

BAB II

TINJAUAN PUSTAKA

2.1 Penelitian yang Relevan

Pada bagian penelitian yang relevan ini, akan membahas tentang beberapa penelitian sebelumnya yang serupa dan relevan dengan penelitian penulis yang sedang berlangsung. Penelitian-penelitian ini sebagai pembanding akan diuraikan berdasarkan topik atau objek utama yang diteliti.

Adapun rangkuman dari 10 penelitian relevan yang dirangkum berikut :

- 1) Penelitian oleh Albakia, S.A.E., & Saputra, R.A.(2023) berjudul “*Identifikasi Jenis Daun Tanaman Obat Menggunakan CNN dengan Model VGG16*” yang diterbitkan di *International Journal of Artificial Intelligence and Applications (IJIAI)*. Penelitian menggunakan pendekatan Transfer Learning VGG16 untuk mengenali sepuluh jenis daun herbal termasuk pepaya dan jarak. Model dilatih menggunakan dataset citra beresolusi tinggi dari *PlantVillage* dan dataset lokal Indonesia. Hasil pengujian menunjukkan akurasi 96% dengan waktu pelatihan yang lebih efisien dibanding CNN murni. Penelitian ini menegaskan efektivitas transfer learning dalam mengenali daun tropis dengan karakteristik serupa.
- 2) Penelitian oleh Setiyono, B., Arif, M.R., & Aini, Q.Q. (2023) yang berjudul “*Identification of Indonesian Medicinal Plants Using Convolutional Neural Network (CNN)*” diterbitkan pada *Journal of Emerging Technologies in Computing and Engineering (JETCE)*. Peneliti membangun arsitektur CNN kustom untuk mengidentifikasi 12 jenis daun tanaman herbal Indonesia, termasuk pepaya dan chaya. Model terdiri dari tiga lapisan konvolusi dan dua lapisan *fully connected*. Dengan menggunakan augmentasi rotasi dan pencahayaan, model mencapai akurasi 94%. Hasil menunjukkan CNN mampu mengenali daun dengan variasi tekstur dan bentuk yang kompleks di lingkungan tropis.
- 3) Penelitian oleh Mulyana, S., & Muthmainnah, I. (2024) berjudul “*Analisis Perbandingan Tingkat Akurasi Algoritma CNN dan SVM Dalam Klasifikasi Pada Daun Gedi, Daun Pepaya, dan Daun Ubi*” yang dipublikasikan dalam *JATI (Jurnal Teknologi dan Informasi)*. Peneliti membandingkan performa CNN dan SVM menggunakan dataset 600 gambar daun. CNN memperoleh akurasi 95,7%

sementara SVM hanya 89,2%. Studi ini menegaskan keunggulan CNN dalam mengenali pola non-linear pada permukaan daun pepaya dan gedi yang memiliki variasi tekstur tinggi.

- 4) Penelitian oleh Purwanto, P., & Sumardi, S. (2022) berjudul “*Perancangan Klasifikasi Tanaman Herbal Menggunakan Transfer Learning pada CNN*” yang diterbitkan di *Jurnal Infokam*. Metode ResNet50 digunakan untuk mengklasifikasi beberapa jenis daun herbal termasuk kemangi dan jambu biji. Model *transfer learning* ini meningkatkan akurasi hingga 97% dibanding CNN standar. Penelitian ini relevan untuk diterapkan pada klasifikasi daun jarak dan chaya yang memiliki kemiripan pola urat daun.
- 5) Penelitian oleh Putra, M.A.P., & Fachrie, M. (2025) berjudul “*Evaluasi Algoritma Deep Learning untuk Estimasi Luas Daun Pepaya pada Smart Garden*” yang diterbitkan dalam *Jurnal Algoritma*. Menggunakan metode Mask R-CNN, penelitian ini fokus pada deteksi area daun pepaya untuk menghitung luas daun secara otomatis. Model segmentasi mencapai akurasi 96%, mendukung penerapan *smart farming* berbasis visi komputer dalam pemantauan pertumbuhan daun pepaya di rumah kaca tropis.
- 6) Penelitian oleh Azzahra, A.R., Darwis, H., & Widyawati, D. (2023) berjudul “*Klasifikasi Daun Herbal Menggunakan CNN dan Naïve Bayes dengan Fitur GLCM*” diterbitkan di *Indonesian Journal of Computer Science*. Metode CNN + GLCM + Naïve Bayes digunakan untuk mengenali delapan jenis daun herbal Indonesia. CNN mengekstraksi fitur bentuk, sementara GLCM mengekstraksi tekstur daun. Akurasi mencapai 98%, menunjukkan bahwa kombinasi fitur spasial dan tekstur menghasilkan performa terbaik pada klasifikasi daun chaya dan pepaya.
- 7) Penelitian oleh Sari, C.A. (2021) berjudul “*Fitur Ekstraksi LBP dan Naive Bayes dalam Klasifikasi Jenis Pepaya Berdasarkan Citra Daun*” diterbitkan pada *Jurnal Masyarakat Informatika*. Studi ini menggabungkan CNN dan Local Binary Pattern (LBP) untuk mengekstraksi fitur tekstur daun pepaya. Dengan kombinasi CNN–LBP–Naïve Bayes, model berhasil mencapai akurasi 97%. Hasil penelitian ini dapat digunakan untuk membedakan varietas pepaya berdasarkan karakteristik visual daunnya.
- 8) Penelitian Oleh Putra, K.U., Yosfand, W., & Ramadhanu, A. (2025). Yang berejudul “*Klasifikasi Kematangan Buah Pepaya Berdasarkan Warna*

Menggunakan CNN” diterbitkan pada *Jurnal Teknologi Sistem Informasi (JITSI)*. Menggunakan Deep CNN, peneliti mengklasifikasi tingkat kematangan buah pepaya berdasarkan warna dan kondisi daun. Akurasi mencapai 96%. Pendekatan ini dapat diperluas untuk analisis kesehatan tanaman chaya dan jarak berdasarkan warna daun.

- 9) Penelitian oleh Arfah, J., Darwis, H., & Sastra, R. (2023). Penelitian ini berjudul “*Klasifikasi Penyakit Bawang Merah Menggunakan Naive Bayes dan CNN dengan Fitur GLCM*” yang diterbitkan di *Indonesian Journal of Computer Science*. Meskipun fokus pada bawang merah, metode CNN–GLCM yang digunakan dapat diterapkan untuk mendeteksi penyakit daun chaya dan pepaya. Model memperoleh akurasi 95% dan mampu mendeteksi kerusakan kecil pada jaringan daun.
- 10) Penelitian oleh Hafiz, A., Tumanggor, A.A., Ibo, M.D., & Noor, M.Y. (2025) berjudul “*Deteksi Jeruk Nipis dan Jeruk Jungga Menggunakan CNN*” diterbitkan di *JATI (Jurnal Teknologi dan Informasi)*. Model CNN kustom digunakan untuk membedakan dua varietas jeruk berdasarkan citra daun dan buah. Hasil menunjukkan akurasi 94%. Pendekatan yang sama dapat digunakan untuk klasifikasi daun pepaya, chaya, dan jarak dengan penyesuaian dataset.

a) Perbedaan Posisi Penelitian (Apa yang Membedakannya)

Penelitian ini berada pada tahap dasar, berbeda dengan penelitian sebelumnya yang fokus pada penyakit tanaman atau klasifikasi tunggal. Penelitian ini menghadirkan model CNN untuk tiga jenis daun yang mirip secara morfologi sehingga menambah kontribusi pada identifikasi biomassa.

2.2 Landasan Teori

Kerangka teori merupakan fondasi konseptual atau filosofis yang meliputi berbagai konsep, prinsip, teori, atau perspektif yang telah diuraikan oleh peneliti terdahulu. Landasan ini berfungsi sebagai pijakan dalam merancang, memandu, dan menafsirkan penelitian yang sedang dilaksanakan. Berikut beberapa penelitian yang penulis anggap relevan dan sejalan dengan bidang penelitian yang penulis teliti:

2.2.1 Teori Morfologi Daun

Morfologi daun merupakan indikator penting dalam klasifikasi spesies tanaman karena ciri-ciri strukturalnya, seperti bentuk helaian (lamina), jumlah lobus, tepi daun (margin), dan pola tulang daun, relatif stabil dan mudah diamati (Rahman, 2020). Ciri-ciri visual ini menjadi dasar dalam klasifikasi otomatis menggunakan citra digital, khususnya untuk daun dengan kemiripan morfologi tinggi. Kemudian diperkuat dengan Penelitian oleh Sari & Nugroho (2021) menunjukkan bahwa bentuk dan kontur daun dapat membedakan spesies dengan akurasi tinggi, sementara Pratama et al. (2022) melaporkan bahwa CNN mampu mengekstraksi perbedaan halus pada tepi dan lobus daun, menghasilkan akurasi lebih dari 90% dalam klasifikasi daun tropis.

Hal ini diperkuat oleh penelitian Prayitno & Palupiningsih (2025) yang menegaskan bahwa dalam ekosistem pertanian cerdas (*smart farming*), ekstraksi fitur otomatis pada citra daun memerlukan model yang mampu menangani variasi pencahayaan dan latar belakang yang kompleks guna menjaga konsistensi identifikasi. Lebih lanjut, menurut Santoso et al. (2023) menambahkan bahwa ciri morfologi seperti bentuk tepi daun, pola urat, dan warna hijau daun merupakan faktor penting dalam proses klasifikasi visual menggunakan metode berbasis *deep learning* seperti CNN.

Kekuatan CNN dalam mengenali hierarki fitur ini juga didukung oleh Cahyaningtyas (2023), yang menyatakan bahwa penggunaan arsitektur berbasis *transfer learning* sangat efektif dalam mengenali tekstur biologis yang rumit, sehingga meminimalkan kesalahan klasifikasi pada spesies yang tampak serupa secara visual. Sejalan dengan itu, Haris (2024) menekankan bahwa optimalisasi pada lapisan konvolusi memungkinkan sistem untuk melakukan pemetaan fitur (*feature mapping*) yang lebih mendalam pada objek nabati, yang pada akhirnya meningkatkan efisiensi komputasi dalam pengenalan pola alami. Pemahaman tentang morfologi daun ini membantu sistem kecerdasan buatan mengenali pola visual alami tanaman tropis secara lebih akurat dan efisien.

2.2.2 Daun Pepaya (Carica Papaya)

Menurut Hawibowo (2024) dan Putra dkk. (2025), daun pepaya (*Carica papaya* L) merupakan bagian penting dari tanaman pepaya yang memiliki nilai fisiologis dan morfologis tinggi, serta berperan penting dalam proses fotosintesis dan identifikasi visual tanaman. Dalam penelitian ini, fokus utama diberikan pada jenis daun pepaya California, yang merupakan varietas pepaya yang populer di daerah tropis dengan ciri khas daun yang lebih lebar dan lobus yang lebih dalam dibandingkan varietas lainnya.

Menurut peneliti sebelumnya seperti Smith et al. (2020), daun pepaya California memiliki bentuk menjari dengan lima hingga sembilan lobus yang jelas, permukaan halus dengan tekstur sedikit berbulu di bagian bawah, dan warna hijau tua yang intens, yang membedakannya dari varietas lokal lainnya. Secara botani, daun ini memiliki panjang rata-rata 30-50 cm dan lebar 20-40 cm, dengan pola tulang daun yang simetris dan vena utama yang menonjol, sehingga memudahkan identifikasi visual.

Lebih lanjut menurut Hawibowo (2024), variasi warna dan tekstur pada daun pepaya California dapat menjadi indikator kondisi fisiologis tanaman, seperti tingkat kematangan buah atau kesehatan daun. Peneliti sebelumnya, seperti Johnson (2022), menambahkan bahwa daun pepaya California sering menunjukkan perubahan warna dari hijau muda menjadi hijau gelap seiring pertumbuhan, dengan tekstur yang lebih kasar pada daun yang terpapar sinar matahari langsung, yang dapat menandai stres lingkungan seperti kekeringan atau infeksi hama. Hal ini menjadikan daun ini sebagai subjek ideal untuk studi morfologi, karena ciri-cirinya yang konsisten memungkinkan analisis yang akurat terhadap respon tanaman terhadap faktor eksternal.

Sementara itu, Putra dkk. (2025) menekankan bahwa karakteristik visual seperti bentuk daun, pola tulang daun, dan intensitas warna hijau pada daun pepaya California dapat dijadikan fitur penting dalam proses klasifikasi citra digital menggunakan metode pembelajaran mesin seperti CNN. Menurut peneliti sebelumnya, Selain itu, daun pepaya memiliki variasi ukuran dan proporsi lobus yang dapat mempengaruhi performa model jika tidak ditangani melalui augmentasi data. Penelitian terdahulu menunjukkan bahwa CNN mampu mengekstraksi perbedaan halus pada kontur dan proporsi lobus daun pepaya, sehingga menghasilkan akurasi klasifikasi yang tinggi bahkan pada dataset terbatas (Pratama et al., 2022). Oleh karena itu, pemahaman morfologi daun pepaya California menjadi dasar penting dalam penelitian klasifikasi daun berbasis kecerdasan buatan, khususnya untuk membedakan spesies atau kondisi tanaman tropis secara akurat.



Gambar 2. 1 Daun pepaya California / Pepaya local Indonesia.

2.2.3 Daun Chaya (*Cnidioscolus aconitifolius*)

Menurut Pratiwi & Nugraha (2022) serta Kusuma dkk. (2023), tanaman chaya (*Cnidioscolus aconitifolius*) merupakan tanaman tropis yang banyak ditemukan di wilayah beriklim panas seperti Indonesia dan dikenal memiliki daun dengan kandungan gizi tinggi serta potensi sebagai bahan pangan fungsional. Dalam penelitian ini, fokus utama diberikan pada jenis daun chaya, yang merupakan varietas utama dari spesies ini dengan ciri khas daun yang lebih tebal dan berbulu halus dibandingkan tanaman tropis lainnya.

Menurut peneliti sebelumnya seperti Garcia et al. (2019), daun chaya memiliki bentuk menjari dengan lima hingga tujuh lobus, tetapi bertekstur lebih tebal dan sedikit berbulu halus pada permukaannya, dengan panjang rata-rata 20-40 cm dan lebar 15-30 cm, serta pola vena yang lebih padat dan tepi lobus yang bergerigi halus, yang membedakannya dari daun pepaya. Secara botani, daun ini memiliki warna hijau gelap yang konsisten, memudahkan identifikasi visual dan analisis morfologi.

Lebih lanjut menurut Pratiwi & Nugraha (2022), perbedaan struktur permukaan dan pola tepi daun chaya menjadi ciri morfologi yang khas dan penting dalam proses pengenalan visual berbasis citra digital. Peneliti sebelumnya, seperti Lopez (2021), menambahkan bahwa tekstur bulu halus pada daun chaya sering menunjukkan adaptasi terhadap lingkungan kering, dengan permukaan yang lebih kasar pada daun dewasa, yang dapat menjadi indikator kesehatan tanaman atau respons terhadap stres seperti kekurangan udara. Hal ini menjadikan daun chaya sebagai subjek ideal untuk studi morfologi, karena ciri-cirinya yang unik memungkinkan analisis yang akurat terhadap variasi spesies tropis.

Selain bentuk lobus, variasi ukuran dan arah tulang daun juga menjadi fitur penting untuk klasifikasi. CNN mampu menangkap perbedaan halus tersebut melalui lapisan konvolusi, sehingga model dapat membedakan daun chaya meskipun morfologi keseluruhannya mirip dengan daun pepaya (Hernandez, 2020). Dengan demikian, karakter morfologi daun chaya menjadi komponen penting dalam penelitian tahap dasar ini untuk membangun dataset dan model klasifikasi yang akurat.

Oleh karena itu, pemahaman morfologi daun chaya menjadi dasar penting dalam penelitian klasifikasi daun berbasis kecerdasan buatan, khususnya untuk membedakan spesies atau kondisi tanaman tropis secara akurat. Secara keseluruhan, integrasi pengetahuan dari peneliti sebelumnya seperti Lopez (2021) dan Garcia et al. (2019) memperkuat pentingnya daun chaya sebagai model studi, karena ciri morfologisnya yang unik mendukung aplikasi praktis dalam pertanian modern.



Gambar 2. 2 Daun Chaya (Cnidoscolus aconitifolius)

2.2.4 Daun Jarak (*Jatropha curcas*)

Daun jarak (*Jatropha curcas*) memiliki bentuk menjari (*palmate*) dengan lima lobus yang simetris dan tepi daun yang relatif rata, yang membedakannya dari daun pepaya dan daun chaya baik dari ukuran maupun bentuk lobusnya. Penelitian di Indonesia oleh **Saputra et al. (2021)** menunjukkan bahwa ciri morfologi seperti jumlah lobus, proporsi lobus, dan bentuk kontur daun jarak merupakan parameter visual yang konsisten dan informatif untuk identifikasi spesies menggunakan citra digital. Karakter morfologi ini menjadi dasar bagi model pembelajaran mesin untuk membedakan daun jarak dari spesies lain meskipun memiliki kemiripan bentuk secara umum.

Selain itu, pola tulang daun jarak yang sederhana dan simetri lobus yang jelas memudahkan ekstraksi fitur visual oleh model Convolutional Neural Network (CNN). Berdasarkan penelitian oleh **Putri & Hidayat (2022)** yang menguji klasifikasi beberapa jenis daun lokal menggunakan CNN, fitur kontur daun, terutama pola tulang dan permukaan, terbukti memegang peran penting dalam meningkatkan akurasi model. Temuan ini menunjukkan bahwa model CNN mampu mengenali pola morfologi yang berbeda secara halus, sehingga daun jarak dapat dibedakan secara efektif dari daun pepaya dan chaya dalam penelitian ini.



Gambar 2. 3 Daun Jarak (Jatropha curcas)

2.2.5 Klasifikasi Berbasis Citra Digital

Klasifikasi berbasis citra digital merupakan salah satu bidang dalam pengolahan citra (*image processing*) yang berfokus pada proses identifikasi dan pengelompokan objek berdasarkan fitur visual seperti bentuk, warna, tekstur, dan pola tepi. Proses ini dilakukan dengan mengubah citra daun menjadi representasi numerik yang dapat diolah oleh komputer. Menurut Gonzalez dan Woods (2018), pengolahan citra digital bertujuan untuk mengekstraksi informasi penting dari gambar agar dapat dianalisis secara objektif dan terukur. Dalam konteks penelitian botani, klasifikasi citra daun digunakan untuk mengenali jenis tanaman berdasarkan karakteristik morfologinya, seperti bentuk tepi daun, jumlah lobus, dan pola tulang daun.

Implementasi teknik ini telah berkembang pesat di lingkungan penelitian Institut Teknologi PLN, sebagaimana dibuktikan oleh Ristanto, Rusjdi, dan Purwanto (2020) yang menunjukkan bahwa penggunaan algoritma *Convolutional Neural Network* (CNN) sangat efektif dalam menangani kompleksitas fitur visual pada citra objek yang bervariasi. Hal ini diperkuat dalam konteks agrikultur oleh Prayitno dan Palupiningsih (2025), yang menyatakan bahwa ekstraksi fitur otomatis melalui *deep learning* pada citra daun merupakan komponen krusial dalam mendukung ekosistem *smart farming* yang presisi.

Lebih lanjut, efektivitas pengolahan citra dalam mengenali karakteristik biologis secara spesifik juga didukung oleh penelitian Rusjdi dan Sudirman (2025), yang menegaskan bahwa integrasi algoritma klasifikasi seperti CNN mampu memproses perbedaan tekstur dan pola visual secara mendalam untuk mencapai akurasi identifikasi yang tinggi pada objek nabati lokal. Dengan menggabungkan teori ekstraksi informasi citra dan perkembangan algoritma terkini, sistem dapat melakukan klasifikasi terhadap daun Pepaya, Chaya, dan Jarak secara lebih akurat berdasarkan pola morfologi unik yang dimiliki masing-masing spesies.

Secara umum, proses klasifikasi berbasis citra digital melibatkan beberapa tahapan utama:

- 1) Akuisisi Citra : pengambilan gambar daun menggunakan kamera dengan pencahayaan terkendali.
- 2) Praproses Citra (Preprocessing) : mencakup konversi warna, penghilangan noise, cropping, dan peningkatan kontras agar fitur morfologi lebih jelas.
- 3) Ekstraksi Fitur (Feature Extraction) : proses mengambil ciri penting seperti bentuk (shape), warna (color), dan tekstur (texture).
- 4) Klasifikasi (Classification) : tahap akhir di mana algoritma pembelajaran mesin seperti CNN, SVM, atau YOLO digunakan untuk mengenali dan mengelompokkan citra daun ke dalam kategori tertentu.

Menurut Zhang et al. (2021), metode berbasis *deep learning* memiliki tingkat akurasi yang lebih tinggi dibandingkan metode konvensional karena mampu melakukan ekstraksi fitur secara otomatis tanpa perlu perhitungan manual. Pada penelitian ini, digunakan metode YOLO (You Only Look Once) karena kemampuannya dalam mengklasifikasi objek daun secara cepat serta efisien dalam satu tahap pemrosesan.


Pendekatan klasifikasi citra digital sangat relevan dalam bidang pertanian dan biologi karena mampu membantu proses identifikasi tanaman secara otomatis tanpa memerlukan keahlian botani yang mendalam. Hasil penelitian Nurhadi et al. (2022) menunjukkan bahwa sistem klasifikasi daun menggunakan model CNN mencapai akurasi di atas 90% dalam mengenali spesies tanaman lokal. Dengan demikian, pengembangan sistem berbasis YOLO untuk daun jarak pagar dan pepaya Jepang diharapkan dapat mempercepat proses identifikasi morfologi dan membantu penelitian taksonomi digital.

2.2.6 Deep Learning

Menurut *Deep Learning* (DL) yang merupakan sebuah teknik berbasis jaringan saraf tiruan telah banyak digunakan dalam beberapa tahun terakhir sebagai salah satu

metode implementasi *Machine Learning* (ML). DL menggunakan beberapa lapisan (*layers*) di antara lapisan masukan (*input layer*) dan lapisan keluaran (*output layer*). Arsitektur tersebut dapat digunakan untuk melakukan pemrosesan nonlinier dengan beberapa tahap yang hasilnya dapat digunakan untuk *feature learning* dan klasifikasi pola (*pattern classification*). Jumlah lapisan dalam DL yang bervariasi dapat digunakan untuk melakukan abstraksi dengan tingkat yang berbeda-beda.

DL juga dapat dideskripsikan sebagai sebuah kelas dalam algoritme ML yang menggunakan beberapa lapisan pemrosesan nonlinier yang disusun secara *cascade* untuk ekstraksi fitur (*feature extraction*) dan *transformation*. Setiap lapisan menggunakan keluaran dari lapisan sebelumnya sebagai masukannya. Algoritme yang digunakan dapat bertipe *supervised* dan *unsupervised* serta implementasinya dapat digunakan sebagai *pattern analysis (unsupervised)* dan klasifikasi (*supervised*). Beberapa teknik dalam DL dapat dikategorikan menjadi *supervised*, *semi-supervised*, dan *unsupervised*. Kategori lain, seperti *Reinforcement Learning (RL)* atau *Deep RL (DRL)*, seringkali dikategorikan menjadi semi-supervised atau unsupervised.



Gambar 2. 4 kategori dalam Deep Learning

- 1) *Deep Supervised Learning*: Teknik *learning* yang digunakan dalam kategori ini menggunakan data yang telah diberi label sebelumnya (*labeled data*). Contoh yang populer dalam kategori ini adalah *Deep Neural Networks* (DNN), CNN, (RNN), termasuk juga LSTM, dan *Gated Recurrent Unit* (GRU).
- 2) *Deep Semi-Supervised Learning*: Zhu dan Goldberg (2009) menjelaskan bahwa *semi-supervised learning* menggabungkan sebagian data berlabel (*partially labeled data*) dengan data tanpa label untuk meningkatkan performa model. Beberapa

pendekatan *Deep Reinforcement Learning (DRL)*, *Generative Adversarial Networks (GAN)*, serta *RNN* dan turunannya seperti *LSTM* dan *GRU* juga dapat menerapkan teknik ini.

- 3) *Deep Unsupervised Learning*: Teknik *learning* ini menggunakan data yang tidak diberi label sebelumnya (*unlabeled data*). *Auto Encoders (AE)*, *Restricted Boltzmann Machines (RBM)*, dan generasi terbaru dari *GAN* menggunakan teknik *learning* ini pada implementasinya.
- 4) *Deep Reinforcement Learning*: Teknik *learning* ini digunakan pada lingkungan atau *environments* yang tidak diketahui (*unknown environments*). Pada tahun 2013, *DRL* dimulai dengan hadirnya *Google DeepMind* (Haris et al., 2021).
- 5) *Deep Semi-Supervised Learning*: *Semi-supervised learning* menggunakan teknik *learning* yang menggunakan sebagian data yang telah diberi label sebelumnya (*partially labeled data*). Pada beberapa kasus, *DRL*, *Generative Adversarial Networks (GAN)*, serta *RNN*, termasuk *LSTM*, dan *GRU* juga menggunakan teknik *learning* ini.

2.2.7 Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) adalah algoritma deep learning yang dirancang untuk memproses data gambar, dengan mengidentifikasi kepentingan (bobot dan bias yang dapat dipelajari) pada berbagai elemen dalam gambar untuk membedakan antara objek satu dengan objek lainnya. CNN adalah jenis arsitektur neural network yang khusus digunakan untuk data gambar. Meskipun CNN mirip dengan neural network pada umumnya, CNN memiliki dua lapisan utama dalam arsitekturnya, yaitu lapisan pembelajaran fitur (feature learning) dan lapisan klasifikasi (classification layer).

Efektivitas arsitektur ini dalam mengenali pola visual telah dibuktikan dalam berbagai penelitian di Institut Teknologi PLN. Ristanto, Rusjdi, dan Purwanto (2020) menegaskan bahwa kekuatan utama CNN terletak pada kemampuannya mengekstraksi fitur secara otomatis dari objek yang memiliki variasi visual tinggi, yang sangat krusial dalam proses identifikasi citra digital. Dalam "CNN menjadi metode yang paling umum dan efektif dalam pengenalan gambar untuk sejak tahun 1980-an, karena kemampuan yang baik dalam mengidentifikasi dan mengklasifikasikan pola gambar yang kompleks dan divergen" (Goodfellow, Bengio, & Courville, 2016).

Selain itu, Prayitno dan Palupiningsih (2025) menyatakan bahwa implementasi CNN pada data tanaman memungkinkan pengenalan karakteristik biologis yang lebih presisi melalui pemrosesan lapisan konvolusi yang mendalam. Hal ini sejalan dengan pandangan Rusjdi dan Sudirman (2025) yang mengemukakan bahwa integrasi CNN mampu meningkatkan akurasi klasifikasi secara signifikan, terutama ketika dihadapkan pada data citra yang memiliki kemiripan tekstur dan bentuk yang rapat.

Custom Convolutional Neural Network (Custom CNN) adalah arsitektur CNN yang dirancang secara mandiri oleh peneliti untuk menyesuaikan struktur jaringan dengan karakteristik data yang digunakan. Pendekatan ini memberikan fleksibilitas dalam menentukan jumlah lapisan konvolusi, jumlah filter, dan konfigurasi lapisan klasifikasi, sehingga model dapat dioptimalkan secara spesifik untuk pola visual tertentu. Menurut Zhang, Zhou, dan Lin (2018), penggunaan CNN kustom memungkinkan proses ekstraksi fitur menjadi lebih efisien dan adaptif, terutama pada dataset berukuran kecil hingga menengah. Dalam penelitian ini, Custom CNN dipilih karena mampu menyesuaikan proses pengenalan fitur terhadap citra daun pepaya, daun chaya, dan daun jarak secara lebih tepat dibandingkan model pretrained yang memiliki struktur tetap.

"Salah satu kekuatan dari CNN adalah kemampuan untuk mengurangi jumlah parameter yang perlu dihitung, sehingga dapat meminimalkan jumlah data yang perlu disimpan dalam komputer, dan dapat mempercepat proses pelatihan" (Zhang, Zhou, & Lin, 2018). Dengan demikian, penggunaan CNN dalam klasifikasi daun Pepaya, Chaya, dan Jarak menjadi solusi yang efisien untuk mendapatkan hasil identifikasi yang akurat dengan beban komputasi yang optimal.

Pada lapisan klasifikasi, terdapat beberapa lapisan yang terdiri dari neuron- neuron yang saling terhubung secara penuh (*fully connected*) dengan lapisan lainnya. Lapisan ini menerima input dari output layer di tahap *feature learning*, yang kemudian diproses melalui tahap *flatten* dan beberapa *hidden layer* dalam *fully connected layer* hingga menghasilkan output berupa akurasi klasifikasi untuk setiap kelas. Proses klasifikasi melibatkan tiga langkah utama, yaitu:

- 1) *Flatten* adalah lapisan yang mengubah output dari layer konvolusi menjadi sebuah vektor fitur dalam bentuk satu kolom, yang kemudian digunakan pada

layer yang saling terhubung secara penuh (fully connected layer).

- 2) *Fully connected layer* adalah lapisan yang mirip dengan *Artificial Neural Network (ANN)*, berfungsi untuk melakukan proses klasifikasi.
- 3) *Softmax* adalah lapisan yang digunakan untuk menghitung nilai probabilitas dari setiap kelas, di mana kelas dengan probabilitas tertinggi akan menjadi *output prediksi*. Proses ini adalah operasi yang umum diterapkan dalam berbagai model *CNN*.

Adapun bagian dari lapisan arsitektur *CNN* dijelaskan sebagai berikut:

Tabel 2. 1 Algoritma CNN


Algoritma Proses <i>CNN</i>	Lapisan <i>CNN</i>
<i>Feature Learning Classification</i>	<i>a. Input Layer</i> <i>b. Convolution Layer</i> <i>c. Activation Layer</i> <i>d. Pooling Layer</i> <i>e. Fully Connected Layer</i> <i>f. Output Layer</i>

A. Input Layer

Lapisan ini berguna untuk menampung *pixel value* dari citra yang diinputkan. Citra batik tanah liat yang telah diinputkan memiliki 3 channel warna RGB (*Red, Green, Blue*).

B. Convolutional Layer

Convolutional layer terdiri dari neuron yang disusun dalam bentuk filter dengan ukuran panjang dan tinggi (piksel). Proses konvolusi melibatkan penggunaan kernel dan stride, yaitu proses kombinasi antara dua matriks berbeda untuk menghasilkan matriks baru. Dalam pengolahan citra, konvolusi berarti menerapkan sebuah kernel (misalnya kotak kuning) pada citra di berbagai posisi offset yang memungkinkan, seperti yang diilustrasikan dalam gambar 2.5 berikut




Gambar 2. 5 Operasi pixel

Kotak hijau mewakili gambar yang akan mengalami konvolusi secara keseluruhan. Kernel akan bergerak mulai dari sudut kiri atas menuju sudut kanan bawah. dari proses konvolusi pada data gambar adalah untuk mengekstraksi fitur dari gambar input.

C. Activation layer

Pada lapisan ini, nilai-nilai dari feature map diubah berdasarkan jarak tertentu menggunakan fungsi aktivasi, yaitu ReLU (Rectified Linear Unit). Fungsi ReLU pada dasarnya melakukan "thresholding" dari 0 hingga tak terhingga, menjadikannya salah satu fungsi aktivasi yang paling populer saat ini.

D. Pooling Layer




Gambar 2. 6 Max-Pooling

Lapisan *pooling* berfungsi untuk mengurangi ukuran setiap tumpukan *feature map*. Biasanya, lapisan pooling menggunakan filter berukuran 2x2 yang diaplikasikan dengan langkah dua, dan beroperasi pada setiap bagian dari input. Berikut ini adalah contoh gambar dari proses *max pooling*: Kotak berwarna merah, hijau, kuning, dan biru di sisi kiri mewakili kelompok kotak yang akan diambil nilai maksimum dari setiap kelompok. Hasil

dari proses ini dapat dilihat pada kotak-kotak di sisi kanan.

E. Fully connected layer

Lapisan Fully-connected, atau yang sering disebut dense layer, adalah lapisan di mana setiap neuron dari lapisan sebelumnya terhubung sepenuhnya dengan semua neuron di lapisan berikutnya, mirip dengan struktur pada jaringan syaraf tiruan.



Gambar 2. 7 Fully connected layer

F. OutputLayer

Setelah itu, proses klasifikasi dilakukan dengan bantuan fungsi aktivasi softmax, yang akan mengklasifikasikan input sesuai dengan kategori targetnya, yaitu empat kelas batik tanah liat seperti rumah gadang, rangkiang, kabau padati, dan burung hong (Azmi et al., n.d.).

2.2.8 Roboflow

Roboflow merupakan platform berbasis cloud yang digunakan untuk mengelola dataset citra pada penelitian visi komputer, termasuk klasifikasi daun menggunakan metode Convolutional Neural Network (CNN). Platform ini mempermudah proses anotasi, preprocessing, dan augmentasi sehingga dataset memiliki kualitas yang konsisten sebelum digunakan untuk pelatihan model. Menurut Hidayat dan Sari (2021), Roboflow dapat meningkatkan efisiensi dalam pengolahan dataset karena mendukung berbagai format citra yang sesuai untuk model CNN, seperti folder-class format dan TFRecord. Hal ini menjadikan Roboflow alat yang sangat membantu dalam penelitian klasifikasi objek biologis di tahap dasar.

Dalam implementasi penelitian ini, Roboflow digunakan untuk melakukan anotasi citra daun pepaya, daun chaya, dan daun jarak untuk keperluan klasifikasi. Proses preprocessing seperti *resize*, *cropping*, dan normalisasi dilakukan agar citra memiliki ukuran dan kualitas yang

seragam. Selain itu, teknik augmentasi seperti rotasi, flipping, dan penyesuaian kecerahan diterapkan dengan tujuan memperkaya variasi visual pada dataset. Penelitian oleh Putra et al. (2022) menunjukkan bahwa augmentasi data pada klasifikasi daun tropis dengan CNN dapat meningkatkan kemampuan generalisasi model dan mengurangi risiko overfitting, terutama ketika dataset awal masih terbatas.

Penggunaan Roboflow dalam penelitian klasifikasi daun telah diterapkan dalam beberapa studi di Indonesia. Rahmawati dan Nugroho (2023) berhasil memanfaatkan Roboflow untuk mengelola dataset daun tanaman lokal dan melaporkan peningkatan akurasi model CNN setelah menerapkan augmentasi yang tepat. Studi lain oleh Andika (2021) pada klasifikasi daun jati menggunakan CNN juga menunjukkan bahwa kualitas preprocessing dan anotasi yang baik—yang difasilitasi oleh Roboflow berpengaruh langsung terhadap akurasi model. Dengan demikian, Roboflow bukan hanya membantu dalam pengelolaan dataset, tetapi juga mempercepat alur penelitian berbasis CNN secara keseluruhan.

Dengan fitur seperti *version control*, *dataset management*, dan integrasi mudah ke Google Colab, Roboflow berperan sebagai alat penting dalam penelitian tahap dasar berbasis CNN. Platform ini memberikan dukungan menyeluruh dalam proses persiapan data, yang pada akhirnya berkontribusi pada peningkatan performa model klasifikasi daun pada penelitian ini.

2.2.9 Google Colab

Google Colab (Google Collaboratory) adalah layanan berbasis cloud yang dikembangkan oleh Google untuk mendukung pengembangan proyek data science dan machine learning. Colab menyediakan lingkungan berbasis notebook seperti Jupyter Notebook, yang memungkinkan pengguna untuk menulis dan menjalankan kode Python langsung di browser. Salah satu keunggulan utama Google Colab adalah penyediaan sumber daya komputasi seperti GPU dan TPU secara gratis, sehingga sangat membantu dalam pelatihan model yang membutuhkan komputasi tinggi, seperti CNN (Smith & Lee, 2022).

Colab mempermudah integrasi dengan berbagai layanan cloud, seperti Google Drive dan API pihak ketiga, yang memungkinkan akses langsung ke dataset dan model. Dalam konteks penelitian berbasis machine learning, Google Colab digunakan untuk mengunduh dataset, melatih model, dan mengevaluasi kinerja model. Selain itu, Google Colab mendukung kolaborasi langsung, memungkinkan beberapa pengguna untuk bekerja pada notebook yang sama secara real-time (Patel & Gupta, 2023).

Kemampuan *Google Colab* untuk mendukung pelatihan model secara efisien sangat penting dalam penelitian ini. Dengan memanfaatkan GPU yang tersedia, Colab mempercepat proses pelatihan model CNN pada dataset besar. Selain itu, Colab mendukung berbagai pustaka Python, seperti TensorFlow, PyTorch, dan Ultralytics, yang digunakan untuk membangun, melatih, dan mengevaluasi model. Proses pelatihan dapat dilakukan secara iteratif, dengan output seperti metrik evaluasi (precision, recall, mAP) dan model terbaik yang disimpan di folder runs (Rajput et al., 2023).

Salah satu keunggulan lainnya adalah *Google Colab* menyediakan lingkungan yang fleksibel untuk mengakses dataset melalui API pihak ketiga, seperti Roboflow. Dengan menggunakan API ini, dataset dapat diunduh dan langsung digunakan dalam pelatihan model tanpa perlu menyimpan file secara lokal. Hal ini mempercepat alur kerja penelitian dan mempermudah pengelolaan dataset (Kumar & Sharma, 2023).

2.2.10 Web Kamera

Webcam adalah perangkat keras yang digunakan untuk mengambil gambar dan merekam video. Mereka memiliki banyak kegunaan, terutama dalam aplikasi pengenalan jenis daun, yang dapat digunakan untuk mengidentifikasi jenis daun, dengan benar hingga 99,6%. Selain itu, kamera dan webcam juga dapat digunakan untuk tujuan lain, seperti mengambil foto atau merekam video sesuai dengan kebutuhan.

Dalam konteks aplikasi Android, kamera ponsel pintar atau webcam eksternal dapat diintegrasikan dengan aplikasi untuk mengambil gambar atau merekam video. Selain itu, kamera ponsel juga dapat digunakan untuk mengambil input wajah untuk proses verifikasi dan identifikasi. Hal ini dapat dilakukan dengan menggunakan beberapa library pengolahan citra, seperti OpenCV, yang dapat digunakan untuk mengolah data input wajah dari kamera ponsel dan memanipulasi data tersebut sesuai kebutuhan.

Dengan menggunakan beberapa *library* pengolahan citra, seperti OpenCV, kamera ponsel dapat digunakan untuk mengolah data input wajah dari kamera ponsel dan memanipulasi data tersebut sesuai kebutuhan. Hal ini menjadi sangat mudah dilakukan karena banyaknya dokumentasi dan tutorial yang tersedia" (Jones, 2019).


2.2.11 CRISP-DM

CRISP-DM (*Cross-Industry Standard Process for Data Mining*) adalah sebuah standar proses yang banyak digunakan di bidang *data mining*. Metodologi ini pertama kali diperkenalkan pada tahun 1996 oleh konsorsium yang terdiri dari kalangan industri dan

akademisi, dengan tujuan menyediakan kerangka kerja yang sistematis untuk melaksanakan proyek *data mining*. Secara struktural, metodologi ini terdiri dari enam tahapan siklus hidup, yaitu: *Business Understanding*, *Data Understanding*, *Data Preparation*, *Modeling*, *Evaluation*, dan *Deployment*.

Dalam perkembangannya, kerangka kerja ini tetap relevan digunakan dalam riset berbasis kecerdasan buatan masa kini. Menurut Haris (2024), integrasi arsitektur *Deep Learning* ke dalam metodologi CRISP-DM memberikan struktur yang lebih terukur, terutama pada fase *Modeling* dan *Evaluation*. Beliau menekankan bahwa dalam riset *Data Science* modern, CRISP-DM bukan sekadar urutan kerja, melainkan sebuah proses iteratif di mana hasil evaluasi model seringkali mengharuskan peneliti untuk kembali ke tahap *Data Preparation* guna melakukan augmentasi data atau pembersihan label citra demi mencapai performa model yang optimal.

Lebih lanjut, Menurut Haris (2024) menyatakan bahwa penerapan standar ini dalam penelitian pengolahan citra memungkinkan peneliti untuk melakukan pemetaan masalah (*Business Understanding*) secara lebih tajam, sehingga arsitektur model yang dipilih seperti CNN atau YOLO benar-benar selaras dengan karakteristik data biologis yang dihadapi. Dengan demikian, penggunaan CRISP-DM dalam klasifikasi daun Pepaya dan Jarak ini menjamin bahwa setiap tahapan eksperimen dilakukan secara terdokumentasi dan memiliki akuntabilitas ilmiah yang kuat di lingkungan riset informatika.



Gambar 2. 8 Metode CRISP-DM

Model ini mencakup enam tahapan utama yang bersifat iteratif, artinya setiap langkah memungkinkan untuk kembali ke fase sebelumnya jika diperlukan. Keenam tahap meliputi :

1) Pemahaman Data (Data Understanding)

Pada tahap ini dilakukan pengumpulan serta pemeriksaan data untuk memperoleh gambaran awal. Aktivitasnya meliputi identifikasi atribut penting, eksplorasi data, hingga menemukan potensi permasalahan kualitas data.

2) Persiapan Data (Data Preparation)

Tahap ini mencakup pembersihan dan pengolahan data agar siap digunakan pada proses pemodelan. Prosesnya meliputi seleksi atribut, penggabungan, transformasi, serta penanganan data yang tidak lengkap.

3) Pemodelan (Modeling)

Di bagian ini, diterapkan berbagai metode analisis guna membangun model yang sesuai untuk menyelesaikan permasalahan. Pemilihan algoritma, pengaturan parameter, dan pelatihan model merupakan inti dari tahap ini.

4) Evaluasi (Ecaluation)


Setelah model dikembangkan, langkah berikutnya adalah menilai kinerjanya dengan mengacu pada tujuan bisnis. Apabila hasilnya belum optimal, maka dilakukan perbaikan dengan kembali ke tahap sebelumnya.

5) Penerapan (Deployment)

Tahap terakhir berhubungan dengan implementasi model ke dalam dunia nyata. Hasil analisis dapat diwujudkan dalam bentuk laporan, sistem otomatis, ataupun integrasi ke aplikasi perusahaan untuk mendukung pengambilan Keputusan.

2.3 Kerangka Pemikiran

Berikut adalah kerangka pemikiran yang disusun untuk menggambarkan langkah-langkah proses analisis data dari awal hingga akhir, dengan tujuan untuk mendapatkan kesimpulan dari data yang sedang dianalisis. Selanjutnya, Pada Gambar di atas menunjukkan kerangka pemikiran untuk metodologi penelitian ini. Komponen dalam kerangka penelitian berhubungan satu sama lain. Berikut ini adalah penjelasan tentang komponen tersebut.



Gambar 2. 9 Kerangka Pemikiran

1) Indicators (Data Image)

Data citra daun pepaya, daun chaya, dan daun jarak dikumpulkan sebagai sumber utama penelitian. Setiap citra mewakili variasi bentuk, tekstur, dan morfologi daun yang menjadi dasar proses klasifikasi. Dataset ini digunakan untuk pelatihan, validasi, dan pengujian model CNN.

2) Method Method (Convolutional Neural Network – CNN)

CNN diterapkan sebagai metode utama untuk mengekstraksi fitur visual dari citra daun secara otomatis. Proses meliputi convolution, pooling, dan fully connected layer untuk membangun model klasifikasi. Metode ini dipilih karena kemampuannya mengenali pola citra kompleks dengan akurasi tinggi.

3) Objective

Tujuan utama penelitian adalah mengklasifikasi daun pepaya, daun chaya, dan daun jarak berdasarkan ciri morfologinya menggunakan CNN. Model dirancang untuk membedakan tiga jenis daun yang memiliki kemiripan bentuk pada beberapa bagian. Hasil klasifikasi digunakan untuk mengetahui performa model dalam identifikasi objek biologis.

4) Measurement

Evaluasi performa dilakukan menggunakan confusion matrix untuk melihat tingkat kesalahan dan keberhasilan prediksi model. Metrik precision, recall, F1-score, dan accuracy digunakan untuk menilai kualitas klasifikasi secara kuantitatif. Hasil pengukuran menggambarkan sejauh mana model CNN mampu mengenali masing-masing jenis daun secara akurat.