat prediksi akhir.

Feature map yang dihasilkan dari feature extraction masih berbentuk multidimensional array, sehingga harus melakukan “flatten” atau reshape feature map menjadi sebuah vector agar bisa digunakan sebagai input dari fully-connected layer.

Lapisan Fully-connected adalah lapisan dimana semua neuron aktivitas dari lapisan sebelumnya terhubung semua dengan neuron di lapisan selanjutnya seperti halnya jaringan syaraf tiruan bisa. Setiap aktivitas dari lapisan sebelumnya perlu diubah menjadi data satu dimensi sebelum dapat dihubungkan ke semua neuron di lapisan Fully-Connected.

Lapisan Fully-Connected biasanya digunakan pada metode Multi lapisan Perceptron dan bertujuan untuk mengolah data sehingga bisa diklasifikasikan. Perbedaan anatar lapisan Fully-Connected dan lapisan konvolusi biasa dalah neuron di lapisan konvolusi terhubung hanya ke daerah tertentu pada input. Sementara lapisan Fully-Connected memiliki neuron yang secara keseluruhan terhubung. Namun, kedua lapisan tersebut masih mengoprasikan produk dot, sehinga fungsinya tidak begitu berbeda.

c. *Activation Function*

Setiap fungsi aktivasi yang dipilih sangat mempengaruhi kinerja jaringan saraf *convolutional* untuk masalah tertentu. Untuk lapisan tersembunyi *CNN*, *ReLU* adalah fungsi aktivasi yang disukai karena diferensiasi dan ketahanannya yang sederhana dibandingkan dengan fungsi aktivasi lain seperti *tanh* dan *sigmoid*. *ReLU* biasanya diikuti setelah operasi konvolusi. Nama lain dalam daftar fungsi aktivasi termasuk *sigmoid*, *softmax*, *Leaky ReLu*, *ELU*, dll.

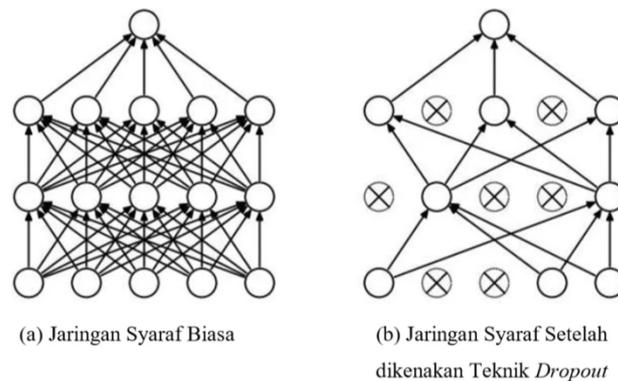
Untuk mencapai performa tercanggih, yang mencakup klasifikasi gambar, *natural language processing* (NLP), *estimation*, *text detection* dan banyak lagi. Untuk kasus pada penelitian ini bertujuan untuk mengklasifikasikan gambar dengan menetapkannya ke label tertentu. Dibandingkan dengan metode lain, *CNN* dapat mencapai akurasi klasifikasi yang lebih baik pada kumpulan data skala besar.

Dropout

Dropout adalah teknik regularisasi jaringan syaraf dimana beberapa neuron akan dipilih secara acak dan tidak dipakai selama pelatihan. Neuron-neuron ini dapat dibilang dibuang secara acak. Hal ini berarti bahwa kontribusi neuron yang dibuang akan diberhentikan sementara jaringan dan bobot baru juga tidak diterapkan pada neuron pada saat melakukan backpropagation.

Dropout merupakan proses mencegah terjadinya overfitting dan juga mempercepat proses learning. Dropout mengacu kepada menghilangkan neuron yang berupa hidden mapun layer yang visible di dalam jaringan. Dengan menghilangkan suatu neuron, berarti menghilangkannya sementara dari jaringan

yang ada. Neuron yang akan dihilangkan akan dipilih secara acak. Setiap neuron akan diberikan probabilitas yang bernilai antara 0 dan 1.



Gambar 13. Gambar Dropout

Pada gambar 13 di atas jaringan syaraf (a) merupakan jaringan syaraf biasa dengan 2 lapisan tersembunyi. Sedangkan pada bagian (b) jaringan syaraf sudah diaplikasikan teknik regularisasi dropout dimana ada beberapa neuron aktivasi yang tidak dipakai lagi. Teknik ini sangat mudah diimplementasikan pada model CNN dan akan berdampak pada performa model dalam melatih serta mengurangi overfitting.

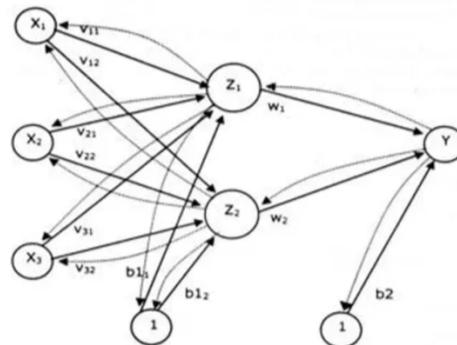
Pembelajaran Backpropagation

Salah satu sifat neural network yang menyerupai dengan otak manusia adalah bahwa neural network membutuhkan proses pembelajaran. Pembelajaran dilakukan untuk menentukan nilai bobot yang tepat untuk masing-masing input. Bobot bertambah jika informasi yang diberikan oleh neuron yang bersangkutan tersampaikan. Sebaliknya jika informasi tidak disampaikan maka nilai bobot berubah secara dinamis sehingga dicapai suatu nilai yang seimbang. Apabila nilai ini telah mampu mengindikasikan hubungan yang diharapkan antara input dan output, proses pembelajaran bisa dihentikan.

Backpropagation merupakan algoritma pembelajaran yang terawasi dan biasanya digunakan oleh perceptron dengan banyak lapisan untuk mengubah bobot-bobot yang terhubung dengan neuron-neuron yang ada pada lapisan tersembunyi. Algoritma ini menggunakan error output untuk mengubah nilai bobot-bobotnya dalam arah mundur (backward). Untuk mendapatkan error ini,

tahap perambatan maju (forward propagation) harus dikerjakan terlebih dahulu. Pada saat perambatan maju, neuron-neuron diaktifkan dengan menggunakan fungsi aktivasi yang dapat diturunkan, seperti fungsi sigmoid.

Arsitektur jaringan backpropagation seperti ditunjukkan pada dibawah ini. Gambar tersebut menunjukkan neural network yang terdiri dari tiga unit neuron pada lapisan input (x_1 , x_2 , dan x_3), dua neuron pada lapisan tersembunyi (Z_1 dan Z_2), dan 1 unit neuron pada lapisan output (Y). Bobot yang menghubungkan x_1 , x_2 , dan x_3 dengan neuron pertama pada lapisan tersembunyi adalah V_{11} , V_{21} , dan V_{31} . b_{11} dan b_{12} adalah bobot bias yang menuju neuron pertama dan kedua pada lapisan tersembunyi. Bobot yang mengubungkan Z_1 dan Z_2 dengan neuron pada lapisan output adalah w_1 dan w_2 . Bobot bias b_2 menghubungkan lapisan tersembunyi dengan lapisan output seperti gambar 14 di bawah ini:



Gambar 14. Gambar Ilustrasi jaringan backpropagation

d. Confusion Matriks

Confusion matrix adalah sebuah tabel yang sering digunakan untuk mengukur kinerja dari model klasifikasi di machine learning. Tabel ini menggambarkan lebih detail tentang jumlah data yang diklasifikasikan dengan benar maupun salah.

Confusion matrix adalah salah satu tools analitik prediktif yang menampilkan dan membandingkan nilai 30ctual atau nilai sebenarnya dengan nilai hasil prediksi model yang dapat digunakan untuk menghasilkan metrik evaluasi seperti Accuracy (akurasi), Precision, Recall, dan F1-Score atau F-Measure.

Ada empat nilai yang dihasilkan di dalam tabel confusion matrix, di antaranya True Positive (TP), False Positive (FP), False Negative (FN), dan True

Negative (TN). Ilustrasi tabel confusion matrix dapat dilihat pada gambar 15 berikut.

		Nilai Aktual	
		Positive	Negative
Nilai Prediksi	Positive	TP	FP
	Negative	FN	TN

Gambar 15. Confusion Matriks

True Positive (TP) : Jumlah data yang bernilai Positif dan diprediksi benar sebagai Positif.

False Positive (FP) : Jumlah data yang bernilai Negatif tetapi diprediksi sebagai Positif.

False Negative (FN) : Jumlah data yang bernilai Positif tetapi diprediksi sebagai Negatif.

True Negative (TN) : Jumlah data yang bernilai Negatif dan diprediksi benar sebagai Negatif.

Akurasi

Akurasi didefinisikan sebagai persentase dari data uji yang diklasifikasikan ke kelas yang benar. Akurasi dapat dinyatakan dalam persamaan berikut.

$$Akurasi = \frac{TP + TN}{TP + TN + FP + FN}$$

2.1.1 Penelitian Terkait

Penelitian sebelumnya (Lin et al., 2018b) tentang *A Novel Method Of Maize Leaf Disease Image Identification Based On A Multichannel Convolutional Neural Network* melakukan penelitian untuk mengidentifikasi penyakit daun jagung dari citra digital. Makalah ini mengusulkan *Multichannel Convolutional Neural Network (MCNN)* baru. Menggunakan metode yang meniru perilaku visual manusia dalam deteksi *saliency video*, lapisan subsampling pertama dan kedua terhubung langsung dengan lapisan pertama yang terhubung penuh. Selain itu, mode campuran metode penyatuan dan normalisasi, unit linier yang diperbaiki

(ReLU) dan *Dropout* diperkenalkan untuk mencegah *overfitting* dan difusi gradien. Untuk menguji *MCNN* yang diusulkan, 10.820 gambar *RGB* yang berisi lima jenis penyakit dikumpulkan dari basis penanaman jagung di Provinsi Shandong. Gambar asli tidak dapat digunakan secara langsung dalam percobaan identifikasi karena *noise* dan daerah yang tidak relevan. Oleh karena itu, *noise* tersebut dihilangkan dan disegmentasi dengan penyaringan homomorfik dan segmentasi *Region of Interest* (ROI) untuk membangun database standar. Serangkaian percobaan pada unit pemrosesan grafis (GPU) 8 GB menunjukkan bahwa *MCNN* dapat mencapai akurasi rata-rata 92,31% dan efisiensi tinggi dalam identifikasi penyakit daun jagung. Desain multichannel dan integrasi berbagai inovasi terbukti menjadi metode yang bermanfaat untuk meningkatkan kinerja.

Penelitian sebelumnya (Setiawan et al., 2019) melakukan penelitian tentang *Maize Leaf Disease Image Classification Using Bag of Features*. Metode yang digunakan yakni *Bag-of-Feature Method* (BOF) adalah kumpulan dari fitur yang terdapat dalam sebuah gambar. Misalnya pada citra wajah manusia, fitur terdiri dari telinga, hidung, mulut, rambut, dagu, anting-anting, warna latar, dan sebagainya. Pada gambar daun jagung, fitur dapat berupa daun, tulang daun, warna daun, penyakit, warna latar belakang, dll. *BOF* tidak perlu mendefinisikan fitur. Dapat langsung mengenali secara otomatis melalui fitur-fitur yang terdapat pada sebuah gambar. Skenario yang digunakan ada dua yakni skenario pertama pengujian untuk setiap jenis data: pelatihan dan validasi. Skenario pertama menggunakan 140 gambar untuk pelatihan dan sisanya (60 gambar) untuk validasi. Akurasi validasi untuk masing-masing skenario adalah 82%, 77%, dan 85%. Hasil pengujian menunjukkan bahwa skenario citra tersegmentasi memiliki akurasi terbaik untuk tahap validasi. Skenario kedua adalah 160 gambar untuk pelatihan dan sisanya (40 gambar) untuk validasi. Akurasi validasi untuk masing-masing skenario adalah 85%, 83%, dan 78%. Hasil pengujian menunjukkan bahwa skenario citra *RGB* memiliki akurasi terbaik untuk tahap validasi. Pada artikel ini, klasifikasi gambar daun pada tanaman jagung telah dilakukan dengan menggunakan metode *Bag-Of-Feature*. Metode ini terdiri dari ekstraksi ciri dengan *SURF*, *clustering* dengan *k-Means*, dan klasifikasi

menggunakan *Support Vector Machine*. Metode ini cukup berguna, dengan akurasi hingga 96% untuk pengujian dan 85% untuk validasi. Untuk mendapatkan hasil yang lebih baik, pelatihan dapat menggunakan lebih banyak data atau menggunakan metode *deep learning* untuk kecepatan dan akurasi klasifikasi yang tinggi.

Penelitian sebelumnya (Syarief & Setiawan, 2020a) tentang *Convolutional Neural Network For Maize Leaf Disease Image Classification*. Metode yang digunakan yakni Ekstraksi fitur untuk mendapatkan fitur secara otomatis menggunakan *convolutional neural network* (CNN). Tujuh model CNN yang diuji yaitu *AlexNet*, *virtual geometry group (VGG) 16*, *VGG19*, *GoogleNet*, *Inception-V3*, *residual network 50 (ResNet50)* and *ResNet101*. Sedangkan klasifikasi menggunakan metode *machine learning* meliputi *k-Nearest neighbor*, *decision tree* dan *support vector machine*. Berdasarkan hasil pengujian, klasifikasi terbaik adalah *AlexNet* dan *support vector machine* dengan akurasi, sensitivitas, spesifisitas masing-masing sebesar 93,5%, 95,08%, dan 93%.

Penelitian sebelumnya (Ahila Priyadarshini et al., 2019) tentang *Maize Leaf Disease Classification Using Deep Convolutional Neural Networks*. Dalam penelitiannya mengusulkan arsitektur berbasis jaringan saraf convolutional (CNN) yang dalam (LeNet yang dimodifikasi) untuk klasifikasi penyakit daun jagung. Hasilnya bahwa dari penelitian ini, menyimpulkan bahwa kernel ukuran 3 x 3 lebih cocok untuk klasifikasi penyakit daun jagung. Selanjutnya, *CNN LeNet* yang diusulkan ini juga dapat digunakan untuk klasifikasi penyakit daun tanaman lainnya.

Penelitian sebelumnya (R. Agarwal & Sharma, 2021a) tentang *Enhanced Convolutional Neural Network (ECNN) for Maize Leaf Diseases Identification*. Diagnosis penyakit daun jagung dilakukan dengan *Enhanced Convolutional Neural Network (ECNN)* dengan pembesaran bidang reseptif dalam penelitian ini. Empat aspek yang digunakan untuk mengimplementasikan *ECNN* dalam penelitian ini. Itu termasuk *framework ECNN*, *fused dilated convolutional layer*, *convolutional layer* dengan satu dimensi, dan *ECNN motivation*. *Multiple pooling* dan *stacked fused dilated convolutional layers*, *one input* dan *one-dimensional*

convolutional layer disusun oleh *ECNN*. Entropi silang yang diperkirakan dan probabilitas nyata dihitung pada tahap akhir. Bobot *ECNN* diperbarui dengan metode *gradient descent*. *Epoch backpropagation* dikalikan untuk menghitung parameter optimal. Model yang tidak dimodifikasi digunakan untuk membuat perbandingan hasil eksperimen. Penyakit daun jagung diidentifikasi dengan metode yang diusulkan. Situs *web Google* terkait data jagung digunakan untuk mengumpulkan sekitar 500 gambar. Kumpulan gambar ini mencakup berbagai stadium penyakit daun jagung. Ada 9 kelas dari gambar-gambar itu. Analisis parameter *F-measure*, akurasi, *recall*, dan presisi dilakukan dengan eksperimen.

Penelitian sebelumnya tentang *Hyperparameter Tuning* (Ramadhani et al., 2021) untuk identifikasi sampah organik dan anorganik, dengan menambah beberapa *hyperparameter* pada arsitektur *CNN* diperoleh akurasi tertinggi mencapai 91,2%. Hal ini tentu lebih tinggi dibandingkan tanpa menggunakan *hyperparameter*. *Hyperparameter* yang digunakan yaitu *dropout*, *padding* dan *stride*. Penambahan *dropout* sebesar 20% untuk meningkatkan *overfitting* saat pelatihan. Sedangkan *padding* dan *stride* digunakan untuk mempercepat proses pelatihan model. Hasil dari optimasi menunjukkan kenaikan tingkat akurasi model sebesar 91,2%, dimana sebelum dilakukan optimasi nilai akurasi model sebesar 67,6%.

Penelitian sebelumnya tentang *Hyperparameter* (Nurhopipah & Larasati, 2021) melakukan penelitian tentang identifikasi jenis sampah menggunakan algoritma *CNN*. Penelitian yang dilakukan ditambahkan optimasi penggunaan metode *CNN* untuk mendapatkan hasil akurat dalam mengidentifikasi jenis sampah. Sebelum dilakukan optimasi hanya mendapatkan akurasi 67,6% tetapi setelah dilakukan optimasi dengan menambah beberapa *hyperparameter* sehingga mendapatkan akurasi yang tinggi sebesar 91,2%. Beberapa *hyperparameter* yang digunakan yaitu *dropout*, *padding*, dan *stride*.

Penelitian sebelumnya juga dari (Lee et al., 2018) yang melakukan penelitian tentang optimasi *hyperparameter tuning* untuk meningkatkan kinerja *CNN* dengan penyetelan *hyperparameter* pada langkah ekstraksi fitur *CNN*. Dalam metode yang diusulkan, *hyperparameter* disesuaikan menggunakan

algoritma *parameter-setting-free harmony search (PSF-HS)*, yang merupakan metode optimasi metaheuristik. Dalam algoritma *PSF-HS*, *hyperparameter* yang akan disesuaikan diatur sebagai harmoni, dan memori harmoni dihasilkan setelah menghasilkan harmoni. Dilakukan simulasi menggunakan arsitektur *CNN* dengan mengacu pada dataset *LeNet-5* dan *MNIST*, dan simulasi menggunakan arsitektur *CNN* dengan mengacu pada *CifarNet* dan dataset *Cifar-10*. Dengan dua simulasi, dimungkinkan untuk meningkatkan kinerja dengan menyetel *hyperparameter* dalam arsitektur *CNN* yang diusulkan di masa lalu.

Penelitian sebelumnya juga tentang *hyperparameter tuning* (MINARNO et al., 2021) melakukan penelitian menggunakan *hyperparameter tuning CNN* untuk klasifikasi Covid-19. Metode yang digunakan yakni *Filter Gabor* dan *hyperparameter tuning CNN* melalui citra *CT-SCAN*. Data yang berhasil dikumpulkan sebanyak 2.481 gambar *CT-Scan*. Sebelum melatih model, dilakukan *preprocessing* data, seperti pelabelan, perubahan ukuran, dan augmentasi gambar. Pengujian Model dilakukan dengan beberapa skenario uji. Hasil terbaik diperoleh pada skenario untuk model *Filter Gabor* dan *CNN* dengan *Hyperparameter Tuning* mendapatkan akurasi sebesar 97,9% dan *AUC* sebesar 99%. Hasil ini lebih baik dibandingkan tanpa menggunakan *hyperparameter tuning CNN*.

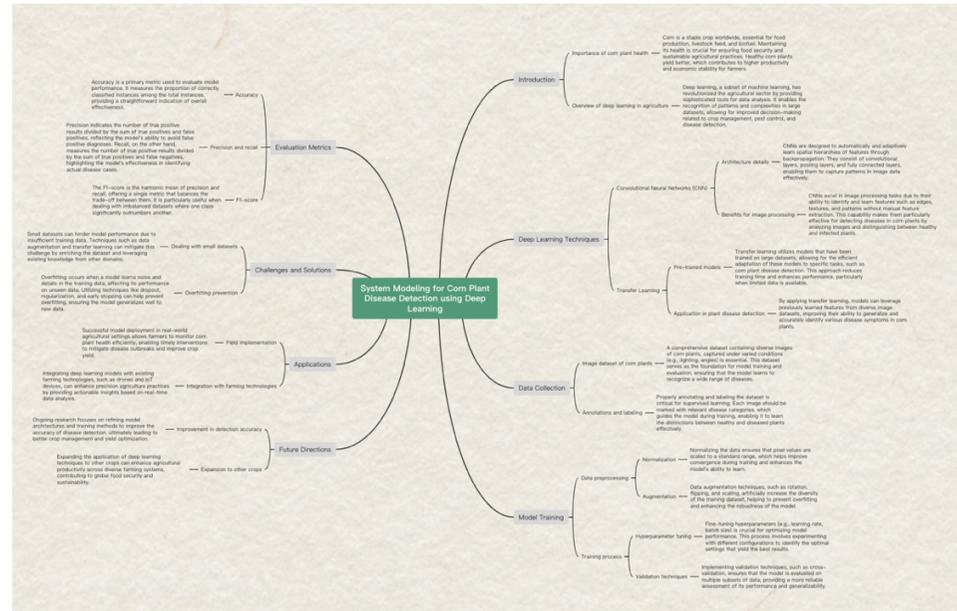
Penelitian lainnya juga tentang *hyperparameter tuning CNN* untuk *pre-trained* untuk efisiensi klasifikasi citra medis menggunakan *CNN* (Rama et al., 2020). Pada penelitian yang dilakukan mengimplementasikan *TensorFlow* untuk mendeteksi *tuberkulosis* pada citra dada dengan akurasi yang maksimal. Penelitian ini dapat melatih jaringan syaraf yang secara umum menggunakan *transfer learning* kemudian diubah dengan membuat rute output dari proses pra-pelatihan tepat sebelum lapisan klasifikasi baru. Oleh karena itu, model pra-pelatihan dapat disesuaikan, untuk mendiagnosis modalitas dan immodalitas dalam gambar *X-Ray* dengan menerapkan model *VGG16* pra-latihan *fine-tuning* dengan *estimator* dan fungsi aktivasi di lapisan tersembunyi arsitektur *CNN*. Hasilnya, ditunjukkan bahwa model fine tuning pra-pelatihan dapat memperoleh klasifikasi yang efisien dengan peningkatan kinerja berdasarkan tingkat akurasi

yang meningkat, sehingga juga memberikan kemungkinan sistem diagnosis otomatis. Diagnosis otomatis penyakit dari gambar input sangat diinginkan di bidang pemrosesan gambar medis.

Penelitian lainnya tentang penggunaan *hyperparameter tuning* terhadap *CNN* untuk klasifikasi tumor otak (Minarno et al., 2021). Penelitian ini menggunakan metode *CNN* untuk mendeteksi tumor pada citra MRI. Dataset yang digunakan sebanyak 3264 citra dengan gambar Glioma, Meningioma, Hipofisis dan tanpa tumor. Penerapan *CNN* dikombinasikan dengan *hyperparameter tuning* mencapai hasil optimal dalam mengklasifikasikan jenis tumor otak. Pada penelitian ini, pengujian model dilakukan dengan tiga skenario yang berbeda. Hasil klasifikasi tumor otak menunjukkan akurasi sebesar 96% pada skenario pengujian model ketiga

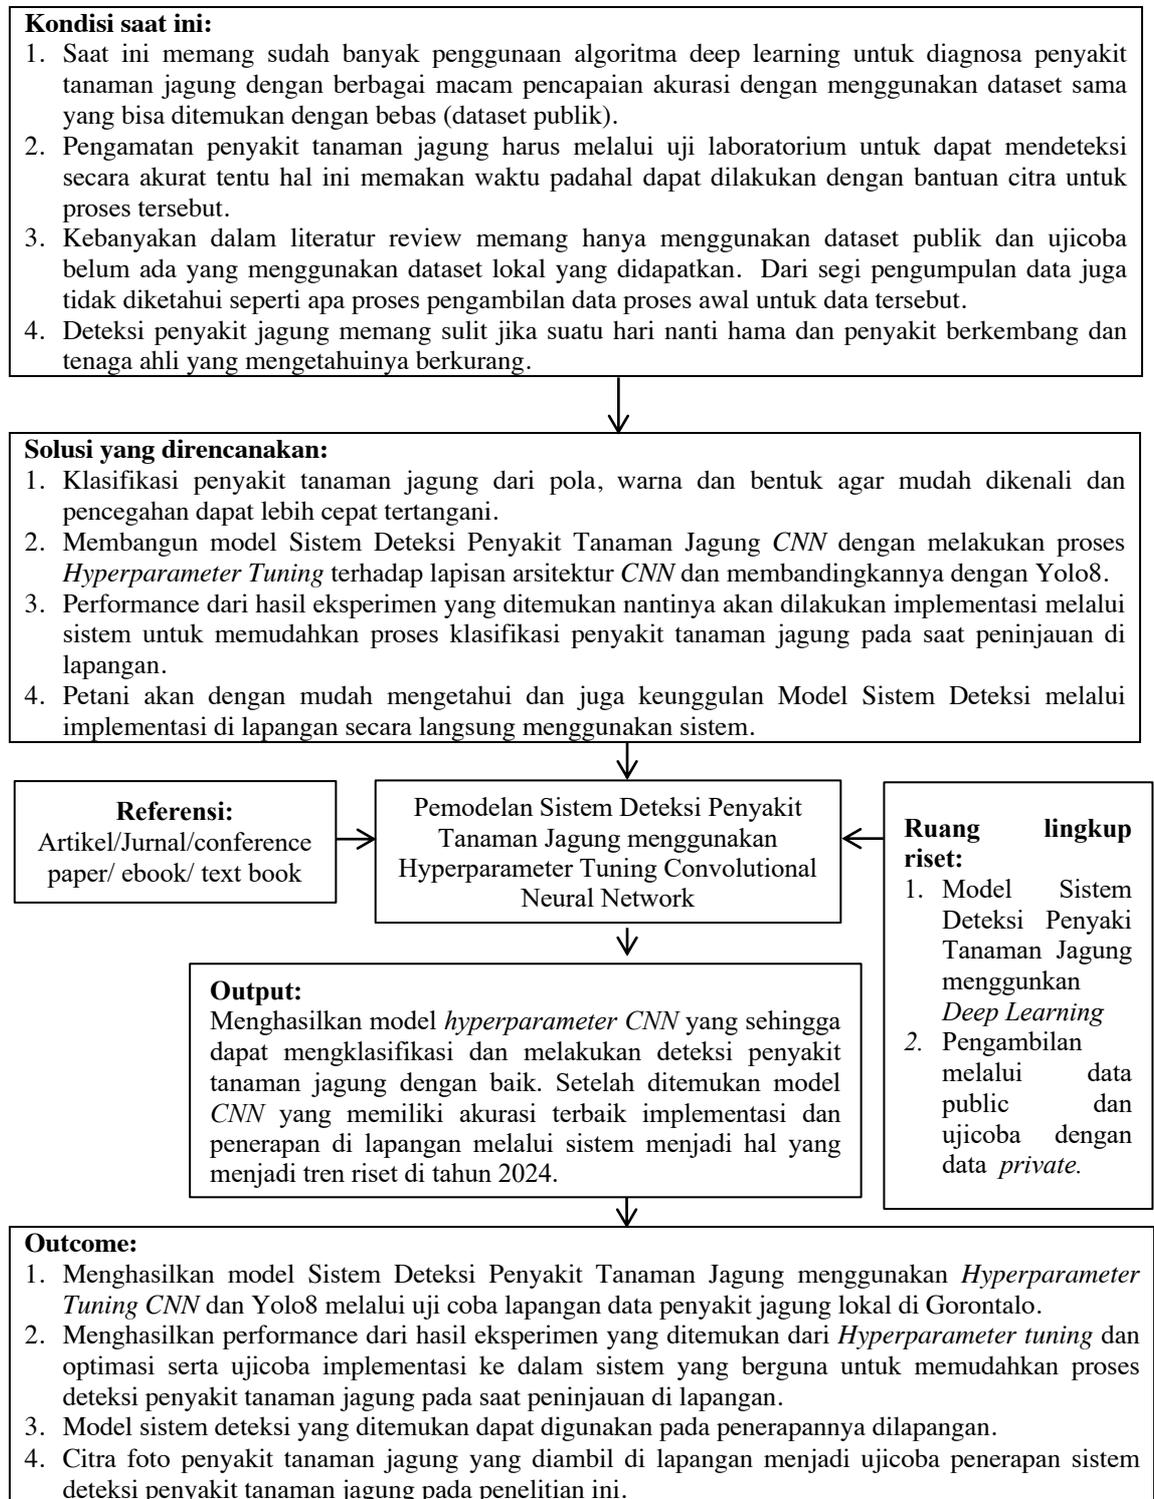
2.1.2 State of The Art

Berdasarkan *state of the art* dan hasil *review* pada mind map pada gambar 16 di bawah ini peneliti juga ingin melakukan penelitian tentang Pemodelan deteksi penyakit tanaman jagung dengan salah satu Teknik yakni *Hyperparameter Tuning CNN* untuk klasifikasi Penyakit Tanaman Jagung. Peneliti tidak hanya melakukan *hyperparameter tuning* tetapi membangun Model Deteksi Penyakit Tanaman Jagung menggunakan *hyperparameter CNN*. Dengan mengembangkan model sistem deteksi penyakit tanaman jagung yang dapat melakukan klasifikasi citra dan mendeteksi penyakit tanaman jagung tentu akan sangat berguna pada masa yang akan datang. Terkait Penyakit tanaman jagung yang paling umum ditemui, proses pemodelan, evaluasi model, sampai dengan implementasi sistem menjadi bagian penting dari hasil penelusuran menggunakan mind map. Hasil dari penelitian ini diharapkan dapat memberikan kontribusi pengetahuan terhadap penemuan Model Sistem Deteksi Penyakit Tanaman Jagung dengan optimasi jaringan *hyperparameter CNN* dan algoritma optimasi untuk data klasifikasi penyakit tanaman jagung baik dari pra-pelatihannya sampai akurasi dan juga implementasi sistem di lapangan yang dapat melakukan analisis langsung terhadap penyakit jagung.



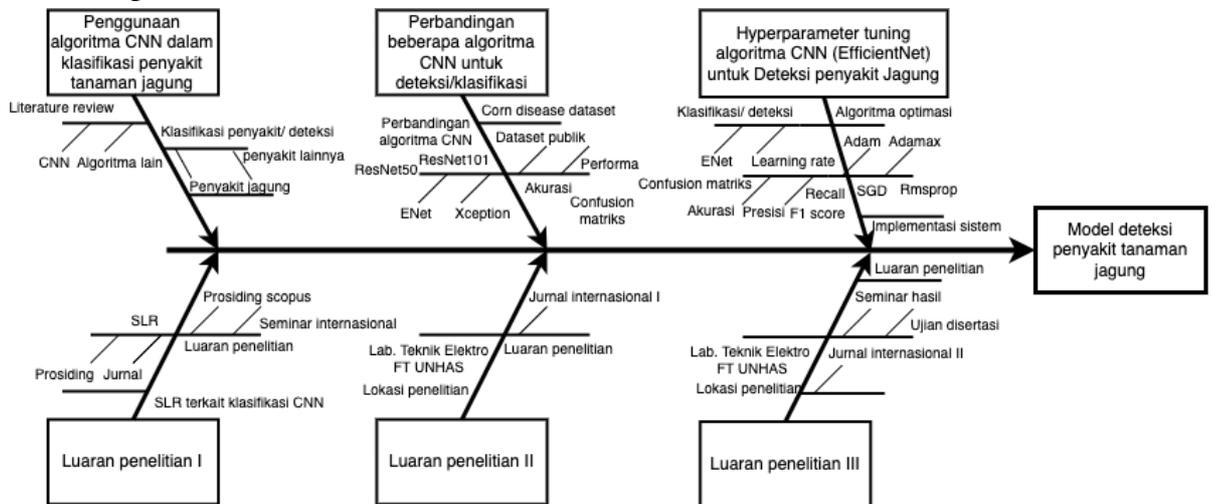
Gambar 16. Mind Map Penelitian

2.1.3 Kerangka Pikir



Gambar 17. Kerangka pikir penelitian

2.1.4 Diagram Fishbone

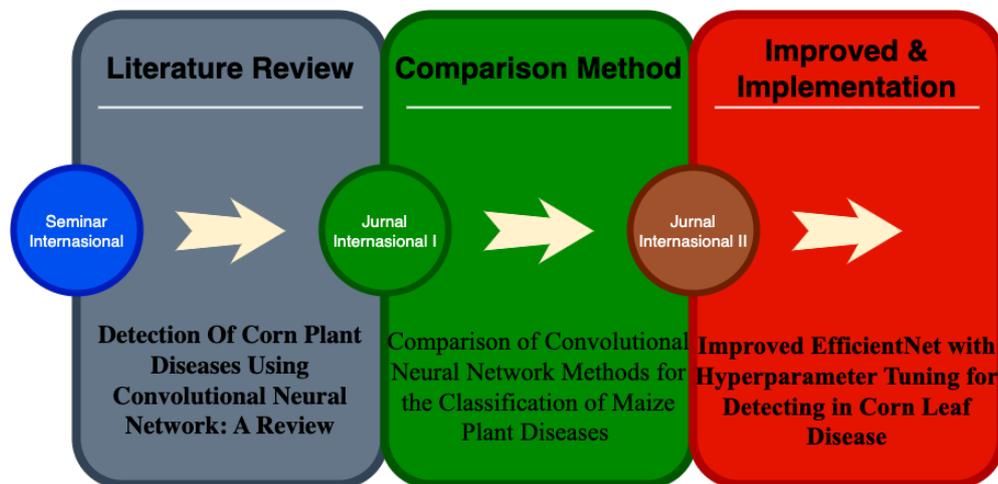


Gambar 18. Fishbone diagram

Tahapan penelitian diawali dengan melakukan studi literatur untuk mencari berbagai sumber pustaka yang relevan dan terkini mengenai berbagai topik terkait dengan penelitian seperti klasifikasi penyakit tanaman jagung, CNN, optimasi dan hyperparameter tuning untuk mendeteksi suatu penyakit baik tanaman maupun lainnya. Tahapan ini masuk pada penelitian I untuk Systematic Literature Review. Setelah itu penelitian II dilakukan dengan membandingkan beberapa metode CNN baik ResNet, VGGNet, Xception dan ENet untuk menemukan performa terbaik dari algoritma CNN. Selanjutnya pada Penelitian III yakni dari hasil perbandingan tersebut terpilih algoritma terbaik yakni ENet untuk klasifikasi yang mencapai akurasi terbaiknya.

Akurasi terbaik tersebut nantinya menjadi pengembangan ENet untuk mencari tuning parameter agar dapat meningkatkan lagi performa dari ENet. Penelitian ini fokus untuk mengembangkan sistem deteksi penyakit tanaman jagung melalui daun jagung agar dapat diterapkan pada saat real time di lapangan. Hasil yang diperoleh akan memungkinkan model untuk mampu melakukan deteksi penyakit tanaman jagung melalui daun jagung. Dataset pada penelitian ini menggunakan dataset publik dari Kaggle dan dikomparasi dengan dataset lokal penyakit tanaman jagung yang ada untuk data ujicoba lapangan. Luaran dari penelitian ini adalah 1 artikel pada prosiding internasional scopus yang membahas literature review pada penelitian I, kemudian dua artikel pada jurnal internasional

terindeks scopus yang isinya membahas topik penelitian II tentang perbandingan metode dan penelitian III menemukan model sistem deteksi penyakit tanaman jagung dari hasil eksperimen yang dikembangkan dalam sebuah sistem. Mileston dari luaran penelitian ini ditampilkan pada gambar 5 berikut:



Gambar 19. Milestone dan luaran penelitian

2.1.5 Jenis Penelitian

Jenis penelitian yang digunakan yakni kuantitatif, penelitian kuantitatif pada dasarnya merupakan suatu pengamatan yang melibatkan beberapa aspek berupa perhitungan, angka atau dinamakan kuantitas. Penelitian kuantitatif ini didasarkan pada perhitungan persentase, rata-rata dan juga perhitungan statistik lainnya. Metode penelitian kuantitatif dapat diartikan sebagai metode penelitian yang berlandaskan pada filsafat positivisme, digunakan untuk meneliti pada populasi atau sampel tertentu, teknik pengambilan sampel pada umumnya dilakukan secara random, pengumpulan data instrumen penelitian, analisis data bersifat kuantitatif/ statistik dalam rangka menguji hipotesis dari sebuah penelitian. Penelitian kuantitatif yang digunakan yakni eksperimen, riset eksperimental merupakan *Research that allows for the causes of behavior to be determined*. Untuk menggambarkan riset eksperimental bisa dilakukan pada dua kelompok dimana kelompok satu disebut kontrol tanpa diberi perlakuan apapun sedangkan pada kelompok ke dua diberikan perlakuan (*treatment*). Contoh lainnya perlakuan yang diberikan pada dua petak tanaman jagung yang diberikan

pupuk. Pada tanaman jagung tersebut ada hal yang diasumsikan sama tetapi ternyata hasilnya tidak sama. Hal ini bisa diakibatkan oleh beberapa faktor yang berpengaruh, salah satunya adalah tingkat kesuburan tanah yang berbeda sehingga memberikan hasil yang berbeda pula. Untuk membangun penelitian yang bersifat eksperimental usahakan agar ada pembandingan antara yang satu dengan yang lainnya.

2.1.6 Sumber Data

Sumber data pada penelitian ini yakni terdiri dari data primer dan data sekunder. Data primer adalah data yang diambil langsung dari obyek penelitian atau merupakan data yang berasal dari sumber asli atau pertama. Data ini tidak tersedia dalam bentuk file atau gambar langsung di lapangan. Peneliti berhasil mengumpulkan data penyakit tanaman jagung langsung yang divalidasi langsung oleh Balai Standarisasi Instrumen Pertanian (BSIP) di Gorontalo. Data sekunder adalah data yang tidak didapatkan secara langsung dari objek penelitian, melainkan data yang berasal dari sumber yang telah dikumpulkan oleh pihak lain. Data sekunder bisa diperoleh dengan cepat dan mudah karena data ini biasanya sudah tersedia dan kita tinggal mengambil dan mengumpulkan saja. Data sekunder dapat kita kumpulkan dari kaggle sebagai pengujian model dari penelitian yang dilakukan. Dataset publik yang digunakan PlantVillage and PlantDoc datasets.

2.1.7 Instrumen Penelitian

Pada pada proses penelitian nanti dibutuhkan instrumentasi penelitian dalam hal ini kebutuhan akan perangkat keras dan perangkat lunak sebagai berikut:

1. Perangkat keras
 - a. PC dengan spesifikasi AMD Radeon RX 6700 XT GPU (12GB GDDR6)
 - b. 3.8 GHz Intel Core i7 8-Core (10th Gen)
 - c. 16GB of 3000 MHz DDR4 RAM
 - d. 1TB 2.5" SSD + 1TB 7200 rpm 3.5" HDD
 - e. Kamera ponsel

2. Perangkat lunak
 - a. Windows 10
 - b. Python

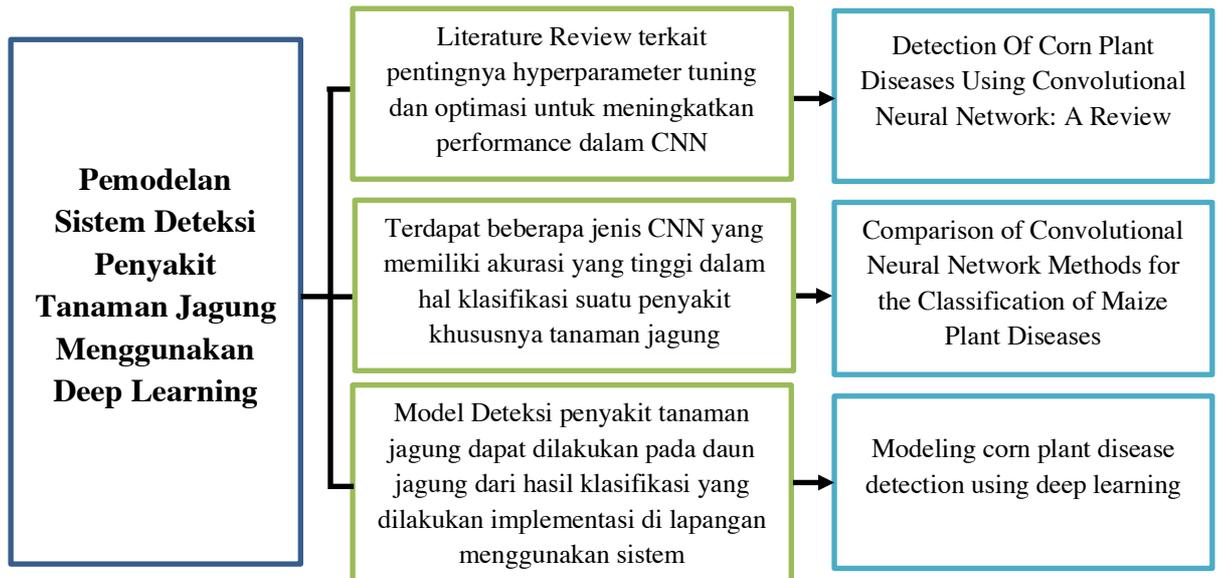
2.2 Hipotesis Penelitian

Studi ini bertujuan untuk mengeksplorasi potensi peningkatan algoritma EfficientNet dengan menggunakan teknik hyperparameter tuning dalam mendeteksi penyakit daun jagung. Hipotesis yang mendasari penelitian ini adalah bahwa dengan mengoptimalkan parameter-parameter yang ada dalam algoritma EfficientNet melalui teknik tuning hyperparameter, akan terjadi peningkatan signifikan dalam kinerja model Convolutional Neural Network (CNN) dalam mengklasifikasikan gejala penyakit pada tanaman jagung. Diharapkan bahwa penyesuaian hyperparameter tertentu, seperti learning rate, jumlah iterasi (epochs), dan ukuran batch (batch size), akan memberikan kontribusi positif terhadap penemuan model sistem deteksi penyakit tanaman jagung yang memiliki performance yang baik dan kehandalan model dalam mendeteksi penyakit.

Studi ini akan melibatkan tahap-tahap eksperimental yang terstruktur, di mana berbagai konfigurasi hyperparameter akan diuji dan dievaluasi menggunakan dataset yang relevan yang mencakup berbagai jenis penyakit daun jagung. Data ini kemudian akan digunakan untuk melatih model CNN, baik yang belum dioptimalkan maupun yang telah dioptimalkan dengan teknik tuning hyperparameter. Evaluasi akan dilakukan dengan membandingkan kinerja kedua jenis model dalam mengidentifikasi dan mengklasifikasikan gejala penyakit, dengan menggunakan metrik-metrik seperti akurasi, presisi, recall, dan F1-score.

Diharapkan bahwa temuan dari penelitian ini akan memberikan wawasan yang lebih mendalam tentang efek dari setiap parameter terhadap kinerja model EfficientNet dalam menemukan model sistem deteksi penyakit pada tanaman jagung. Selain itu, penelitian ini juga diharapkan dapat memberikan panduan yang lebih terperinci bagi peneliti dan praktisi dalam mendapatkan tuning hyperparameter secara optimal dalam pengembangan model CNN untuk mendukung upaya pencegahan dan penanganan penyakit tanaman pada umumnya dan jagung pada khususnya. Dengan demikian, studi ini diharapkan dapat

memberikan kontribusi yang signifikan dalam memperkuat pemahaman dan penerapan teknologi kecerdasan buatan dalam konteks pertanian modern. Gambar 6 menunjukkan konstruksi penelitian dengan hipotesis dan publikasi yang mengkaji mengenai pembuktian hipotesis terkait.



Gambar 20. Konstruksi penelitian dan hipotesis