

**USULAN PENELITIAN DISERTASI**

**Optimasi *Hyperparameter Tuning Convolutional Neural Network* Untuk Klasifikasi Penyakit Tanaman Jagung**

*(Optimization of Hyperparameter Tuning Convolutional Neural Network for Corn Disease Classification)*

Disusun dan diajukan oleh

**Mohamad Ilyas Abas**

**D053201015**



**DEPARTEMEN TEKNIK ELEKTRO**

**UNIVERSITAS HASANUDIN**

**MAKASSAR**

**2022**

## DAFTAR ISI

BAB I PENDAHULUAN .....	1
A.    LATAR BELAKANG .....	1
B.    RUMUSAN MASALAH .....	9
C.    TUJUAN PENELITIAN .....	9
D.    MANFAAT PENELITIAN .....	10
E.    BATASAN MASALAH .....	10
BAB II TINJAUAN PUSTAKA.....	11
A.    LANDASAN TEORI.....	11
1.    Penyakit Tanaman.....	11
2.    Penyakit Tanaman Jagung.....	11
3.    Penyakit-penyakit pada Daun dan Pelepah.....	12
a.    Penyakit Bulai (Downy mildew).....	12
b.    Hawar Daun Helminthosporium (Northern Leaf Blight).....	13
c.    Bercak Daun Helminthosporium (Southern Leaf Blight).....	13
d.    Busuk Pelepah (Sheath Blight) .....	14
4.    Citra Digital .....	15
5. <i>Image Processing</i> .....	16
6. <i>Supervised Learning</i> .....	17
7. <i>Unsupervised Learning</i> .....	18
8. <i>Convolutional Neural Network</i> .....	18
B.    PENELITIAN TERKAIT .....	21
C.    STATE OF THE ART .....	27
D.    KERANGKA KONSEP PENELITIAN .....	50
BAB III METODE PENELITIAN.....	51
A.    TAHAPAN PENELITIAN.....	51
1.    Studi literatur .....	51
2.    Pengumpulan dan analisis data.....	52
3.    Perancangan sistem .....	52
4.    Implementasi sistem.....	52

5.	Ujicoba dataset.....	52
6.	Pengujian dan validasi.....	52
7.	Pembuatan laporan .....	53
8.	Kesimpulan dan saran .....	53
B.	WAKTU DAN LOKASI PENELITIAN.....	53
1.	Waktu penelitian .....	53
2.	Lokasi penelitian .....	53
C.	JENIS PENELITIAN .....	53
D.	PERANCANGAN SISTEM.....	56
E.	SUMBER DATA .....	58
F.	INSTRUMENTASI PENELITIAN.....	59
G.	JADWAL PENELITIAN .....	59
	DAFTAR PUSTAKA .....	61

## **BAB I PENDAHULUAN**

### **A. LATAR BELAKANG**

Gorontalo terbentuk kurang lebih 400 tahun lalu dan merupakan salah satu kota tua di Sulawesi selain Kota Makassar, Pare-pare dan Manado. Gorontalo pada saat itu menjadi salah satu pusat penyebaran agama Islam di Indonesia Timur yaitu dari Ternate, Gorontalo, Bone. Seiring dengan penyebaran agama tersebut Gorontalo menjadi pusat pendidikan dan perdagangan masyarakat di wilayah sekitar seperti Bolaang Mongondow (Sulut), Buol Toli-Toli, Luwuk Banggai, Donggala (Sulteng) bahkan sampai ke Sulawesi Tenggara. Gorontalo menjadi pusat pendidikan dan perdagangan karena letaknya yang strategis menghadap Teluk Tomini (bagian selatan) dan Laut Sulawesi (bagian utara) [1].

Provinsi Gorontalo terkenal dengan komoditas tanaman pangan yang merupakan komoditas dominan dan dikembangkan secara intensif terutama jagung. Luas Lahan kering di Gorontalo mencapai 390.929 hektar. Dari luasan tersebut, sekitar 220.406 hektar merupakan lahan yang potensial untuk pengembangan komoditas jagung. Berdasarkan potensi lahan yang ada, baru sekitar 99.176 hektar sudah dimanfaatkan dan sisanya sekitar 121.230 hektar belum dimanfaatkan [1].

Lahan yang tersedia untuk pengembangan investasi yaitu lahan yang termasuk dalam Areal Penggunaan Lain (APL). Luas lahan APL sebesar 429.568 ha. Kementerian Kehutanan RI menetapkan luas lahan APL Provinsi Gorontalo sebesar 373.900 ribu ha. Namun, lahan-lahan yang tersedia yaitu berupa hutan primer, hutan sekunder dan semak belukar seluas 115.866 ha. Lahan-lahan yang tersedia ini sebagian besar telah dicadangkan untuk pengembangan kelapa sawit. Oleh karena itu, lahan yang riil tersedia untuk investasi saat ini di masing-masing kabupaten diperkirakan tidak lebih dari 1.000 hektar. Areal Penggunaan

Lain (APL) yang dimanfaatkan untuk pengembangan tanaman kakao di kabupaten Boalemo [1].

Jagung diusahakan oleh 90% petani kecil dengan pemilikan lahan kurang dari 1 ha. Areal jagung tersebar di 6 kabupaten/kota dengan luas 140.423 ha pada tahun 2013. Produksi jagung tahun 2014 (ASEM) sebesar 719.780 ton pipilan kering, meningkat sebesar 50.686 ton (7,04 persen) dibandingkan produksi tahun 2013. Kenaikan produksi tersebut disebabkan peningkatan luas panen sebesar 8.393 hektar (5,64 persen) dan peningkatan produktivitas sebesar 0,72 kwintal/hektar (1,48 persen).

Jagung diperdagangkan dalam negeri dalam bentuk antar pulau, juga diekspor. Volume antar pulau lebih banyak dari volume ekspor. Hal ini karena harga jagung dalam negeri lebih tinggi dari harga jagung di pasar dunia. Harga jagung rata-rata dalam negeri di tingkat produsen tahun 2012 sebesar Rp. 3106/kg, di tingkat konsumen Rp. 5501/kg dan harga jagung di pasar dunia Rp. 2766/kg. Harga jagung di Provinsi Gorontalo berkisar antara Rp. 2800 – Rp. 3000 per kg pipilan kering (harga 2 Juni 2014) untuk kadar air 17% [2].

Jagung diekspor dalam bentuk pipilan kering sebanyak 30.300 ton dan diperdagangkan antar pulau sebanyak 110.308 ton. Total jagung yang dijual keluar daerah sebanyak 140.708 ton pada tahun 2012. Perusahaan-perusahaan yang menampung dan membeli jagung dari petani yaitu: UD Kemiri Putih, PT Harim (Korea), Mitra Agro Marketing, Manna Utara Sejahtera, Isimu Sejati Makmur Utama, CV Utami dan Mitra Mandiri Agri Makmur. Usaha tani jagung menghasilkan pendapatan bagi petani dalam waktu yang relatif singkat, 3 bulan, dengan 2-3 kali tanam setiap tahun. Pendapatan petani rata-rata di Gorontalo sebesar Rp. 7.5 juta pada tingkat harga rata-rata Rp. 2800/kg dan produktivitas rata-rata 5.4 ton/ha setiap musim tanam [2].

Seiring berjalannya waktu memang jagung merupakan komoditas unggulan Provinsi Gorontalo 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 di Gorontalo. Oleh sebab itu, perlu adanya edukasi terhadap petani, pelatihan kepada petani dan juga tata cara penanaman dan lain sebagainya.

Kondisi iklim di Gorontalo 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. Secara karakteristik beberapa penyakit tanaman jagung di Gorontalo yakni penyakit bercak daun, penyakit hawar daun, penyakit hawar pelepah dan gejala serangan penggerek batang [3], [4].

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* Schw. Serangan hama dan penyakit yang terjadi pada tanaman jagung harusnya dapat diantisipasi sebelum meluas dan tentunya akan menyebar ke segala area tanaman jagung [4]. 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 [5] dan juga deteksi penyakit tanaman jagung menggunakan *CNN* [6]. Untuk penggunaan algoritma *CNN* sendiri karena memiliki akurasi yang tinggi juga banyak digunakan peneliti sebelumnya menggunakan *ECNN* [7]. 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 [8].

Penelitian-penelitian yang telah dilakukan sebelumnya memiliki berbagai macam kelebihan dari segi algoritma, dataset dan penggunaan berbagai macam dataset. Seperti pada penelitian [7] 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 [9] 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 [10] 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 [11] *preprocessing* data diawali dengan mengubah ukuran gambar menjadi 256x256 piksel untuk jaringan dangkal, 224x224 untuk *VGG16*, *VGG19* dan *ResNet50* serta 299x299 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 [12] 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 [13] 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 [14] 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* [15], [16] 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* [17], [18]. 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* [19]. *Hyperparameter tuning* bertujuan untuk menentukan arsitektur lapisan dalam langkah ekstraksi fitur jaringan saraf pada *CNN* [20]. Oleh sebab itu kinerja *CNN* akan lebih ditingkatkan menggunakan modifikasi parameter dengan teknik *hyperparameter tuning*.

Penyakit jagung sendiri pada dasarnya terdiri dari Hawar Daun, Bulai (*Downy Mildew*), Hama Belalang dan Bercak Daun (*Southern Leaf Blight*) [21], [22]. Beberapa penelitian juga telah dilakukan untuk biji jagung [23]. 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*) [24].

Salah satu keunggulan *CNN* yakni ekstraksi fitur secara otomatis [25], [26] bahkan dapat mengenali sembilan jenis penyakit dan hama yang berbeda [27]. Efektivitas algoritma *CNN* memang sudah terbukti bahkan untuk selain penyakit jagung [28]. Memilih arsitektur dan set *hyperparameter* terbaik di antara kombinasi mungkin dapat menjadi tantangan yang signifikan. Untuk penelitian tentang *hyperparameter tuning CNN* telah diteliti sebelumnya [17], [18], [29] 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% [19].

*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)* [19], [30]. 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 [20].

Deteksi penyakit jagung ini nantinya akan dilakukan analisis dan dibuatkan sistem [15], [31], 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 [12]. Oleh sebab itu, peneliti menawarkan pembuatan sistem 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 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 *Genetic Algorithm (GA)* [32], [33] dan *Particle Swarm Optimization (PSO)* [34]–[38]. Hasilnya menunjukkan bahwa optimasi yang dilakukan dapat meningkatkan akurasi dari *CNN*. Pada akhir penelitian nanti *Hyperparameter Tuning* dan juga *Hybrid CNNPSO* dan juga *CNNGA* akan menjadi perbandingan penelitian yang dilakukan sehingga penelitian lebih kompleks serta menghasilkan *novelty* dari penelitian.

## **B. RUMUSAN MASALAH**

1. Bagaimana cara mengoptimasi *hyperparameter* pada algoritma *CNN* untuk klasifikasi penyakit tanaman jagung?
2. Bagaimana menemukan model terbaik *Hyperparameter CNN* dan juga algoritma optimasi?
3. Bagaimana membangun model terbaik yang didapatkan dari hasil eksperimen ke dalam sebuah sistem?

## **C. TUJUAN PENELITIAN**

1. Mengklasifikasikan penyakit tanaman jagung menggunakan optimasi *hyperparameter CNN* untuk mencari akurasi terbaik.
2. Menemukan model klasifikasi terbaik dengan data penyakit tanaman jagung yang dikumpulkan menggunakan komparasi *hyperparameter CNN* dan juga algoritma optimasi *Genetic Algorithm (GA)* dan juga *Particle Swarm Optimization (PSO)*.
3. Memodelkan sistem dari hasil eksperimen yang didapatkan untuk mengklasifikasi penyakit tanaman jagung.

#### **D. MANFAAT PENELITIAN**

1. Menemukan formulasi *hyperparameter tuning* algoritma *CNN* yang di implementasikan ke dalam sebuah sistem.
2. Memudahkan pihak Balai Pengkajian Teknologi Pertanian (BPTP) 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.

#### **E. BATASAN MASALAH**

Adapun peneliti memiliki batasan masalah sebagai berikut:

1. Dataset yang dilatih diambil dari beberapa referensi yang didapatkan guna untuk mendapatkan citra penyakit jagung yang lebih banyak.
2. Dataset jagung yang digunakan untuk proses training dan testing diambil dari kumpulan dataset *public* yang digabung dengan data *private* di lapangan untuk jagung di Gorontalo.
3. Penelitian terbatas pada penyakit tanaman jagung.
4. Penelitian hanya mencari formulasi model yang tepat dari *hyperparameter* algoritma *CNN*, Komparasi algoritma *optimizer* dan penerapannya secara implementasi sistem.

## **BAB II TINJAUAN PUSTAKA**

### **A. LANDASAN TEORI**

#### **1. Penyakit Tanaman**

Ilmu Penyakit Tumbuhan adalah ilmu yang mempelajari kerusakan yang disebabkan oleh organisme yang tergolong ke dalam dunia tumbuhan seperti Tumbuhan Tinggi Parastis, Ganggang, Jamur, bakteri, Mikoplasma dan Virus. Kerusakan ini dapat terjadi baik di lapangan maupun setelah panen. Penyakit tumbuhan dapat ditinjau dari dua sudut yaitu sudut biologi dan sudut ekonomi, demikian juga penyakit tanamannya. Di samping itu, untuk mempelajari Ilmu Penyakit Tumbuhan perlu diketahui beberapa istilah dan definisi yang penting. Kerusakan yang ditimbulkan oleh penyakit tumbuhan dapat menimbulkan kerugian yang sangat besar terhadap masyarakat. Kerusakan ini selain dapat menyebabkan hilangnya hasil panen ternyata juga dapat menimbulkan gangguan terhadap konsumen dengan adanya racun yang dihasilkan oleh jamur dalam hasil pertanian tersebut [39].

#### **2. Penyakit Tanaman Jagung**

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 [40].

### **3. 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 kumparan 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 mitokondria 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.

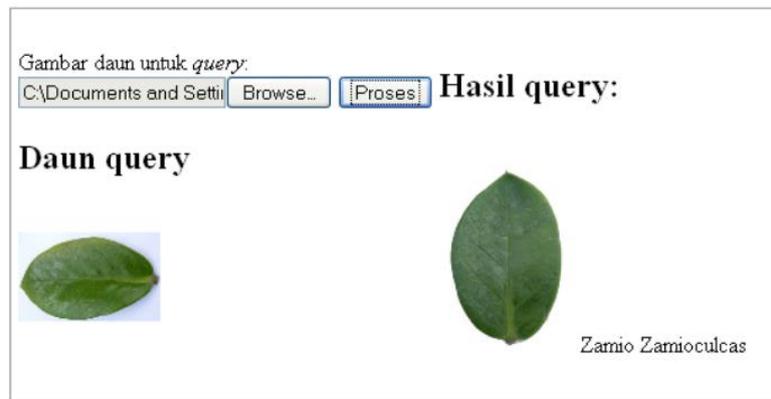
#### **4. Citra Digital**

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 [41].

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)

## 5. *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 [42]

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.

## 6. *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* [43].

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 [44].

## **7. *Unsupervised Learning***

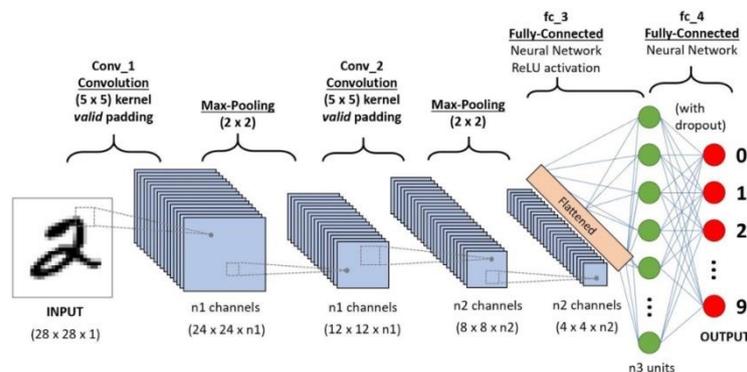
Algoritma *unsupervised learning* adalah algoritma yang tidak membutuhkan data berlabel. Pada *unsupervised learning*, algoritma tidak membutuhkan data training. Algoritma ini digunakan dalam mendeteksi pola dan pemodelan deskriptif yang tidak membutuhkan kategori atau *output* berlabel yang menjadi 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*.

## **8. *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 [45].

*CNN* pertama kali dikembangkan dengan nama *NeoCognitron* oleh Kunihiro Fukushima, seorang peneliti dari *NHKBroadcasting Science Research Laboratories*, Kinuta, Setagaya, Tokyo, Jepang [4]. Konsep tersebut kemudian dimatangkan oleh Yann LeCun, seorang peneliti dari *AT&T Bell Laboratories di Holmdel, New Jersey, USA*. Model *CNN* dengan nama *LeNet* berhasil diterapkan oleh LeCun pada penelitiannya 9 mengenai pengenalan angka dan tulisan tangan. Pada tahun 2012, Alex Krizhevsky dengan penerapan *CNN* miliknya berhasil menjuarai kompetisi *ImageNet Large 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 [46].

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 [45].



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

1900. 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.

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*.

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.

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.

## **B. PENELITIAN TERKAIT**

Penelitian sebelumnya [47] 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 [48] 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 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 [5] 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 [49] 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 [7] 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* [50] 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* [51] 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 [20] 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* [52] 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, pengubahan 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 *pra-trained* untuk efisiensi klasifikasi citra medis menggunakan *CNN* [29]. 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 [18]. 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

Selanjutnya terkait penggunaan algoritma optimasi juga pernah dilakukan [34] dengan melakukan optimasi menggunakan salah satu algoritma *Particle Swarm Optimization (PSO)* dikombinasikan dengan *CNN* diberi nama *cPSO-CNN* yang sempurna menyempurnakan *hyperparameter* dari jaringan *CNN*. Hasil eksperimen menunjukkan bahwa *cPSO-CNN* bekerja secara kompetitif jika dibandingkan dengan beberapa algoritma yang dilaporkan dalam hal keunggulan *hyper-parameter CNN* dan biaya komputasi secara keseluruhan.

Penelitian lainnya juga tentang [53] melakukan *hybrid GA-PSO-CNN* untuk perkiraan tenaga angin jangka pendek. *Hybrid GA dan PSO* dapat membuat model peta fitur antara faktor yang mempengaruhi tenaga angin seperti kecepatan, arah angin dan suhu. Selain itu, algoritma *GA-PSO mix-encoding* diperkenalkan untuk mengoptimalkan *hyperparameter* dan bobot jaringan secara kolaboratif, yang memecahkan masalah penentuan subjektif jaringan optimal di *CNN* dan secara efektif mencegah optimasi lokal dalam proses pelatihan. Hasilnya menunjukkan bahwa *MAE*, *MSE*, dan *MAPE* dari model *GA-PSO-CNN* yang diusulkan masing-masing turun 1,13–9,55%, 0,46–7,98%, dan 3,28–19,29%, di musim yang berbeda,

dibandingkan dengan *Single-CNN*, Model *PSO-CNN*, *ISSO-CNN*, dan *CHACNN*. Ukuran dan jumlah kernel konvolusi di setiap lapisan konvolusi berkurang 5–18,4% dalam model *GA-PSO-CNN*.

Penelitian lainnya tentang *optimasi hyperparameter CNN* menggunakan *Genetic Algorithm (GA)* [54]. Untuk mendapatkan *hyperparameter* dengan kinerja yang lebih baik, para ahli diharuskan untuk mengonfigurasi sekumpulan pilihan *hyperparameter* secara manual. Hasil terbaik dari konfigurasi manual ini selanjutnya dimodelkan dan diimplementasikan di *CNN*. Namun, kumpulan data yang berbeda memerlukan model atau kombinasi *hyperparameter* yang berbeda, yang dapat menjadi rumit dan membosankan. pencarian *hyperparameter* pada dataset *CIFAR-10*. Selama penyelidikan dengan berbagai metode optimasi, kinerja dalam hal akurasi diuji dan dicatat. Meskipun tidak ada perbedaan yang signifikan antara pendekatan yang diusulkan dan *state-of-the-art* pada dataset *CIFAR-10*, namun potensi sebenarnya terletak pada hibridisasi algoritma genetika dengan metode pencarian lokal dalam mengoptimalkan struktur jaringan dan pelatihan jaringan

### C. STATE OF THE ART

Tabel 1. *State of the art* penelitian terkait

No.	Judul	Tahun	Penulis	Metode	Hasil
1	Using Deep Learning for Image-Based Plant Disease Detection	2016. Frontiers in Plant Science	Sharada P. Mohanty, David P. Hughes, and Marcel Salathé	CNN. AlexNet, GoogLeNet.	Melatih jaringan saraf konvolusi yang dalam untuk mengidentifikasi 14 spesies tanaman dan 26 penyakit (atau tidak ada). Model yang terlatih mencapai akurasi 99,35% pada set uji yang ditahan, menunjukkan kelayakan pendekatan ini. Secara keseluruhan, pendekatan pelatihan model pembelajaran mendalam pada kumpulan data gambar yang semakin besar dan tersedia untuk umum menghadirkan jalur yang jelas menuju diagnosis penyakit tanaman yang dibantu smartphone dalam skala global yang masif. Untuk mengatasi masalah over-fitting, kami memvariasikan set pengujian untuk melatih rasio himpunan dan mengamati bahwa bahkan dalam kasus ekstrim pelatihan hanya pada 20% data dan menguji model terlatih pada 80% data

					lainnya, model mencapai akurasi keseluruhan 98,21% (skor F1 rata-rata 0,9820 ) dalam kasus GoogLeNet::TransferLearning::Color::20-80. Seperti yang diharapkan, kinerja AlexNet dan GoogLeNet secara keseluruhan menurun jika kita terus meningkatkan rasio test set to train set.
2	Penerapan Convolutional Neural Network Deep Learning dalam Pendeteksian Citra Biji Jagung Kering	<b>2016</b> Optical Measurement Technology and Instrumentation	Xinhua Xie, Xiangqian Zhang, Bing He, Dong Liang, Dongyan Zhang, Linsheng Huang	18 fitur bobot yang lebih besar dipilih oleh algoritma Relief-F dan sebagai input dari mesin vektor relevansi (RVM), dan identifikasi otomatis karat garis gandum dan embun tepung direalisasikan.	Hasil eksperimen menunjukkan bahwa rata-rata tingkat pengenalan dan kecepatan prediksi model RVM adalah 5,56% dan 7,41 kali lebih tinggi dari Support Vector Machine (SVM). Dan aplikasi menemukan bahwa perlu sekitar 1 menit untuk mendapatkan hasil identifikasi. Oleh karena itu, dapat disimpulkan bahwa sistem dapat digunakan untuk mengenali penyakit gandum dan menyelidiki secara real-time di lapangan.
3	Deep Neural Networks Based Recognition of Plant Diseases by Leaf Image Classification	<b>2016.</b> Hindawi Publishing Corporation Computational Intelligence and Neuroscience	Srdjan Sladojevic, Marko Arsenovic, Andras Anderla, IDubravko Culibrk, and Darko Stefanovic	Generasi terbaru dari convolutional neural networks (CNNs)	Semua langkah penting yang diperlukan untuk menerapkan model pengenalan penyakit ini dijelaskan secara lengkap di seluruh makalah ini, mulai dari mengumpulkan gambar untuk membuat database, yang dinilai oleh para ahli pertanian. Caffe, kerangka pembelajaran mendalam yang dikembangkan oleh Berkley Vision and Learning Centre, digunakan untuk melakukan pelatihan CNN yang mendalam. Hasil eksperimen pada model yang dikembangkan mencapai presisi antara 91% dan 98%, untuk tes kelas terpisah, rata-rata 96,3%
4	A Robust Deep-Learning-Based Detector for Real-Time Tomato Plant Diseases and Pests Recognition	<b>2017.</b> Sensor (MDPI)	Alvaro Fuentes, Sook Yoon, Sang Cheol Kim and Dong Sun Park	Deep Learning CNN Kelompok VGG-16, ResNet-50, ResNet-101, ResNet-152, ResNetXt-50	Hasil eksperimen menunjukkan bahwa sistem yang kami usulkan dapat secara efektif mengenali sembilan jenis penyakit dan hama yang berbeda, dengan kemampuan untuk menangani skenario kompleks dari area sekitar pabrik.
5	Deep Learning for Tomato Diseases: Classification and Symptoms Visualization	<b>2017.</b> Applied Artificial Intelligence	Mohammed Brahimi, Kamel Boukhalfa, and Abdelouahab Moussaouic	Convolutional Neural Network(CNN )	Salah satu keuntungan terbesar CNN adalah ekstraksi fitur secara otomatis dengan memproses langsung gambar mentah. Hasil yang diperoleh sangat menggembirakan, mencapai akurasi 99,18%, yang kami lakukan pada model dangkal secara dramatis, dan dapat digunakan sebagai alat praktis bagi petani untuk melindungi tomat dari penyakit.
6	A Novel Method Of	<b>2018</b>	Zhongqi Lin, Shaomin Mu, Aiju	Mengidentifikasi penyakit	Untuk menguji MCNN yang diusulkan, 10.820 gambar RGB yang berisi lima jenis

	Maize Leaf Disease Image Identification Based On A Multichannel Convolutional Neural		Shi, Chao Pang, Xiaoxiao Sun	<p>daun jagung dari citra digital, makalah ini mengusulkan Multichannel Convolutional Neural Network (MCNN) baru. MCNN terdiri dari input layer, lima convolutional layer, tiga subsampling layer, tiga fully connected layer dan output layer. 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.</p>	<p>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, mereka dihilangkan dan disegmentasi dengan penyaringan homomorfik dan segmentasi wilayah yang diminati (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.</p>
7	Identification of Apple Leaf Diseases Based on Deep Convolutional Neural Networks	<b>2018.</b> symmetry S Article (MDPI)	Bin Liu, Yun Zhang, DongJian He and Yuxiang Li	<p>Deep Learning CNN Makalah ini mengusulkan pendekatan identifikasi yang akurat</p>	<p>Hasil eksperimen menunjukkan bahwa pendekatan identifikasi penyakit yang diusulkan berdasarkan jaringan saraf convolutional mencapai akurasi keseluruhan 97,62%, parameter model berkurang 51.206.928 dibandingkan dengan yang ada di model AlexNet</p>

				untuk penyakit daun apel berdasarkan jaringan saraf convolutional	standar, dan akurasi model yang diusulkan dengan gambar patologis yang dihasilkan memperoleh peningkatan sebesar 10,83%. Penelitian ini menunjukkan bahwa model pembelajaran mendalam yang diusulkan memberikan solusi yang lebih baik dalam pengendalian penyakit untuk penyakit daun apel dengan akurasi tinggi dan tingkat konvergensi yang lebih cepat, dan bahwa teknik pembuatan gambar yang diusulkan dalam makalah ini dapat meningkatkan kekokohan model jaringan saraf convolutional.
8	Maize Plant Disease Identification (Zea Mays L. Saccharata) Using Image Processing and K-Nearest Neighbor (K-NN)	<b>2018.</b> International Journal of Engineering & Technology	Prihastuti Harsani, Arie Qurania and Karina Damayanti	Penelitian ini melakukan implementasi metode pengolahan citra digital untuk mengidentifikasi penyakit pada tanaman jagung yang disebabkan oleh hama. Penyakit tersebut adalah Daun Hawar, Bulai (Downy Midew), Belalang Hama, Daun Bercak (Southern Leaf Blight). Melalui deteksi warna dan tepi, akurasi yang diperoleh adalah 91,7%.	Hasil uji validasi menggunakan ekstraksi karakteristik gabungan antara warna dan tepi untuk hama daun jagung menghasilkan nilai akurasi 91,7%.
9	Segmentation of Corn Leaf Disease Based on Fully Convolution Neural Network	<b>2018.</b> Academic Journal of Computing & Information Science	Zhen Wanga, Shanwen Zhang School	Pertama, pra-pemrosesan dan peningkatan data dilakukan pada gambar yang diperoleh untuk membuat set pelatihan dan set pengujian untuk pembelajaran mendalam. Kedua, gambar terpusat	Hasilnya menunjukkan bahwa metode ini memiliki efek segmentasi yang lebih baik dan akurasi segmentasi lebih dari 96%.

				<p>pelatihan dimasukkan ke dalam FCN, dan peta fitur diperoleh melalui beberapa lapisan konvolusi, penyatuan, dan aktivasi; Peta fitur di-upsampling untuk mendapatkan peta fitur dengan ukuran yang sama dengan gambar input. Akhirnya, resolusi gambar tersegmentasi dipulihkan dengan proses dekonvolusi, dan hasil segmentasi adalah keluaran. Metode ini digunakan untuk segmen gambar penyakit daun jagung umum.</p>	
10	<p>Crop conditional Convolutional Neural Networks for massive multi-crop plant disease classification over cell phone acquired images taken on real field conditions</p>	<p><b>2019.</b> Computers and Electronics in Agriculture. Science Direct. Elsevier</p>	<p>Artzai Picon, Maximilian Seitz, Aitor Alvarez-Gil, Patrick Mohnke, Amaia Ortiz-Barred, Jone Echazarra</p>	<p>Dalam karya ini, kami mengusulkan tiga arsitektur CNN berbeda yang menggabungkan meta-data non-gambar kontekstual seperti memotong informasi ke Jaringan Neural Convolutional berbasis gambar. Ini menggabungkan keuntungan dari secara</p>	<p>Jaringan klasifikasi penyakit tanaman bersyarat yang menggabungkan kontekstual formasi dengan penggabungan pada tingkat vektor embedding memperoleh akurasi seimbang 0,98 meningkatkan semua metode sebelumnya dan menghilangkan 71% kesalahan klasifikasi dari metode sebelumnya.</p>

				bersamaan belajar dari seluruh dataset multi-tanaman sekaligus mengurangi kompleksitas kelas penyakit.	
11	Maize Leaf Disease Image Classification Using Bag of Features	2019	Mohammad Syarief, Novi Prastiti, Wahyudi Setiawan	<p>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.</p>	<p>Dua skenario 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.</p> <p>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.</p> <p>Hasil pengujian dari pekerjaan ini kemudian dibandingkan dengan pekerjaan sebelumnya untuk mengukur tingkat keberhasilan pengujian sesuai dengan metode. Perbandingan akurasi hasil pengujian terdapat pada Tabel 7. Untuk tahapan pelatihan, akurasi yang dicapai relatif tinggi, mencapai 96%, sedangkan akurasi validasi lebih sedikit dibandingkan penelitian sebelumnya. Hal ini dapat ditingkatkan dengan menambah jumlah data latih sehingga proses pembelajaran bisa lebih luas.</p> <p>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.</p>
12	Automatic Detection of Corn Leaf Disease by Using Fuzzy C-	2019. American Journal of Engineering	Nurhidayati, Syaiful Anam, Agus Widodo	Fuzzy C-Means Algoritma Fuzzy C-Means telah	Dari hasil pengujian didapatkan nilai akurasi diatas 99%. Hal ini menunjukkan bahwa metode yang penulis usulkan sangat baik untuk diterapkan dalam proses segmentasi citra bercak daun jagung.

	Means Algorithm and Morphological Operation	Research (AJER)		terbukti dapat menangani pengumpulan data yang besar, tidak jelas dan tidak pasti. Makalah ini akan mengusulkan deteksi otomatis penyakit daun jagung menggunakan algoritma Fuzzy C-Means. Karena hasil segmentasi citra dengan algoritma Fuzzy C-Means belum sesuai, maka digunakan operasi morfologi untuk memperbaiki hasil tersebut.	
12	Detection of Disease on Corn Plants Using Convolutional Neural Network Methods	<b>2019.</b> Jurnal Ilmu Komputer dan Informasi (Journal of a Science and Information).	Ardi Hidayat, Ucu Darusalam, Irmawati Faculty	CNN	Dengan jumlah dataset sebanyak 3.854 gambar penyakit pada tanaman jagung, yang terdiri dari tiga jenis penyakit jagung yaitu Common Rust, Gray Leaf Spot, dan Northern Leaf Blight. Dengan hasil akurasi sebesar 99%, dalam mendeteksi penyakit pada tanaman jagung.
13	Maize leaf disease classification using deep convolutional neural networks	<b>2019.</b> Neural Computing and Applications (Springer)	Ramar Ahila Priyadharshini, Selvaraj Arivazhagan, Madakannu Arun, Annamalai Mirnalini	Dalam penelitian ini, kami mengusulkan arsitektur berbasis jaringan saraf convolutional (CNN) yang dalam (LeNet yang dimodifikasi) untuk klasifikasi penyakit daun jagung.	Dari penelitian ini, kami menyimpulkan bahwa kernel ukuran 3 x 3 lebih cocok untuk klasifikasi penyakit daun jagung. Selanjutnya, CNN yang diusulkan ini juga dapat digunakan untuk klasifikasi penyakit daun tanaman lainnya.
14	Implementation of Improved	<b>2020.</b> Internatio	Ibrahim M. Adekunle	SVM, Random Forest, Neural	Hasil eksperimen menunjukkan bahwa penerapan teknik pembelajaran mesin yang

	Machine Learning Techniques for Plant Disease Detection and Classification	Journal of Research and Innovation in Applied Science (IJRIAS)		Network	<p>dimodifikasi dapat digunakan secara efektif untuk klasifikasi penyakit daun tanaman bahkan dengan akurasi 96,7%. Pendekatan ini akan sangat berguna bagi petani untuk mencegah kerusakan tanaman, kekurangan produksi pangan di masyarakat dan pemborosan uang untuk produk pertanian seperti pestisida dan sebagainya.</p> <p>Namun, di masa depan pekerjaan penelitian ini dapat ditingkatkan dengan menggabungkan pengklasifikasi jaringan saraf dengan Deep Learning menggunakan daun tanaman lain untuk menangkap lebih banyak informasi yang dapat berguna untuk klasifikasi yang lebih baik ketepatan. Selain itu, studi yang komprehensif diperlukan untuk memahami faktor-faktor yang mempengaruhi deteksi penyakit tanaman, seperti kelas dan ukuran dataset, kecepatan belajar, penerangan dan sebagainya.</p>
15	Plant Disease Identification Based on Deep Learning Algorithm in Smart Farming	<b>2020.</b> Hindawi Discrete Dynamics in Nature and Society	Yan Guo, Jin Zhang, Chengxin Yin, Xiaonan Hu, Yu Zou, Zhipeng Xue, and Wei Wang	Regional Proposal Network (RPN) Model yang digunakan dalam makalah ini terutama terdiri dari tiga langkah berikut. Langkah pertama adalah mencari daun yang sakit. Algoritma RPN digunakan untuk melatih dataset daun di lingkungan yang kompleks, dan jaringan saraf regresi bingkai dan jaringan saraf klasifikasi digunakan untuk menemukan dan mengambil daun yang sakit di	<p>Citra yang diperoleh dengan algoritma RPN dimasukkan ke dalam Algoritma Chan–Vese dan gambar dalam set level nol dipertahankan. Gambar di luar set level nol diatur ke hitam untuk mendapatkan hasil segmentasi gambar.</p> <p>Pengaturan Parameter Pengambilan Daun. Resnet-101 dipilih sebagai model prapelatihan, dan jaringan dilatih dengan menggunakan dataset daun penyakit dengan latar belakang sederhana dalam makalah ini. Dalam makalah ini, semua parameternya dimodifikasi dan dimulai diinisialisasi pada lapisan keluaran terakhir Resnet-101, dan nomor klasifikasi diubah dari 1000 menjadi 4, yang sesuai dengan hasil identifikasi empat jenis penyakit daun.</p> <p>Citra uji dimasukkan ke dalam model VGG-16 dan algoritma RPN, algoritma RPN pada dasarnya dapat membingkai struktur blade utama, yang memiliki kinerja lebih baik daripada model aslinya.</p> <p>Berdasarkan hasil di atas, dapat diketahui bahwa setelah 500 iterasi, algoritma Chan–Vese bisa mendapatkan hasil segmentasi citra daun yang lebih baik. Meskipun algoritme Chan–Vese tidak dapat secara efektif mengekstrak kontur tepi bilah dibandingkan dengan algoritme DAS, algoritma ini mempertahankan struktur lengkap bilah pusat termasuk urat daun,</p>

				lingkungan yang kompleks. Tahap kedua adalah segmentasi daun yang sakit. Algoritma Chan-Vese digunakan untuk mensegmentasi citra daun yang sakit.	warna titik, dan bentuk titik. Struktur sentral lengkap dari bilah yang diperoleh dengan algoritma Chan-Vese dapat digunakan untuk identifikasi penyakit pada langkah berikutnya.
16	A Deep-Learning-Based Real-Time Detector for Grape Leaf Diseases Using Improved Convolutional Neural Networks	<b>2020.</b> Frontiers in Plant Science	Xiaoyue Xie, Yuan Ma, Bin Liu, Jinrong He, Shuqin Li and Hongyan Wang	Artikel ini pertama kali memperluas citra penyakit daun anggur melalui teknologi pemrosesan citra digital, dengan membangun dataset penyakit daun anggur (GLDD). Berdasarkan GLDD dan algoritma deteksi Faster R-CNN, model Faster DR-IACNN berbasis deep-learning dengan kemampuan ekstraksi fitur yang lebih tinggi disajikan untuk mendeteksi penyakit daun anggur dengan memperkenalkan modul Inception-v1, modul Inception-ResNet-v2 dan SE-blok.	Hasil eksperimen menunjukkan bahwa model deteksi Faster DR-IACNN mencapai presisi 81,1% mAP pada GLDD, dan kecepatan deteksi mencapai 15,01 FPS. Penelitian ini menunjukkan bahwa detektor real-time Faster DR-IACNN berbasis deep learning memberikan solusi yang layak untuk diagnosis penyakit daun anggur dan memberikan panduan untuk deteksi penyakit tanaman lainnya.
17	A Review On Crop Disease Identification And	<b>2020.</b> European Journal of Molecular	J Sujithra, M Ferni Ukrit	SVM, NN, K-Means	Makalah ini menyajikan survei tentang identifikasi penyakit tanaman menggunakan citra berbagai teknik pengolahan. Berbagai teknik

	Classification Through Leaf Images	& Clinical Medicine			computer vision digunakan untuk mengidentifikasi penyakit tanaman, tetapi masih ada dampak dalam mendeteksi semua penyakit menggunakan satu teknik. Dari survei, hasilnya dibandingkan dengan pendekatan berbeda yang berakhir dengan algoritma seperti Support Vector Machine dan Neural Network yang memainkan peran penting dan mencapai kinerja yang lebih menonjol dalam deteksi dan klasifikasi penyakit. Pendekatan ini memberikan solusi optimal untuk penyakit tanaman. Para peneliti telah melakukan pekerjaan ini pada beberapa tanaman saja. Banyak lagi varietas tanaman yang masih ada untuk diagnosis. Varietas tersebut harus diambil untuk pekerjaan di masa depan dan solusi yang tepat harus diidentifikasi dengan menggunakan pendekatan yang berbeda.
18	EfficientNet based recognition of maize diseases by leaf image classification	<b>2020.</b> Journal of Physics: Conference Series	Jiangchuan Liua, Mantao Wang, Lie Bao, Xiaofan Li	Untuk memverifikasi kekokohan dan keakuratan metode yang diusulkan dalam makalah ini, verifikasi uji dilakukan dalam dataset uji dengan VGG-16, Inception-v3 dan Resnet-50, masing-masing.	Hasil eksperimen menunjukkan bahwa kecepatan pelatihan model jaringan yang diusulkan dalam makalah ini telah meningkat secara signifikan, dan akurasi pengenalannya jauh lebih baik daripada jaringan lain dengan maksimum 98,52%, yang dapat mewujudkan aplikasi produksi pertanian. Untuk mewujudkan pengenalan otomatis citra penyakit jagung, makalah ini mengusulkan metode transfer learning berbasis EfficientNet. Lapisan konvolusi dan lapisan penyatuan jaringan tetap, hanya melatih lapisan koneksi penuh, dan bobot serta tingkat pembelajaran model disesuaikan dengan baik. Untuk mengevaluasi kinerja model jaringan, percobaan EfficientNet dilakukan dengan pelatihan asli, kelompok kontrol juga menambahkan Inception-V3, VGG-16, Resnet-50 sebagai kontras percobaan. Apakah metode pembelajaran transfer diadopsi atau tidak, efeknya secara umum lebih baik daripada VGG-16 melalui eksperimen, dan metode pembelajaran transfer lebih baik daripada jaringan lain. Dalam makalah ini, efek eksperimental dari metode ini adalah yang tertinggi, akurasi pengenalan delapan kategori gambar penyakit yang berbeda mencapai 98,52%, dan jumlah parameter jaringan adalah yang terkecil.
19	Detection and Classification of Leaf Diseases in Maize Plant using Machine Learning	<b>2020.</b> National College of Ireland Project Submission Sheet School of	Adarsh Jayakumar	Penelitian saat ini bertujuan untuk mengevaluasi kinerja algoritme seperti XGBoost,	Pelatihan model dilakukan pada database open source yang berisi hampir 4000 gambar, mencakup empat kelas yang berbeda, termasuk gambar tanaman yang sehat. Dari model yang dikembangkan, arsitektur VGG19 CNN dengan transfer learning berkinerja terbaik dengan mencapai akurasi keseluruhan 95 persen,

		Computing		<p>Gradient Boost, Convolutional Neural Network (CNN) dan arsitekturnya seperti VGG16 dan VGG19 yang digabungkan dengan augmentasi data dan pembelajaran transfer terhadap algoritme pembelajaran mesin tradisional seperti Support Vector Machine (SVM), Random Forest dan mengukur keefektifannya dalam mengidentifikasi dan mengklasifikasi penyakit tanaman jagung dalam hal akurasi, presisi, daya ingat dan waktu pelatihan.</p>	<p>sehingga memenuhi kebutuhan untuk membangun model klasifikasi yang efektif dan kuat. Juga, kinerja model yang dikembangkan ditemukan meningkat dengan peningkatan jumlah data pelatihan. Hasil yang diperoleh dengan menggunakan teknik transfer learning pada arsitektur CNN sangat menjanjikan dan dapat dikembangkan lebih lanjut untuk membentuk sistem identifikasi penyakit tanaman yang komprehensif yang mampu beroperasi di lingkungan dunia nyata. Dengan demikian dapat memberdayakan komunitas pertanian untuk mendiagnosis penyakit dan memulai pengobatan tepat waktu tanpa campur tangan ahli yang terlatih.</p>
20	Deep Convolutional Neural Network based Detection System for Real-time Corn Plant Disease Recognition	2020. Procedia Computer Science	Mishra, Sumita Sachan, Rishabh Rajpal, Diksha	<p>Model CNN mendalam yang telah dilatih sebelumnya diterapkan ke raspberry pi 3 menggunakan Intel Movidius Neural Compute Stick yang terdiri dari blok perangkat keras CNN khusus.</p>	<p>Selama pengenalan penyakit daun jagung, model deep learning mencapai akurasi 88,46% menunjukkan kelayakan metode ini. Model pengenalan penyakit tanaman jagung yang disajikan mampu berjalan pada perangkat pintar mandiri seperti raspberry-pi atau <i>smartphone</i> dan drone.</p> <p>Analisis kinerja Deep CNN yang dirancang telah menunjukkan akurasi rata-rata 98,40%. Selain itu, versi modifikasi dari model CNN yang dirancang dengan parameter yang dapat dilatih yang dioptimalkan dikerahkan pada NCS untuk melakukan inferensi pada gambar langsung yang diambil dari ponsel pintar dengan akurasi rata-rata 88,66%. Sedangkan hasil yang dicapai cukup</p>

					menjanjikan; akurasi pengenalan pada NCS dapat lebih ditingkatkan dengan penyetelan dan optimalisasi parameter hiper dan meningkatkan keragaman operasi penyatuan, selanjutnya augmentasi data dapat digunakan. Dalam penelitian masa depan, kami berencana untuk mendiversifikasi dataset dengan memasukkan penyakit jagung tambahan untuk meningkatkan kemandirian metode.
21	Implementation of Improved Machine Learning Techniques for Plant Disease Detection and Classification	<b>2020.</b> International Journal of Research and Innovation in Applied Science (IJRIAS)	Ibrahim M. Adekunle	SVM, Random Forest, Neural Network	<p>Hasil eksperimen menunjukkan bahwa penerapan teknik pembelajaran mesin yang dimodifikasi dapat digunakan secara efektif untuk klasifikasi penyakit daun tanaman bahkan dengan akurasi 96,7%. Pendekatan ini akan sangat berguna bagi petani untuk mencegah kerusakan tanaman, kekurangan produksi pangan di masyarakat dan pemborosan uang untuk produk pertanian seperti pestisida dan sebagainya.</p> <p>Namun, di masa depan pekerjaan penelitian ini dapat ditingkatkan dengan menggabungkan pengklasifikasi jaringan saraf dengan Deep Learning menggunakan daun tanaman lain untuk menangkap lebih banyak informasi yang dapat berguna untuk klasifikasi yang lebih baik ketepatan. Selain itu, studi yang komprehensif diperlukan untuk memahami faktor-faktor yang mempengaruhi deteksi penyakit tanaman, seperti kelas dan ukuran dataset, kecepatan belajar, penerangan dan sebagainya.</p>
22	Plant Leaf Disease Detection and Classification using Conventional Machine Learning and Deep Learning	<b>2020.</b> International Journal on Emerging Technologies	Hardikkumar S. Jayswal and Jitendra P. Chaudhari	Machine learning, Neural network, Random forest, Support vector machine.	<p>Dalam Survei ini kami membahas metodologi tradisional, pembelajaran mesin, dan teknik pembelajaran mendalam untuk deteksi dan klasifikasi penyakit tanaman. Kami membahas empat fase utama untuk mendeteksi dan mengklasifikasikan penyakit yaitu Pra-pemrosesan Gambar, Segmentasi, Seleksi fitur dan klasifikasi. Dari survei di atas dapat disimpulkan bahwa K-means untuk segmentasi, SVM dan JST adalah metode yang paling efisien untuk mendeteksi dan mengklasifikasikan tanaman yang terinfeksi. Setelah mensurvei berbagai makalah penelitian tentang pembelajaran mendalam, dapat disimpulkan bahwa CNN memberikan kinerja terbaik di bidang deteksi dan klasifikasi penyakit tanaman.</p> <p>perbandingan yang dibuat antara metode pembelajaran mesin tradisional dan metode pembelajaran mendalam, dapat dilihat dengan jelas bahwa pembelajaran mendalam jauh lebih baik daripada metode tradisional. Beberapa dataset telah</p>

					ditangkap dalam situasi standar berarti tidak adanya noise sehingga ketika noise muncul dalam gambar, ada kemungkinan kinerja suatu algoritma akan menurun. Setelah mensurvei ratusan makalah satu batasan utama ditemukan bahwa banyak peneliti datang dengan dataset mereka sendiri yang tidak tersedia untuk peneliti lain sehingga pengembangan algoritma baru dari peneliti lain tidak dapat menguji dataset yang tidak tersedia untuk umum.
23	Convolutional neural network for maize leaf disease image classification	<b>2020</b> TELKOM NIK Telecom munication, Computing, Electronics and Control (SINTA 1)	Mohammad Syarief, Wahyudi Setiawan	Ekstraksi fitur 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%.
24	Plant Disease Detection using CNN Model and Image Processing	<b>2020.</b> International Journal of Engineering Research & Technology (IJERT)	Md. Tariqul Islam	Makalah ini menggunakan pengolahan citra model CNN (Convolutional Neural Network) untuk melatih dataset.	Sistem kami berhasil memberikan tingkat akurasi 94,29%. Pembudidaya universal bisa mendapatkan bantuan dari pekerjaan penelitian kami untuk menumbuhkan tingkat produksi tanaman dan buah-buahan dan mengurangi penyakit tanaman dan serangga yang menarik.  Karya ini memberikan gagasan otentik untuk mendeteksi daun yang terserang ('Anggur', 'Kentang' dan 'Strawberry') dan petani yang bekerja untuk menghasilkan buah-buahan ini mendapatkan obat

					<p>sehingga mereka dapat meningkatkan produksi di industri pertanian. Spesialis yang bekerja di bidang pertanian menerima proses deteksi penyakit secara cepat dengan teknik image processing sehingga teknologi Image Processing mencapai milestone dalam waktu yang sangat singkat. Bagian daun yang ditransmisikan dengan mudah disegmentasi dan dianalisis menggunakan model CNN dan model ini memberikan hasil terbaik secara instan. Akibatnya petani yang mendeteksi penyakit tanaman secara manual dapat menghemat waktu mereka dan mengurangi kecurigaan terhadap kemungkinan deteksi yang salah. Tujuan masa depan kami adalah mengembangkan sistem multimedia terbuka dan membuat perangkat lunak yang secara otomatis mendeteksi penyakit tanaman dan memberikan solusinya.</p>
25	Enhanced Convolutional Neural Network (ECNN) for Maize Leaf Diseases Identification	<b>2020.</b> Smart Innovations in Communication and Computational Sciences	Rohit Agarwal Himanshu Sharma	<p>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</p>	<p>Bobot ECNN diperbarui dengan metode penurunan gradien. 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 dan desa tanaman 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.</p>

				layers, one input dan one-dimensional convolutional layer disusun oleh ECNN. Entropi silang yang diperkirakan dan probabilitas nyata dihitung pada tahap akhir.	
26	Automatic Fuzzy Logic-Based Maize Common Rust Disease Severity Predictions with Thresholding and Deep Learning	<b>2021.</b> Pathogens . MDPI	Malusi Sibiya and Mbuyu Sumbwanyambe	Convolutional Neural Network (CNN)	Hal ini dicapai dengan menerapkan segmentasi ambang batas pada gambar daun jagung yang sakit (penyakit Common Rust) untuk mengekstrak persentase luas daun yang sakit yang kemudian digunakan untuk mendapatkan aturan keputusan fuzzy untuk penetapan gambar Common Rust ke kelas keparahannya. Empat kelas keparahan kemudian digunakan untuk melatih jaringan VGG-16 agar secara otomatis mengklasifikasikan gambar uji penyakit Common Rust sesuai dengan kelas keparahannya. Dilatih dengan gambar yang dikembangkan dengan menggunakan pendekatan yang diusulkan ini, jaringan VGG-16 mencapai akurasi validasi 95,63% dan akurasi pengujian 89% saat diuji pada gambar penyakit Common Rust di antara empat kelas keparahan penyakit bernama Tahap awal, Tahap menengah , Stadium Akhir dan Stadium Sehat.
27	Automatic Identification of Peanut-Leaf Diseases Based on Stack Ensemble	<b>2021.</b> Applied Sciences (Switzerland)	Haixia Qi, Yu Liang, Quanchen Ding and Jun Zou	Dalam eksperimen ini, model pembelajaran mendalam memiliki akurasi yang lebih tinggi daripada metode pembelajaran mesin tradisional. Selain itu, model pembelajaran mendalam mencapai kinerja yang lebih baik saat menggunakan augmentasi data dan ensemble	Di antara kelima CNN model, akurasi DenseNet121 diset tes adalah 95,98%, yang lebih tinggi dari model lainnya. Akurasi InceptionV3, ResNet50, AlexNet, dan VGG16 di set pengujian masing-masing adalah 95,07%, 95,25%, 91,79%, dan 93,35%. Dalam metode pembelajaran mesin tradisional, SVM mencapai akurasi 73,20%, yang 11,77% lebih tinggi dari LR terendah 61,43%. Dibandingkan dengan jaringan saraf convolutional, metode pembelajaran mesin tradisional jauh kurang efektif dalam identifikasi. Jaringan saraf convolutional dapat secara otomatis mengekstrak fitur gambar yang berguna melalui lapisan convolutional, dan kemudian meringkas dan mengklasifikasikan fitur ini dengan baik melalui lapisan akhir yang terhubung sepenuhnya.

				<p>susun. Setelah ensemble dengan regresi logistik, akurasi jaringan residual dengan 50 lapisan (ResNet50) mencapai 97,59%, dan skor F1 jaringan konvolusi padat dengan 121 lapisan (DenseNet121) setinggi 90,50. Model deep learning yang digunakan dalam eksperimen ini memiliki peningkatan skor F1 terbesar setelah ensemble regresi logistik. Jaringan pembelajaran mendalam dengan lapisan jaringan yang lebih dalam seperti ResNet50 dan DenseNet121 berkinerja lebih baik dalam eksperimen ini.</p>	
28	Image-Based Detection of Plant Diseases: From Classical Machine Learning to Deep Learning Journey	<b>2021.</b> Hindawi Wireless Communications and Mobile Computing	Rehan Ullah Khan, Khalil Khan, Waleed Albattah, and Ali Mustafa Qamar	DL pada umumnya dan CNN pada khususnya telah dikembangkan untuk menganalisis data multidimensi seperti gambar. Model yang	Dalam makalah ini, kami telah membahas bagaimana ML secara umum dan DL secara khusus telah membantu mengidentifikasi penyakit pada tanaman. Jika penyakit tidak diidentifikasi dengan benar, mereka mempengaruhi hasil panen dan pada akhirnya mengakibatkan masalah jangka panjang, seperti pemanasan global dan bahkan kelaparan. Pekerjaan yang diusulkan merangkum beberapa studi tentang otomatisasi dan identifikasi penyakit tanaman melalui metode ML yang berbeda. Naskah yang diusulkan juga

				<p>mendasari didasarkan pada ANN multilayer. Namun demikian, lapisan konvolusi melakukan operasi kernel di berbagai area gambar yang disediakan. Representasi yang diperoleh tidak tergantung pada operasi seperti translasi atau rotasi. Fitur-fitur semacam ini telah terbukti bekerja lebih baik dibandingkan dengan fitur-fitur tradisional yang sebelumnya digunakan dalam pendeteksian penyakit tanaman.</p>	<p>menunjukkan penerimaan yang baik dari berbagai metode CV dalam domain ini, menjadikannya area penelitian yang luas untuk dieksplorasi dalam waktu dekat. Beberapa poin dirangkum dalam paragraf berikut, yang dapat membantu untuk memperbaiki dan meningkatkan keadaan saat ini dan memberi peneliti beberapa ide potensial untuk mengeksplorasi lebih lanjut bidang ini di masa depan.</p>
29	A Mobile-Based System for Detecting Plant Leaf Diseases Using Deep Learning	<b>2021.</b> AgriEngineering (MDPI)	Ahmed Abdelmoamen Ahmed and Gopireddy Harshavardhan Reddy	<p>Sistem yang dikembangkan menggunakan Convolutional Neural networks (CNN) sebagai mesin pembelajaran mendalam yang mendasari untuk mengklasifikasi 38 kategori penyakit. Kami mengumpulkan dataset citra yang berisi 96.206 gambar</p>	<p>Antarmuka pengguna dikembangkan sebagai aplikasi seluler Android, memungkinkan petani untuk mengambil foto daun tanaman yang terinfeksi. Ini kemudian menampilkan kategori penyakit bersama dengan persentase kepercayaan. Sistem ini diharapkan dapat menciptakan peluang yang lebih baik bagi petani untuk menjaga tanaman mereka tetap sehat dan menghilangkan penggunaan pupuk yang salah yang dapat membuat tanaman stres. Akhirnya, kami mengevaluasi sistem kami menggunakan berbagai metrik kinerja seperti akurasi klasifikasi dan waktu pemrosesan. Kami menemukan bahwa model kami mencapai akurasi klasifikasi keseluruhan sebesar 94% dalam mengenali 38 kelas penyakit yang paling umum di 14 spesies tanaman.</p>

				daun tanaman dari tanaman yang sehat dan terinfeksi untuk pelatihan, validasi, dan pengujian model CNN.	
30	State of the art on southern corn leaf blight disease incited by <i>Cochliobolus heterostrophus</i> : detection, pathogenic variability and novel control measures	<b>2021.</b> Bulgarian Journal of Agricultural Science	Abdulaziz Bashir Kutawa, Khairulmazmi Ahmad, Asgar Ali, Mohd Zobir Hussein, Mohd Aswad Abdul Wahab, and Kamaruzaman Sijam	State of the art analisis Karakteristik morfologi, molekuler dan patogen patogen C. heterostrophus sangat membantu dalam mendeteksi patogen.	Berdasarkan ciri morfologi, warna koloni patogen ditemukan abu-abu, abu-abu muda. Bentuk konidia memanjang dengan panjang dan lebar berkisar antara 42-133 m dan 6-21 m. Primer universal dan spesifik yang berbeda digunakan untuk mengidentifikasi patogen menggunakan metode molekuler.  Penggunaan fungisida daun seperti propiconazole, mancoz-eb dan Zineb dilaporkan dapat mengurangi epidemi penyakit Hawar Daun (SCLB), meskipun bahan kimia ini tidak ramah lingkungan. Namun cara pengendalian penyakit yang paling baik adalah dengan menggunakan varietas tahan seperti Gangwon, Brokat TSW, SLBR3 dan SLBR5. Selain itu, <i>Trichoderma harzianum</i> (SH2303) dan <i>T. atroviride</i> (SG3403) telah menunjukkan aktivitas biokontrol yang kuat terhadap patogen SCLB. Praktik budaya seperti rotasi tanaman dan pengolahan tanah membantu meminimalkan sisa tanaman di pertanian penanaman jagung.
<b><i>Hyperparameter Tuning CNN</i></b>					
31	Optimal hyperparameter tuning of convolutional neural networks based on the parameter-setting-free harmony search algorithm	<b>2018</b> <b>OPTIK</b> International Journal for Light and Electron Optics	Woo-Young Lee, Seung-Min Parka, Kwee-Bo Sim	CNN Hyperparameter tuning parameter-setting-free harmony search (PSF-HS)	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 hyperparameters dalam arsitektur CNN yang diusulkan di masa lalu. Penelitian dilakukan dengan memperbarui HM untuk mengurangi jumlah bobot dan bias yang perlu dilatih oleh CNN yang terdiri dari vektor harmoni yang dihasilkan. Mengatur kondisi terminasi sehingga semua vektor harmoni yang tersimpan dalam HM menyatu menjadi satu vektor harmoni. Hasil simulasi menunjukkan bahwa HM konvergen menjadi satu vektor harmoni.
32	Performance comparison of the convolutional neural network	<b>2019</b> AIP Conference Proceedings	K. R. Prilianti, T. H. P. Brotosudarmo, S. Anam, and A. Suryanto	Gradient Descent Optimization CNN	Fokus penelitian ini adalah untuk meningkatkan akurasi model CNN dengan melakukan optimasi pada pemilihan parameter arsitektur CNN yaitu metode optimasi dan loss function.

	optimizer for photosynthetic pigments prediction on plant digital image	gs			Di sini, 7 pengoptimal berbasis penurunan gradien dibandingkan, yaitu, Stochastic Gradient Descent (SGD), Adaptive Gradient (Adagrad), Adaptive Delta (Adadelta), Root Mean Square Propagation (RMSProp), Adaptive Momentum (Adam), Adaptive Max Pooling (Adamax), dan Momentum Adaptif Nesterov (Nadam). Dari hasil eksperimen diketahui bahwa Adam merupakan pengoptimal terbaik untuk meningkatkan kemampuan LeNet dalam menangani hubungan konten pigmen citra digital. Namun, ketika sumber daya untuk eksperimen terbatas, menggunakan Adadelta dan Adamax adalah pilihan yang bijaksana untuk meminimalkan risiko
33	Optimization of convolutional neural network hyperparameters for automatic classification of adult mosquitoes	<b>2020</b> Plos One	Daniel Motta, Alex A' lisson Bandeira Santos, Bruna Aparecida Souza Machado, Otavio Goncalves Vicente Ribeiro-Filho, Luis Octavio Arriaga Camargo, Matias Alejandro Valdenegro-Toro, Frank Kirchner, Roberto Badaro	Hyperparameter CNN Xception dan DenseNet	Untuk melatih CNN agar melakukan klasifikasi morfologi nyamuk secara otomatis, kumpulan data, yang mencakup 7.561 gambar nyamuk target dan 1.187 gambar serangga lain, diperoleh. Berbagai jaringan saraf, seperti Xception dan DenseNet, digunakan untuk mengembangkan model klasifikasi otomatis berdasarkan gambar. Sebuah proses optimasi terstruktur pencarian acak dan pencarian grid dikembangkan untuk memilih set hyperparameter dan meningkatkan akurasi model. Model yang dioptimalkan, selama fase pengujian, memperoleh akurasi seimbang (BA) 93,5% dalam mengklasifikasikan nyamuk target dan serangga lainnya dan BA 97,3% dalam mendeteksi nyamuk genus Aedes dibandingkan dengan Culex. Hasilnya memberikan informasi dasar untuk melakukan klasifikasi morfologis spesies nyamuk secara otomatis.
34	Performance Comparison of the Convolutional Neural Network Optimizer for Photosynthetic Pigments Prediction on Plant Digital Image	<b>2018</b> AIP Conference Proceeding	K.R. Pilianti T.H.P. Brotosudarmo, S. Anam and A. Suryanto	CNN Hyperparameter Gradient Descent	Fokus penelitian ini adalah untuk meningkatkan akurasi model CNN dengan melakukan optimasi pada pemilihan parameter arsitektur CNN yaitu metode optimasi dan loss function. Seperti yang sudah diketahui, tidak ada satu pun pengoptimal yang dapat mengungguli semua kasus. Pemilihan pengoptimal harus dilakukan dengan mempertimbangkan variabilitas data dan tingkat nonlinier dari pola hubungan yang ada dalam data. Karena perhitungan teoritis saja tidak cukup untuk menentukan pengoptimal terbaik, maka diperlukan eksperimen untuk melihat secara langsung kinerja pengoptimal yang diduga sesuai dengan karakteristik data yang dianalisis. Metode optimasi penurunan gradien terkenal karena kemudahan komputasi dan kecepatan konvergensi pada kumpulan

					data besar. Di sini, 7 pengoptimal berbasis penurunan gradien dibandingkan, yaitu, Stochastic Gradient Descent (SGD), Adaptive Gradient (Adagrad), Adaptive Delta (Adadelta), Root Mean Square Propagation (RMSProp), Adaptive Momentum (Adam), Adaptive Max Pooling (Adamax), dan Momentum Adaptif Nesterov (Nadam). Dari hasil eksperimen diketahui bahwa Adam merupakan pengoptimal terbaik untuk meningkatkan kemampuan LeNet dalam menangani hubungan konten pigmen citra digital. Namun, ketika sumber daya untuk eksperimen terbatas, menggunakan Adadelta dan Adamax adalah pilihan yang bijaksana untuk meminimalkan risiko.
35	Optimasi Akurasi Metode Convolutional Neural Network untuk Identifikasi Jenis Sampah	<b>2019</b> JURNAL RESTI (Rekayasa Sistem dan Teknologi Informasi	Rima Dias Ramadhani, Afandi Nur Aziz Thohari, Condro Kartiko, Apri Junaidi, Tri Ginanjar Laksana, Novanda Alim Setya Nugraha	CNN Hyperparameter untuk dropout, padding, dan stride	Pada penelitian ini dilakukan optimasi penggunaan metode CNN untuk mendapatkan hasil yang akurat dalam mengidentifikasi jenis sampah. Optimasi dilakukan dengan menambah beberapa hyperparameter pada arsitektur CNN. Dengan menambahkan hyperparameter diperoleh nilai akurasi yang tinggi yaitu 91,2%. Sedangkan apabila tidak menggunakan hyperparameter nilai akurasi hanya sebesar 67,6%. Terdapat tiga hyperparameter yang digunakan untuk menaikkan nilai akurasi model yaitu dropout, padding, dan stride. Penambahan dropout sebesar 20% untuk meningkatkan overfitting saat pelatihan. Sedangkan padding dan stride digunakan untuk mempercepat proses pelatihan model.
36	Hyper Parameter Tuning Of Pre-Trained Deep Learning Model For An Efficient Medical Image Classification Using CNN	<b>2020</b> Journal of Critical Review	A. Rama, Bhavani M, Surya V	CNN Hyperparameter dengan arsitektur VGG16	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. Pekerjaan yang diusulkan membantu mengidentifikasi fungsi aktivasi terbaik untuk mengklasifikasikan penyakit menggunakan pembelajaran mendalam
37	Convolutional neural network with hyperparameter tuning for brain tumor classification	<b>2021</b> Kinetik: Game technology, Informatika system, Computer network, Computing	Agus Eko Minarno, Mochammad Hazmi Cokro Mandiri, Yuda Munarko, Hariyady	CNN with hyperparameter tuning Dropout, Dense layer, Optimizer (Adam, Adamax, RMS prop, SGD)	Penelitian ini bertujuan untuk mengklasifikasikan tumor otak menjadi empat kelas, yang meliputi: tidak ada tumor, glioma, meningioma, dan hipofisis. Pada penelitian ini dilakukan tiga model skenario dan hasil terbaik diperoleh pada model ketiga (ke-3) dengan akurasi 96%, sedangkan parameter terbaik diperoleh dari hasil Hyperparameter Tuning pada model yang diusulkan. Penelitian di masa depan didorong untuk menemukan metode baru

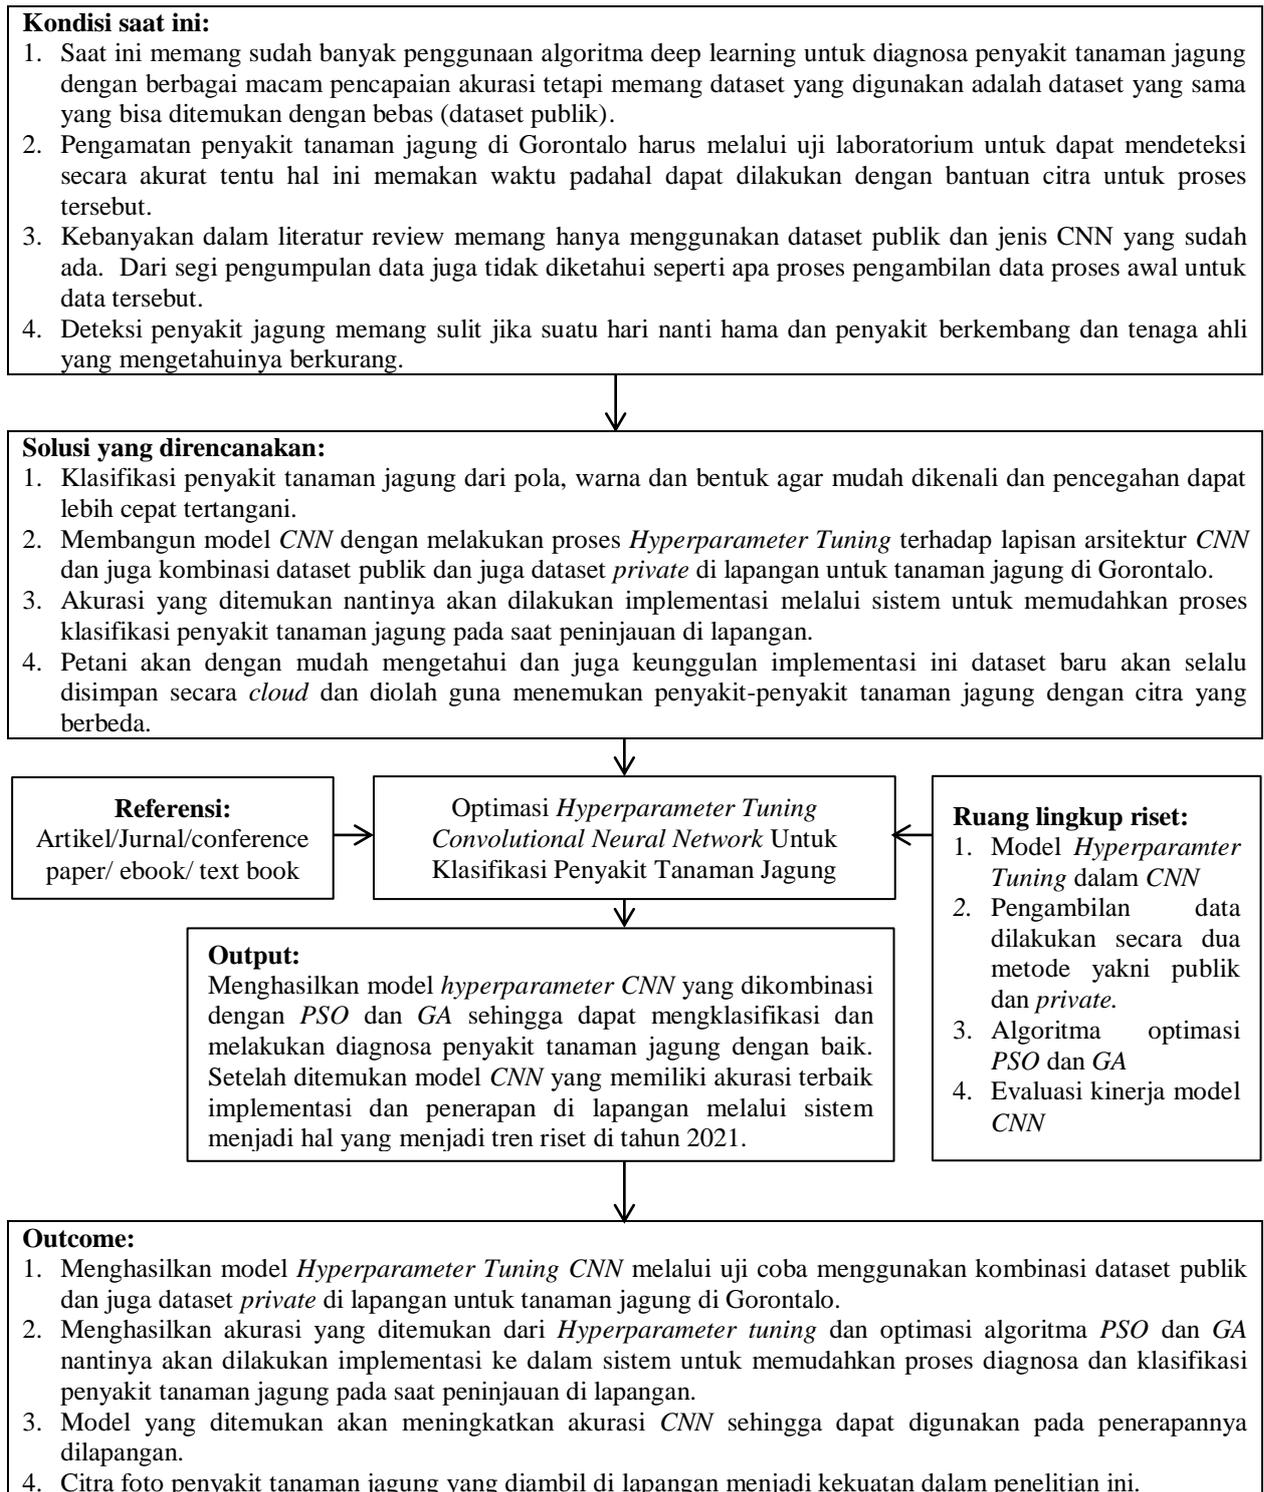
		g, Electronic and Control			untuk klasifikasi tumor otak dan untuk menavigasi parameter baru untuk model potensial
38	Hyperparameter Optimization in Convolutional Neural Network using Genetic Algorithms	<b>2019</b> (IJACSA) International Journal of Advanced Computer Science and Applications,	Nurshazlyn Mohd Aszemi, P.D.D Dominic	CNN GA Hyperparameter Random Search	Melakukan pencarian grid akan membuang banyak waktu dengan menyebutkan tingkat pembelajaran. Jutaan kombinasi hyperparameter akan membuat pencarian Grid tampak tidak praktis. Pencarian acak memungkinkan beberapa nilai hyperparameter dipilih dengan proses eliminasi atau seleksi. Pencarian acak tidak mencapai akurasi mutakhir sebesar 90% Di masa depan, algoritma genetika (GA) akan digunakan sebagai metode pencarian optimasi dengan arsitektur CNN yang diuji. Menggabungkan metode pencarian seperti pencarian grid, pencarian manual, pencarian acak dan pencarian lokal dengan pencarian global seperti GA akan diterapkan untuk penelitian lebih lanjut. Namun, menjalankan GA sebagai ruang pencarian hyperparameter membutuhkan biaya komputasi. Oleh karena itu, menjalankan beberapa GPU menjadi pertimbangan penulis. Dengan waktu yang cukup, lebih banyak metode optimasi seperti Bayesian dapat diselidiki seperti pencarian acak pada makalah ini.
39	cPSO-CNN: An efficient PSO-based algorithm for fine-tuning hyper-parameters of convolutional neural networks	<b>2019</b> ELSEVIER Swarm and Evolutionary Computation	Yulong Wang, Haoxin Zhang, Guangwei Zhang	PSO CNN untuk mencari hyperparameter tuning terbaik	Usulan varian baru optimasi (PSO) cPSO-CNN untuk mengoptimalkan konfigurasi hiperparameter dari CNN yang ditentukan arsitektur. cPSO-CNN menggunakan fungsi kepercayaan yang ditentukan oleh distribusi normal majemuk untuk memodelkan pengetahuan pakar tentang penyempurnaan parameter hiper CNN untuk meningkatkan kemampuan eksplorasi PSO kanonik. cPSO-CNN juga mendefinisikan ulang koefisien percepatan skalar PSO sebagai vektor untuk beradaptasi lebih baik untuk rentang varian hyper-parameter CNN. Selain itu, model prediksi linier diadopsi untuk peringkat cepat partikel PSO untuk mengurangi biaya evaluasi fungsi kebugaran. Hasil eksperimen menunjukkan bahwa cPSO-CNN bekerja secara kompetitif jika dibandingkan dengan beberapa algoritma yang dilaporkan dalam hal keunggulan hyper-parameter CNN dan biaya komputasi secara keseluruhan.
40	Genetic Algorithm Based Hybrid Model Of convolutional Neural Network And	<b>2021</b> Turkish Journal of Computer and Mathematics	Siji George C G, B. Sumathi	CNN, Random Forest, Hybrid CNNRF	Hasil eksperimen menunjukkan bahwa model yang diusulkan jauh mengalahkan model dasar yang ada dalam hal akurasi klasifikasi dan secara efektif mengintegrasikan CNN yang dimodifikasi secara genetik dengan pengklasifikasi Random Forest.

	Random Forest Classifier For Sentiment Classification	Education			Hasil eksperimen menunjukkan bahwa CNNRFGA memiliki akurasi 96,7%, Precision 96,6%, Recall 96,3% dan F1 Score 96,4. Dengan parameter terbaik LR: 0,001, Momentum: 0.95, iteration:7, Dropout: 0,4. Hyperparameter tuning dari model yang diusulkan menggunakan algoritma genetika membantu mengidentifikasi nilai terbaik untuk parameter yang dipilih dan memberikan kinerja yang menjanjikan dibandingkan dengan pencarian grid dan metode pencarian acak
41	A Hybrid GA-PSO-CNN Model for Ultra-Short-Term Wind Power Forecasting	2021 Energies MDPI	Jie Liu, Quan Shi, Ruilian Han and Juan Yang	Hybrid GA-PSO-CNN	Model dapat membuat peta fitur antara faktor-faktor yang mempengaruhi tenaga angin seperti kecepatan angin, arah angin, dan suhu. Selain itu, algoritma GA-PSO mix-encoding diperkenalkan untuk mengoptimalkan hyperparameter dan bobot jaringan secara kolaboratif, yang memecahkan masalah penentuan subjektif jaringan optimal di CNN dan secara efektif mencegah optimasi lokal dalam proses pelatihan. Efektivitas prediksi model yang diusulkan diverifikasi menggunakan data dari ladang angin di Ningxia, Cina. Hasilnya menunjukkan bahwa MAE, MSE, dan MAPE dari model GA-PSO-CNN yang diusulkan masing-masing turun 1,13-9,55%, 0,46-7,98%, dan 3,28-19,29%, di musim yang berbeda, dibandingkan dengan Single-CNN, Model PSO-CNN, ISSO-CNN, dan CHACNN. Ukuran dan jumlah kernel konvolusi di setiap lapisan konvolusi berkurang 5-18,4% dalam model GA-PSO-CNN.

Berdasarkan *state of the art* dan hasil *review* di atas peneliti juga ingin melakukan penelitian *Hyperparameter Tuning CNN* untuk klasifikasi Penyakit Tanaman Jagung yang juga dipadukan dengan algoritma optimasi seperti *Particle Swarm Optimization (PSO)* dan *Genetic Algorithm (GA)*. Model *hyperparameter* yang ditemukan selanjutnya akan di optimasi menggunakan *optimizer algorithm* guna peningkatan akurasi dan menurunkan nilai *error* dalam pembelajaran jaringan syaraf pada *CNN*. Jagung yang menjadi komoditas utama di Gorontalo haruslah menjadi pusat perhatian pada riset ini. Dengan mengembangkan sistem yang dapat melakukan klasifikasi citra dan mendeteksi penyakit tanaman jagung tentu akan sangat berguna nantinya. *Hyperparameter tuning CNN* digunakan karena berdasarkan hasil

*review* jurnal memiliki nilai akurasi yang tinggi bahkan lebih dari 90%. Hal itu menjadi alasan peneliti menggunakan algoritma optimasi *hyperparameter tuning CNN* dengan menambahkan juga algoritma optimasi seperti *PSO* dan *GA* yang nantinya akan ditemukan akurasi yang terbaik. Hasil dari penelitian ini diharapkan dapat memberikan kontribusi pengetahuan terhadap optimasi jaringan *hyperparameter CNN* dan *hybrid* algoritma optimasi *PSO* dan *GA* 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 yang di uji coba ke ladang jagung di Gorontalo.

## D. KERANGKA KONSEP PENELITIAN

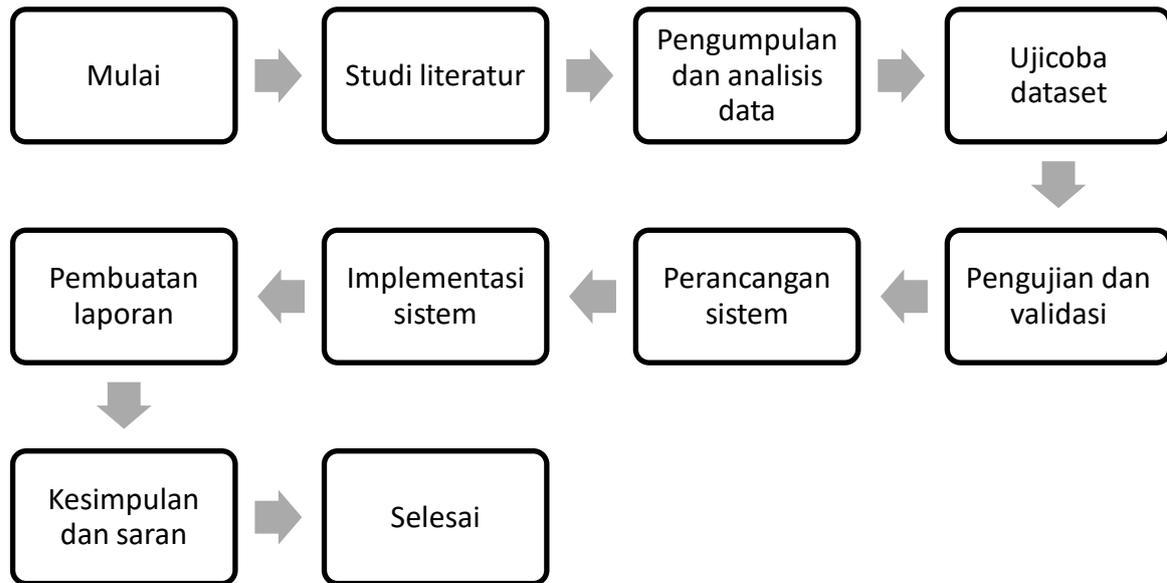


Gambar 5. Kerangka konsep penelitian

## BAB III METODE PENELITIAN

### A. TAHAPAN PENELITIAN

Tahapan penelitian merupakan perencanaan dan tahapan dalam suatu penelitian guna mengetahui langkah-langkah sebuah penelitian sebagaimana pada gambar 6 di bawah ini:



Gambar 6. Tahapan penelitian

Tahapan penelitian di atas dapat dijelaskan sebagai berikut:

#### 1. Studi literatur

Studi literatur dilakukan untuk penelusuran pustaka mengenai topik yang diangkat baik dari segi dataset, metode, implementasi dan mencari tren riset. Teknik yang dilakukan dengan menggunakan *tools mendeley*, *publish or perish* dan juga *VOS* guna menemukan *related* artikel yang akan diangkat menjadi sebuah penelitian. Beberapa artikel memang ditemukan yang berhubungan dengan *CNN*, deteksi penyakit tanaman jagung, akurasi dari tiap jenis *CNN* dan proses pengambilan datanya.

## 2. Pengumpulan dan analisis data

Proses ini dilakukan untuk mencari dan mengumpulkan dataset awal secara *online* guna mengetahui jenis-jenis penyakit tanaman jagung. Dataset yang dicari merupakan dataset *public* yang memang sudah divalidasi oleh penyedia dataset. Pengumpulan data penyakit tanaman jagung ini sangat penting untuk memperoleh banyak data citra. Data citra yang banyak akan langsung dilatih dan dianalisis menggunakan algoritma *CNN*. Proses ini guna mengetahui akurasi *CNN* itu sendiri. Setelah mendapatkan formulasi algoritmanya barulah peneliti melakukan pengambilan data secara *private* atau datang langsung ke lapangan dalam hal ini mengambil data jagung di Dinas Pertanian Gorontalo atau Balai Pengkajian Teknologi Pertanian.

## 3. Perancangan sistem

Pada tahapan ini dilakukan untuk merancang sebuah perangkat keras dan perangkat lunak yang nanti akan digunakan. Perangkat keras bisa berupa personal komputer (PC) yg digunakan dan bahasa pemograman atau software yang akan digunakan baik *matlab*, *python* dan aplikasi lainnya untuk pengembangan sistem.

## 4. Implementasi sistem

Tahapan implementasi sistem merupakan tahapan ujicoba sistem. Dapat juga untuk melakukan implementasi model sistem yang telah dirancang sebelumnya.

## 5. Ujicoba dataset

Tahapan ini sebenarnya bertujuan untuk melakukan ujicoba terhadap dataset yang didapatkan dari hasil pencarian melalui internet atau online. Dataset yang diolah memang merupakan dataset publik. Peneliti juga melakukan pengumpulan data secara turun langsung ke lapangan dan melakukan kombinasi dataset yang melakukan pelatihan dan testing dataset dengan model yang dibuat sebelumnya.

## 6. Pengujian dan validasi

Setelah proses ujicoba dataset selanjutnya tahapan pengujian dan validasi dari model yang dibuat. Proses pengujian ini melibatkan ahli untuk dapat melakukan validasi model dari akurasi yang didapatkan dari proses *CNN*.

#### 7. Pembuatan laporan

Tahapan ini merupakan proses terakhir apabila telah selesai seluruh rangkaian tahapan penelitian yakni dengan menyusun laporan hasil dari penelitian yang dilakukan.

#### 8. Kesimpulan dan saran

Setelah hasil penelitian selesai selanjutnya tahapan untuk membuat sebuah kesimpulan dan saran dari penelitian yang dilakukan. Tahapan ini juga tergolong penting karena kesimpulan dan saran yang akan dibuat akan berguna bagi pengembangan penelitian selanjutnya.

### **B. WAKTU DAN LOKASI PENELITIAN**

#### 1. Waktu penelitian

Penelitian ini akan dilaksanakan selama 1 tahun mulai November 2021 sampai dengan November 2022.

#### 2. Lokasi penelitian

Lokasi penelitian untuk jagung diambil langsung dari tanaman jagung di Gorontalo setelah itu dilaksanakan pada laboratorium Departemen Teknik Elektro, Fakultas Teknik, Universitas Hasanudin.

### **C. 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 [55]. 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* [55]. 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. Inilah yang kita sebut sebagai kelemahan dari desain eksperimental. Terkadang asumsi yang digunakan merupakan dari dampak. Asumsi yang dikenakan dari dampak sebaiknya diungkapkan dalam tulisan. Misalnya walaupun letak geografisnya berbeda tingkat kesuburan dan tingkat kemiringannya sama. Untuk membangun penelitian yang bersifat eksperimental usahakan agar ada pembandingan antara yang satu dengan yang lainnya.

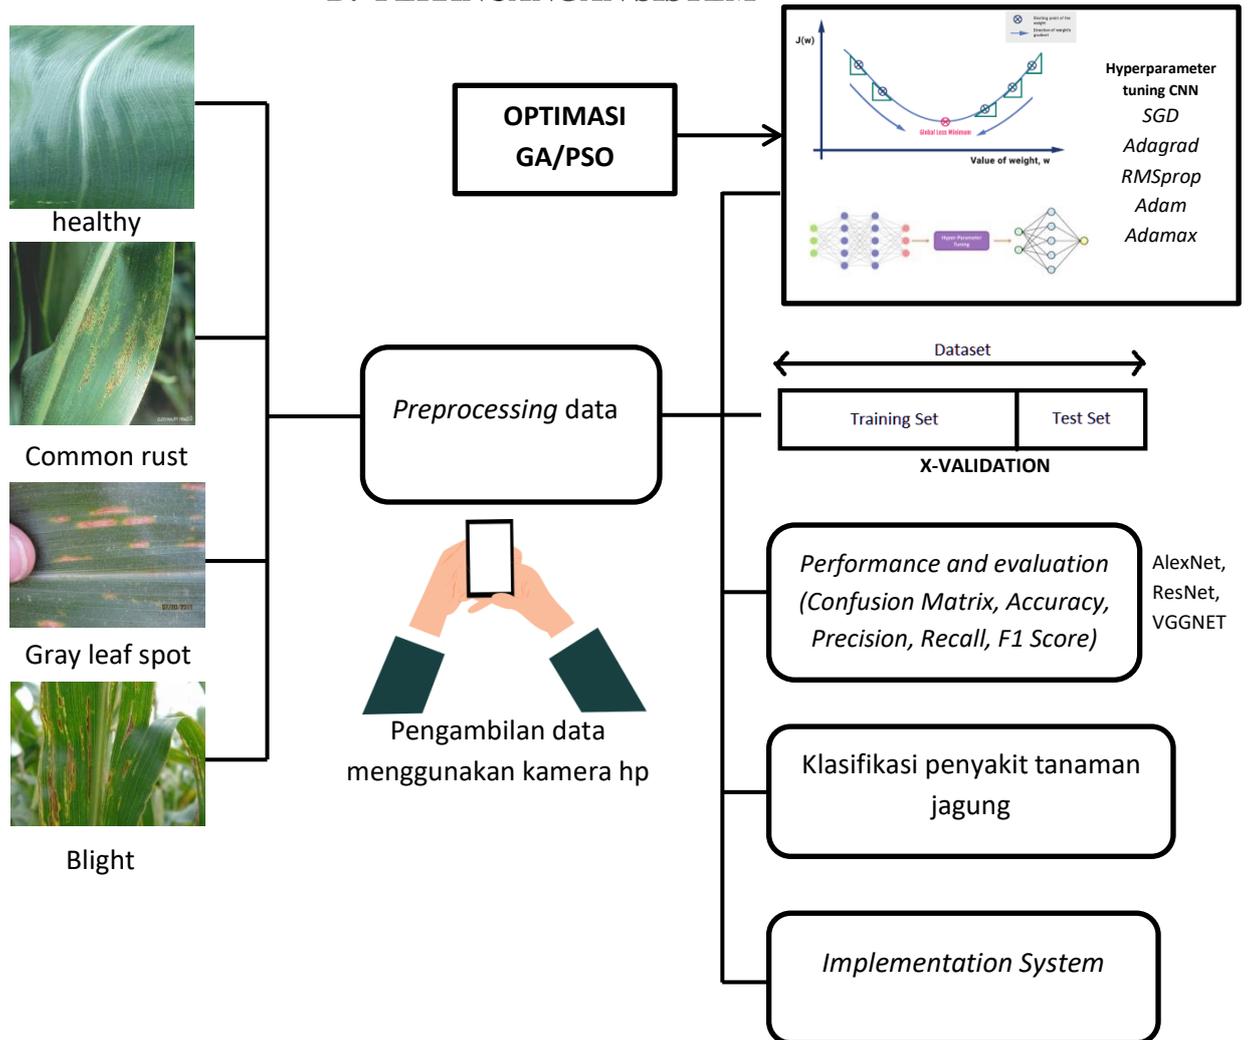
Di bidang ilmu komputer banyak digunakan eksperimental riset baik berupa simulasi (diatur jumlahnya) ada pembandingan dan hasilnya berupa grafik. Misalnya grafik produksi dari beberapa kali panen dengan beberapa varietas yang berbeda. Metode yang didapatkan dengan eksperimental riset. Grafik produksi dari beberapa kali panen disebut dengan hasil penelitian. Metode ini disebut dengan metode eksperimental. Sedangkan pada penelitian di bidang teknologi informasi juga sering digunakan penelitian eksperimental baik berupa *case study* maupun penelitian survey. Dalam desain eksperimental juga terdapat hubungan sebab akibat.

Hubungan sebab akibat ini terjadi jika dampaknya merupakan efek dari korelasi, dampaknya menimbulkan efek dan juga kita bisa mencari penjelasan dari hubungan sebab akibat. Misalnya untuk melihat hubungan sebab akibat antara sistem pembelajaran yang menggunakan *e-learning* dengan yang tidak menggunakan *e-learning*.

Dalam penelitian eksperimental ada yang disebut *independent variable* (faktor yang dimanipulasi) dan *dependent variable* (faktor yang diukur). Misalnya dua petak jagung, dimana perlakuan yang diberikan berupa pemupukan sedangkan yang ingin diukur adalah produksi jagung setelah panen. Pada faktor yang dimanipulasi (pemupukan) yang kita berikan 4 macam perlakuan misalnya tanpa pemupukan (0); pemupukan dengan 0.5 kg/ha; pemupukan dengan 1.0 kg/ha; dan pemupukan 1.5 kg/ha kg. Kita dapatkan hasil yang berbeda-beda. Pada saat kita melakukan pemupukan hingga 1.5 kg/ha ternyata hasil produksinya menurun. Ini berarti dalam grafik yang kita buat terdapat satu titik yang kita sebut dengan titik optimalisasi (titik maksimum).

Berdasarkan data yang kita dapatkan dapat digambarkan grafik yang berbeda-beda dimana setiap pertambahan satu satuan *independent variable* akan menghasilkan grafik yang berbeda. Pada grafik ini yang menjadi *independent* variabelnya adalah pemupukan dan *dependent* variabelnya adalah tingkat produksi yang dihasilkan. Karena pupuk yang diberikan berbeda-beda maka akan didapatkan hasil yang berbeda juga. Kondisi penelitian eksperimental yang diberikan perlakuan inilah yang kita sebut sebagai batasan dari penelitian.

## D. PERANCANGAN SISTEM



Gambar 7. Perancangan sistem

Blok diagram perancangan sistem di atas, penjabarannya dapat dijelaskan sebagai berikut:

Sistem yang diusulkan terdiri dari tujuh fase dari pengumpulan dataset citra penyakit tanaman jagung, *preprocessing* data, klasifikasi menggunakan algoritma *CNN*, *training* dan *testing* dataset, mengukur *performance* bisa berupa akurasi atau nilai *error* dan evaluasi, klasifikasi penyakit tanaman jagung dan validasi bersama ahli dan terakhir implementasi melalui sebuah sistem.

1. Pengumpulan data dilakukan dengan menggabungkan dataset *public* yang sudah ditemukan dengan dataset *private* yang akan dikumpulkan dari data lapangan pertanian jagung di Gorontalo. Untuk dataset *private* yang akan dikumpulkan peneliti akan

melakukan pengambilan sampel tanaman jagung yang terinfeksi penyakit dengan menggunakan kamera ponsel (*HP*). Dari pengambilan gambar tersebut kemudian akan di anotasikan berdasarkan jenis penyakit tanaman jagung.

2. *Proprocessing* data ini berperan sangat penting pada penelitian ini yakni dengan melakukan modifikasi atau pengoptimalan penggunaan pengumpulan data dan juga mengoptimalkan algoritma yang digunakan.
3. *Hyperparameter* algoritma *CNN* yang digunakan dilakukan ujicoba terlebih dahulu baik itu *SGD*, *Adagrad*, *RMSprop*, *Adam* dan *Adamax*. Hal ini guna menemukan model *hyperparameter* terbaik dalam penelitian ini. Setelah ditemukan optimasi *hyperparameter CNN* kemudian akan dikomparasi menggunakan algoritma *optimizer* yakni *Genetic Algorithm* atau *Particle Swarm Optimization (PSO)*.
4. *Training* dan *testing* untuk menemukan pola *training* dan *testing* itu sendiri baik pembagiannya menggunakan *cross validation* ataupun metode lainnya yang akan digunakan. Proses ini sangat penting karena penentuan *training* dan *testing* akan berpengaruh terhadap *performance*.
5. *Performance* dan *evaluation* digunakan untuk mengecek kemampuan dari algoritma bisa dilihat dari (*Confusion Matrix*, *Accuracy*, *Precision*, *Recall*, *F1 Score*). Evaluasi terhadap algoritma ini juga menjadi hal penting guna dapat membandingkan juga dengan hasil dari jenis *CNN* yang sudah ada seperti *AlexNet*, *ResNet*, *VGGNet* dan lain sebagainya.
6. Klasifikasi penyakit tanaman jagung yang menjadi objek penelitian ini menjadi hal yang penting bagi model yang dibuat, apakah algoritma *CNN* dapat melakukan klasifikasi penyakit tanaman jagung melalui citra gambar dan seperti apa hasilnya. Proses klasifikasi awalnya diolah menggunakan salah satu bahasa pemrograman dan diuji model terbaik yang ditemukan sebelum dilanjutkan pada tahapan implementasi sistem.

7. Implementasi dalam sistem merupakan tahapan akhir dalam penelitian ini. Setelah model ditemukan sistem sederhana akan dibuat berbasis *web* untuk melakukan klasifikasi penyakit tanaman jagung langsung dari lapangan. Dataset yang sebelumnya disimpan dalam sebuah *cloud* akan langsung dapat melakukan klasifikasi penyakit tanaman jagung.

## E. SUMBER DATA

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*. Data primer tersebut harus dicari melalui narasumber atau responden yaitu orang yang kita jadikan obyek penelitian atau orang yang kita jadikan sebagai sarana mendapatkan informasi maupun data. Pencarian data primer bisa dilakukan dengan cara wawancara atau *interview* langsung dengan responden, melalui telepon, email dan sebagainya. Dalam mengumpulkan data primer, biasanya peneliti menggunakan instrumen penelitian yang disebut dengan kuesioner [55]. Data primer yang dimaksud pada penelitian ini yakni data yang memang diambil dari lapangan yakni citra penyakit tanaman jagung di Gorontalo. Setelah itu langsung mengamati tanaman jagung) yang ditanam petani dengan umur yang bervariasi, (penanaman ditingkat petani tidak seragam) sehingga dapat ditemukan tanaman dalam berbagai umur yaitu ada yang berumur 3, 4, 5, 6, 8, 10 minggu. Hama dan penyakit yang ditemukan pada tanaman jagung dikumpulkan serta di ambil citra fotonya.

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 perpustakaan, perusahaan-perusahaan, organisasi-organisasi perdagangan,

biro pusat statistik, dan kantor-kantor pemerintahan seperti data dari Badan Pusat Statistik (BPS), data hasil riset, data dari perusahaan dan lain sebagainya. Data sekunder disebut juga sebagai pendukung untuk *preprocessing* nanti dalam pengolahan data dari dataset publik.

## F. INSTRUMENTASI 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/ DSLR
2. Perangkat lunak
  - a. Windows 10
  - b. Python

## G. JADWAL PENELITIAN

Berikut jadwal penelitian yang dibuat selama satu tahun mulai dari studi literatur sampai dengan ujian promosi

KEGIATAN	BULAN											
	1	2	3	4	5	6	7	8	9	10	11	12
Studi literatur												
Penyusunan proposal												
Seminar proposal												
Pengumpulan dan analisis data												
Perancangan sistem												
Seminar Internasional												
Implementasi sistem												

Ujicoba dataset												
Pengujian dan validasi												
Publikasi jurnal scopus 1												
Pembuatan laporan disertasi												
Kesimpulan dan saran												
Publikasi jurnal scopus 2												
Seminar hasil												
Ujian promosi disertasi												

## DAFTAR PUSTAKA

- [1] Gorontalo, “Sejarah Gorontalo,” *GorontaloKota*, 2019. <https://www.gorontaloKota.go.id/page/sejarah-gorontalo>.
- [2] D. P. P. Gorontalo, “Potensi Pertanian Jagung,” 2019. <https://dispan.gorontaloProv.go.id/potensi-pertanian-jagung/>.
- [3] M. Lihawa and Z. Ilahude, “Basis Data Hama dan Penyakit Tanaman Jagung di Provinsi Gorontalo,” 2017.
- [4] Ilham, R. Iswati, and S. Dude, “Penyakit vegetatif tanaman jagung hibrida varietas bima-20 uri di gorontalo.,” pp. 609–615, 2015.
- [5] M. Syarief and W. Setiawan, “Convolutional neural network for maize leaf disease image classification,” *Telkomnika (Telecommunication Comput. Electron. Control.*, vol. 18, no. 3, pp. 1376–1381, 2020, doi: 10.12928/TELKOMNIKA.v18i3.14840.
- [6] A. Hidayat, U. Darusalam, and I. Irmawati, “Detection of Disease on Corn Plants Using Convolutional Neural Network Methods,” *J. Ilmu Komput. dan Inf.*, vol. 12, no. 1, p. 51, 2019, doi: 10.21609/jiki.v12i1.695.
- [7] R. Agarwal and H. Sharma, “Enhanced Convolutional Neural Network (ECNN) for Maize Leaf Diseases Identification,” *Smart Innov. Commun. ...*, 2021, [Online]. Available: [https://link.springer.com/chapter/10.1007/978-981-15-5345-5\\_27](https://link.springer.com/chapter/10.1007/978-981-15-5345-5_27).
- [8] I. M. Adekunle, “Implementation of Improved Machine Learning Techniques for Plant Disease Detection and Classification,” *Int. J. Res. Innov. Appl. Sci. /*, vol. V, no. Vi, pp. 2454–6194, 2020, [Online]. Available: [www.rsisinternational.org](http://www.rsisinternational.org).
- [9] T. Wiesner-Hanks *et al.*, “Image set for deep learning: Field images of maize annotated with disease symptoms,” *BMC Res. Notes*, vol. 11, no. 1, pp. 10–12, 2018, doi: 10.1186/s13104-018-3548-6.
- [10] S. Sladojevic, M. Arsenovic, A. Anderla, D. Culibrk, and D. Stefanovic, “Deep Neural Networks Based Recognition of Plant Diseases by Leaf Image Classification,” *Comput. Intell. Neurosci.*, vol. 2016, 2016, doi: 10.1155/2016/3289801.
- [11] G. Wang, Y. Sun, and J. Wang, “Automatic Image-Based Plant Disease Severity Estimation Using Deep Learning,” *Comput. Intell. Neurosci.*, vol. 2017, 2017, doi: 10.1155/2017/2917536.
- [12] A. Jayakumar, “Detection and Classification of Leaf Diseases in Maize Plant using Machine Learning,” 2020, [Online]. Available: <http://trap.ncirl.ie/id/eprint/4278>.
- [13] T. Islam, “Plant Disease Detection using CNN Model and Image Processing,” *Int. J. Eng. Res. Technol.*, vol. 9, no. 10, pp. 291–297, 2020, [Online]. Available: <https://www.ijert.org/plant-disease-detection-using-cnn-model-and-image-processing>.
- [14] Z. Wang and S. Zhang, “Segmentation of Corn Leaf Disease Based on Fully Convolution Neural Network,” *Acad. J. Comput. Inf. Sci.*, vol. 1, no. 1, pp. 9–18, 2018, doi: 10.25236/ajcis.010002.

- [15] A. A. Ahmed, "A Mobile-Based System for Detecting Plant Leaf Diseases Using Deep Learning," pp. 478–493, 2021.
- [16] A. Picon, M. Seitz, A. Alvarez-Gila, P. Mohnke, A. Ortiz-Barredo, and J. Echazarra, "Crop conditional Convolutional Neural Networks for massive multi-crop plant disease classification over cell phone acquired images taken on real field conditions," *Comput. Electron. Agric.*, vol. 167, no. May, p. 105093, 2019, doi: 10.1016/j.compag.2019.105093.
- [17] P. Lacerda, B. Barros, C. Albuquerque, and A. Conci, "Hyperparameter optimization for COVID-19 pneumonia diagnosis based on chest CT," *Sensors*, vol. 21, no. 6, pp. 1–11, 2021, doi: 10.3390/s21062174.
- [18] A. E. Minarno, M. Hazmi Cokro Mandiri, Y. Munarko, and H. Hariyady, "Convolutional Neural Network with Hyperparameter Tuning for Brain Tumor Classification," *Kinet. Game Technol. Inf. Syst. Comput. Network, Comput. Electron. Control*, vol. 4, 2021, doi: 10.22219/kinetik.v6i2.1219.
- [19] D. Motta *et al.*, "Optimization of convolutional neural network hyperparameters for automatic classification of adult mosquitoes," *PLoS One*, vol. 15, no. 7, pp. 1–30, 2020, doi: 10.1371/journal.pone.0234959.
- [20] W. Y. Lee, S. M. Park, and K. B. Sim, "Optimal hyperparameter tuning of convolutional neural networks based on the parameter-setting-free harmony search algorithm," *Optik (Stuttg.)*, vol. 172, no. May, pp. 359–367, 2018, doi: 10.1016/j.ijleo.2018.07.044.
- [21] P. Harsan, A. Qurania, and K. Damayanti, "Maize Plant Disease Identification (Zea Mays L. Saccharata) Using Image Processing and K-Nearest Neighbor (K-Nn)," *Int. J. Eng. Technol.*, vol. 7, no. 3.20, p. 402, 2018, doi: 10.14419/ijet.v7i3.20.20581.
- [22] U. Darusalam and I. Irmawati, "DETECTION OF DISEASE ON CORN PLANTS USING CONVOLUTIONAL NEURAL NETWORK METHODS," *jiki3.cs.ui.ac.id*, [Online]. Available: <https://jiki3.cs.ui.ac.id/index.php/jiki/article/view/695>.
- [23] A. Wu *et al.*, "Classification of corn kernels grades using image analysis and support vector machine," *Adv. Mech. Eng.*, vol. 10, no. 12, pp. 1–9, 2018, doi: 10.1177/1687814018817642.
- [24] B. S. Kusumo, A. Heryana, O. Mahendra, and H. F. Pardede, "Machine Learning-based for Automatic Detection of Corn-Plant Diseases Using Image Processing," *2018 Int. Conf. Comput. Control. Informatics its Appl. Recent Challenges Mach. Learn. Comput. Appl. IC3INA 2018 - Proceeding*, no. February 2019, pp. 93–97, 2019, doi: 10.1109/IC3INA.2018.8629507.
- [25] M. Brahim, K. Boukhalfa, and A. Moussaoui, "Deep Learning for Tomato Diseases: Classification and Symptoms Visualization," *Appl. Artif. Intell.*, vol. 31, no. 4, pp. 299–315, 2017, doi: 10.1080/08839514.2017.1315516.
- [26] A. Ramcharan, K. Baranowski, P. McCloskey, B. Ahmed, J. Legg, and D. P. Hughes, "Deep learning for image-based cassava disease detection," *Front. Plant Sci.*, vol. 8, no. October, pp. 1–7, 2017, doi: 10.3389/fpls.2017.01852.

- [27] A. Fuentes, S. Yoon, S. C. Kim, and D. S. Park, “A robust deep-learning-based detector for real-time tomato plant diseases and pests recognition,” *Sensors (Switzerland)*, vol. 17, no. 9, 2017, doi: 10.3390/s17092022.
- [28] J. Amara, B. Bouaziz, and A. Algergawy, “A deep learning-based approach for banana leaf diseases classification,” *Lect. Notes Informatics (LNI), Proc. - Ser. Gesellschaft fur Inform.*, vol. 266, pp. 79–88, 2017.
- [29] A. Rama, M. Bhavani, and V. Surya, “Hyper Parameter Tuning of Pre-Trained Deep Learning Model for an Efficient Medical Image Classification Using Cnn,” *J. Crit. Rev.*, no. September, 2020, doi: 10.13140/RG.2.2.28985.39525.
- [30] K. R. Prilianti, T. H. P. Brotosudarmo, S. Anam, and A. Suryanto, “Performance comparison of the convolutional neural network optimizer for photosynthetic pigments prediction on plant digital image,” *AIP Conf. Proc.*, vol. 2084, no. March, 2019, doi: 10.1063/1.5094284.
- [31] X. Xie, X. Zhang, B. He, D. Liang, D. Zhang, and L. Huang, “A system for diagnosis of wheat leaf diseases based on Android smartphone,” *Opt. Meas. Technol. Instrum.*, vol. 10155, p. 1015526, 2016, doi: 10.1117/12.2246919.
- [32] S. Loussaief and A. Abdelkrim, “Convolutional Neural Network hyper-parameters optimization based on Genetic Algorithms,” *Int. J. Adv. Comput. Sci. Appl.*, vol. 9, no. 10, pp. 252–266, 2018, doi: 10.14569/IJACSA.2018.091031.
- [33] S. G. C. G. Et. al., “Genetic Algorithm Based Hybrid Model Of convolutional Neural Network And Random Forest Classifier For Sentiment Classification,” *Turkish J. Comput. Math. Educ.*, vol. 12, no. 2, pp. 3216–3223, 2021, doi: 10.17762/turcomat.v12i2.2379.
- [34] Y. Wang, H. Zhang, and G. Zhang, “cPSO-CNN: An efficient PSO-based algorithm for fine-tuning hyper-parameters of convolutional neural networks,” *Swarm Evol. Comput.*, vol. 49, no. June, pp. 114–123, 2019, doi: 10.1016/j.swevo.2019.06.002.
- [35] J. Fregoso, C. I. Gonzalez, and G. E. Martinez, “Optimization of convolutional neural networks architectures using pso for sign language recognition,” *Axioms*, vol. 10, no. 3, 2021, doi: 10.3390/axioms10030139.
- [36] Y. Guo, J. Y. Li, and Z. H. Zhan, “Efficient Hyperparameter Optimization for Convolution Neural Networks in Deep Learning: A Distributed Particle Swarm Optimization Approach,” *Cybern. Syst.*, vol. 52, no. 1, pp. 36–57, 2020, doi: 10.1080/01969722.2020.1827797.
- [37] M. Yusoff, M. Syafiq, I. Saaidi, A. S. Afendi, and A. M. Hassan, “Tuberculosis X-Ray Images Classification based Dynamic Update Particle Swarm Optimization with CNN,” vol. 48, no. 9, 2021.
- [38] Z. Fouad, M. Alfonse, M. Roushdy, and A. B. M. Salem, “Hyper-parameter optimization of convolutional neural network based on particle swarm optimization algorithm,” *Bull. Electr. Eng. Informatics*, vol. 10, no. 6, pp. 3377–3384, 2021, doi: 10.11591/eei.v10i6.3257.
- [39] C. Pertanian, “Definisi Penyakit Tanaman.”

- <http://cybex.pertanian.go.id/mobile/artikel/96042/Definisi-Penyakit-Tanaman/>.
- [40] M. S. Sudjono, “Penyakit Jagung dan Pengendaliannya,” *Balai Penelit. Tanam. Pangan Maros*, vol. 8, no. 11, pp. 34–36, 2018, [Online]. Available: <http://balitsereal.litbang.pertanian.go.id/wp-content/uploads/2018/08/11penyakit.pdf>.
- [41] A. Kadir and A. Susanto, *Teori dan Aplikasi Pengolahan Citra*. Yogyakarta: Andi Yogyakarta, 2013.
- [42] R. C. Gonzales and R. E. Woods, *Digital Image Processing*. New Jersey: Prentice-Hall inc, 2002.
- [43] I. H. Witten;, E. Frank;, and M. A. Hall;, *Data Mining*. 2008.
- [44] C. C. Aggarwal, *Data mining: the textbook*. books.google.com, 2015.
- [45] H. Wu *et al.*, “Autonomous Detection of Plant Disease Symptoms Directly from Aerial Imagery,” *Plant Phenome J.*, vol. 2, no. 1, pp. 1–9, 2019, doi: 10.2135/tppj2019.03.0006.
- [46] W. T. Kim, D. M. Kang, S. J. Yoon, H. Cho, and ..., “Development of a CNN-based Expert System using Domain Knowledge,” ... *Circuits/Systems ...*, 2019, [Online]. Available: <https://ieeexplore.ieee.org/abstract/document/8793323/>.
- [47] Z. Lin, S. Mu, A. Shi, C. Pang, and X. Sun, “A novel method of maize leaf disease image identification based on a multichannel convolutional neural network,” *Trans. ASABE*, 2018, [Online]. Available: <https://elibrary.asabe.org/abstract.asp?aid=49777>.
- [48] W. Setiawan, M. Syarief, and N. Prastiti, “Maize Leaf Disease Image Classification Using Bag of Features,” *J. INFOTEL*, 2019, [Online]. Available: <http://ejournal.st3telkom.ac.id/index.php/infotel/article/view/428>.
- [49] R. Ahila Priyadharshini, S. Arivazhagan, M. Arun, and A. Mirnalini, “Maize leaf disease classification using deep convolutional neural networks,” *Neural Comput. Appl.*, vol. 31, no. 12, pp. 8887–8895, 2019, doi: 10.1007/s00521-019-04228-3.
- [50] R. D. Ramadhani, A. N. A. Thohari, C. Cartiko, A. Junaidi, and T. G. Laksana, “Optimasi Akurasi Metode Convolutional Neural Network untuk Identifikasi Jenis Sampah,” *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 1, no. 10, pp. 11–12, 2021.
- [51] A. Nurhopipah and N. A. Larasati, “CNN Hyperparameter Optimization using Random Grid Coarse-to-fine Search for Face Classification,” *Kinet. Game Technol. Inf. Syst. Comput. Network, Comput. Electron. Control*, vol. 4, pp. 19–26, 2021, doi: 10.22219/kinetik.v6i1.1185.
- [52] A. E. MINARNO, M. H. C. MANDIRI, and M. R. ALFARIZY, “Klasifikasi COVID-19 menggunakan Filter Gabor dan CNN dengan Hyperparameter Tuning,” *ELKOMIKA J. Tek. Energi Elektr. Tek. Telekomun. Tek. Elektron.*, vol. 9, no. 3, p. 493, 2021, doi: 10.26760/elkomika.v9i3.493.
- [53] J. Liu, Q. Shi, R. Han, and J. Yang, “A hybrid ga–pso–cnn model for ultra-short-term wind power forecasting,” *Energies*, vol. 14, no. 20, 2021, doi: 10.3390/en14206500.

- [54] N. M. Aszemi and P. D. D. Dominic, "Hyperparameter optimization in convolutional neural network using genetic algorithms," *Int. J. Adv. Comput. Sci. Appl.*, vol. 10, no. 6, pp. 269–278, 2019, doi: 10.14569/ijacsa.2019.0100638.
- [55] Z. Hasibuan A, "Metodologi Penelitian Pada Bidang Komputer," *Metodol. Penelit. Pada Bid. Ilmu Komput. Dan Teknol. Inf.*, vol. 4, no. 1, pp. 1–194, 2007.