



## Tinjauan Penerapan CNN dan YOLO Pada Pengolahan Citra Agraria Medis Industri Cerdas

**Robby Saputra<sup>\*1</sup>, Yan Rianto<sup>2</sup>, Muhammad Romadhona Kusuma<sup>3</sup>**

Email: <sup>1</sup>14240031@nusamandiri.ac.id, <sup>2</sup>yanr001@gmail.com, <sup>3</sup>m.romadhona.kusuma@darunnajah.ac.id

<sup>1</sup>Informatika, Teknologi Informasi, Universitas Nusa Mandiri

<sup>2</sup>Informatika, Teknologi Informasi, Universitas Nusa Mandiri

<sup>3</sup>Sistem Teknologi Informasi, Sains dan Teknologi, Universitas Darunnajah

Diterima: 16 Januari 2026 | Direvisi: 24 Februari 2026 | Disetujui: 27 April 2026

©2020 Program Studi Teknik Informatika Fakultas Ilmu Komputer,  
Universitas Muhammadiyah Riau, Indonesia

### Abstrak

Pesatnya *Artificial Intelligence* (AI), khususnya *deep Learning*, dorongan transformasi signifikan dalam pengolahan citra digital pada sektor agraria, medis, dan industri cerdas. Ada dua pendekatan yang paling dominan dalam penelitian ini yaitu *Convolutional Neural Network* (CNN) untuk klasifikasi citra dan *You Only Look Once* (YOLO) untuk deteksi objek secara *real-time*. Tujuan dari penelitian ini untuk meninjau secara sistematis penerapan, kinerja, serta tantangan penggunaan CNN dan YOLO pada berbagai domain dengan karakteristik data yang beda. Metode yang digunakan adalah *Systematic Literatur Review* (SLR) terhadap publikasi ilmiah terkini yang relevan, fokusnya pada metrik evaluasi seperti akurasi, presisi, recall, *F1-score*, dan *Mean Average Precision* (mAP). Hasil tinjau menunjukkan bahwa CNN unggul pada tugas klasifikasi citra dengan tingkat akurasi tinggi, terutama pada data yang pola visualnya relatif stabil, sedangkan YOLO lebih efektif pada aplikasi yang menuntut kecepatan inferensi dan deteksi objek secara langsung. Tapi, ditemukan beberapa keterbatasan utama, antara lain penurunan performa pada kondisi pencahayaan ekstrem, latar belakang kompleks, objek berukuran kecil, serta kemiripan visual antar kelas. Disimpulkan bahwa pemilihan arsitektur harus disesuaikan dengan karakteristik data dan kebutuhan aplikasi.

**Kata kunci:** *convolutional neural network, yolo pengolahan citra, deep learning, industri cerdas*

## *A Review of the Application of CNN and YOLO in Smart Industrial Medical Agrarian Image Processing*

### Abstract

*The Rapid growth of Artificial Intelligence (AI), particularly Deep Learning, is driving significant transformations in digital image processing in the agricultural, medical, and smart industrial sectors. Two approaches are most dominant in this research Convolutional Neural Network (CNN) for image classification and You Only Look Once (YOLO) for real-time object detection. The purpose of this reasearch is to systematically review the application, performance, and defense of CNN and YOLO in various domains with different data characteristics. The method used is a Systematic Literatur Review (SLR) of the latest relevant scientific publications, focusing on evaluation matrices such as accuracy, pression, recall, F1-score, and Mean Average Precision (mAP). The review results show that CNN excels in image classification tasks with a high level of accuracy, especially on data with relatively stabel visual patterns, while YOLO is more effective in applications that demand inference speed and direct object detection. However, several major limitations were found, including decreased performance in extreme lighting conditions, complex backgrounds, small objects, and visual similarity between classes. It is concluded that the choice of architecture must be adjusted to the characteristics of the data and application needs,*

**Keywords:** *convolutional neural network, yolo, image processing, deep learning, smart industry*

## 1. PENDAHULUAN

Pertumbuhan teknologi informasi serta kecerdasan buatan (*Artificial Intelligence*) telah membawa perubahan signifikan dalam metode pengolahan citra digital, berubah dari pendekatan konvensional menuju otomatisasi cerdas[1]. Salah satunya cabang dari perkembangan ini adalah *Deep Learning*, yang menggunakan jaringan saraf tiruan berlapis banyak untuk mempelajari representasi datanya untuk tingkat abstraksi tinggi[2]. Metode ini, khususnya *Convolutional Neural Network (CNN)*, telah menjadi standar dalam visi komputer karena kemampuannya melakukan ekstraksi fitur secara otomatis dari citra mentah tidak perlu untuk intervensi manual rumit[3]. Kemampuan ini begitu krusial demi mengatasi tantangan pengolahan citra di dunia nyata seringkali memiliki variasi tinggi, begitu perbedaan pencahayaan, di posisi objek dan noise latar belakang[4].

Studi literatur dilakukan di penelitian bertujuan untuk mendapatkan informasi serta pengetahuan yang relevan dengan fokus penelitian[5]. Tinjauan Berbagai literatur menunjukkan bahwa arsitektur CNN dan pengembangannya, seperti *You Only Look One (YOLO)*, telah dilakukan secara meluas untuk lintas disiplin ilmu. Pada sektor agraria, teknologi ini digunakan untuk mendeteksi penyakit pada daun jagung[6], daun tomat [7], tanaman kentang[8], paprika paprika[9], lalu untuk menentukan kualitas komoditas laut seperti udang serta rumput laut[10],[11]. Di bidang lain seperti medis, algoritma ini membantu diagnosis melalui segmentasi citra panoramik gigi[12] serta indentifikasi stroke iskemik pada hasil *CT Scan* [13]. Lalu dalam konteks industri cerdas, YOLO banyak dimanfaatkan karena kecepatan deteksinya yang *real-time*, mulai dari deteksi cacat produk garmen[14], pemetaan kerusakan jalan[15],[13], validasi keaslian uang kertas [16], hingga sistem keamanan berbasis pengenalan wajah[1],[17].

Alasan penelitian ini meskipun banyak studi telah membuktikan keandalan CNN dan YOLO secara terpisah di masing-masing bidang, inspeksi manual yang subjektif, lambat, dan rentan kesalahan masih ada di lapangan [6]. Namun, terdapat kebutuhan mendesak untuk pahami bagaimana satu jenis arsitektur *deep learning* dapat beradaptasi dengan karakteristik data yang sangat berbeda, mulai dari tekstur organik pada tanaman hingga pola geometris pada infrastruktur kota[13]. Penelitian ini ditulis untuk memadukan perkembangan terkini dari penerapan kedua algoritma tersebut, untuk dapat memetakan kekuatan serta tantangan implementasinya dalam mengganti sistem manual di sektor yang beragam.

Penelitian ini bertujuan untuk mengetahui bagaimana perbandingan kinerja dan efektivitas penerapan arsitektur CNN dan YOLO dalam klasifikasi dan deteksi objek pada citra digital di sektor agraria, medis, dan industri cerdas. Di harapkan dapat memberikan rekomendasi untuk solusi teknologi adaptif serta efisien serta mendukung modernisasi di ketiga sektor tersebut

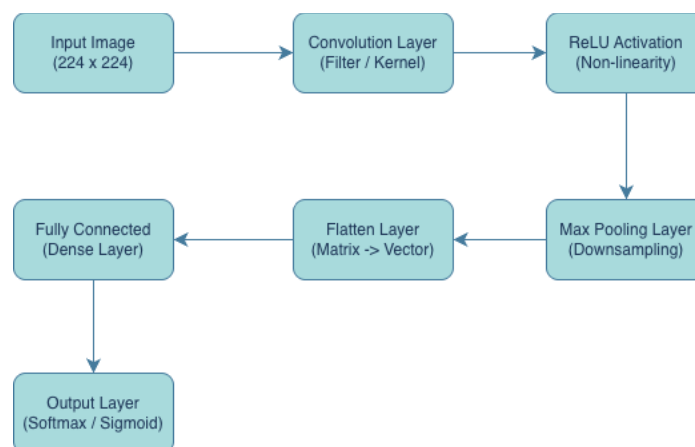
## 2. METODE PENELITIAN

Penelitian ini menggunakan pendekatan tinjauan pustaka sistematis (*Systematic Literature Review*) untuk mengidentifikasi, mengevaluasi, dan menginterpretasi penelitian yang relevan terakait penerapan algoritma *Deep Learning*, khususnya *Convolutional Neural Network (CNN)* dan *You Look Once (YOLO)*

### 2.1 Diagram dan Arsitektur Model

#### a. Arsitektur *Convolutional Neural Network (CNN)*

Digunakan untuk penelitian seperti penyakit jagung, klasifikasi apel, dan deteksi masker

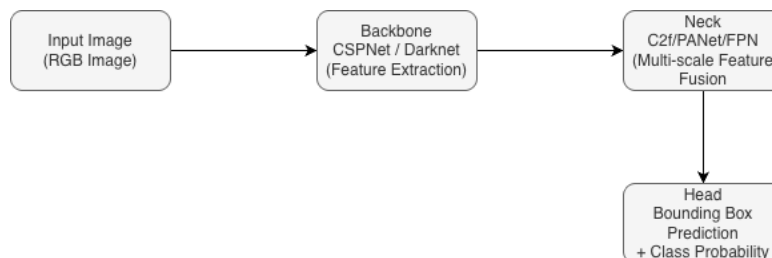


Gambar 1. Diagram CNN

Berdasarkan gambar CNN pada gambar 1 terlihat ada beberapa langkah yaitu *Input* layar untuk menerima citra mentah (contohnya ukuran 224x224)[18],[6]. *Convolution Layer* untuk lakukan operasi konvolusi dengan filter/kernel untuk mengekstrak fitur[18], *Activation Function* (ReLU) setiap operasi konvolusi, fungsi ReLU dipakai secara langsung[18], *Pooling Layer* (*Max Pooling*) untuk mengurangi dimensi spesial data[18], *Flatten Layer* untuk mengubah data matriks jadi vektor dimensi satu[18], *Fully Connected* (*Dense Layer*) untuk lapisan jaringan saraf tiruan penuh[18], *Output Layer* (*Softmax / Sigmoid*) hasilkan probabilitas kelas (contohnya sehat vs sakit)[1]

b. Arsitektur YOLO (*You Only Look Once*)

pada penelitian ini ada YOLOv8 untuk trikoma kentang dan gigi Panoramik dan YOLOv4 untuk kerusakan jalan



Gambar 2. Diagram YOLO

Terlihat diagram YOLO lebih sedikit prosesnya ketimbang dari proses CNN, langkah-langkahnya adalah *Backbone* yaitu digunakan untuk *Cross Partial Network* (CSP) sebagai ekstraksi fitur yang efisien[8], *Neck* menggunakan *Cross-Stage Feature Fusion* (C2f) untuk menggabungkan fitur dari berbagai skala (*multi*) digunakan mendekteksi objek yang kecil ataupun besar[8], *Head* yaitu bagian pendeteksi yang memprediksi *bounding box* dan objek kelas[8].

2.3 Rumus

Rumus matematis yang digunakan dalam literatur untuk evaluasi kinerja dan pemrosesan citra

a. Rumus CNN Metrik Evaluasi Kinerja (*Confusion Matrix*)

Digunakan di hampir semua jurnal dalam mengukur keberhasilan model[18],[6],[19]

Akurasi (*Accuracy*): Rasio Prediksi benar terhadap total data[18],[6]

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \times 100\%$$

Presisi (*Precision*): Tingkat Kekuratan antara data diminta dengan hasil prediksi yang di berikan[18], [6]

$$Precision = \frac{TP}{TP+FP}$$

*Recall* (Sensitivitas): Tingkat keberhasilan model dama menemukan kembali informasi[18],[6]

$$Recall = \frac{TP}{TP+FN}$$

F1-Score: Rata-rata harmonik dari presisi dan *recall*[18],[6]

$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall}$$

Keterangan tambahan : TP(*True Positive*), TN(*True Negative*), FP(*False Positive*), FN(*False Negative*)

b. Rumus YOLO

*Confidence Score* (Nilai Kepercayaan): Digunakan untuk menentukan keyakinan model ke objek di *bounding box*

$$Confidence = Pr(Object) \times IOU_{Pred}^{truth}$$

IOU adalah *intersection Over Union* (irisan area prediksi dengan area sebenarnya)[8],[20]

Ukuran Tensor *Output* YOLO

$$Ukuran\ Tensor = S \times S \times (B \times 5 + C)$$

S ialah ukuran grid, B ialah jumlah *bounding box*, dan C adalah jumlah kelas[8]

#### 2.4. Hasil penelitian

Bagian ini menjelaskan ringkasan hasil eksperimen dari studi kasus yang mencakup sektor agraria, medis, industri cerdas dan industri kreatif. Setiap tabel menampilkan metrik evaluasi yang digunakan pada pendekatan dan domain penelitian

Tabel 1. Hasil Klasifikasi Penyakit Daun (Studi Kasus Agraria – jagung)[3]

No	Kelas Penyakit	Terdeksi benar	Terdeteksi salah
1	Bercak Daun	8	2
2	Daun Sehat	10	0
3	Hawar Daun	9	1
4	Karat Daun	10	0

Keterangan: Tabel ini menampilkan performa model klasifikasi CNN dalam mendeteksi empat kelas kondisi jagung. Pada daun sehat dan karat daun memiliki tingkat deteksi benar yang tinggi

Tabel 2. Peforma Model Deteksi Trikona Daun Kentang (Studi Kasus Agraria)[8]

No	Parameter	Jumlah
1	<i>True Positive (TAPI)</i>	278
2	<i>False Positive (FP)</i>	3
3	<i>False Negative (FN)</i>	53
4	<i>Precision</i>	98%
5	<i>Recall</i>	83,9%

Keterangan: Bahwa YOLO memiliki tingkan presisi yang sangat tinggi, meskipun nilai *recall* masih dapat ditingkatkan untuk mengurangi jumlah objek

Tabel 3. Evaluasi Model Segmentasi Gigi (Studi Kasus Medis)[12]

No	Metrik Evaluasi	Nilai (%)
1	mAP ( <i>mean Average Precision</i> )	95,8
2	<i>Precision</i>	93,7
3	<i>Recall</i>	93,1

Keterangan: Menandakan kemampuan model dalam mendekteksi dan memisahkan objek gigi secara akurat dengan nilai mAP diatas 95%

Tabel 4. Kategori Kerusakan Jalan (Studi Kasus Industri Cerdas / Infrastruktur)[13]

No	Tipe Kerusakan	Detail Kerusakan	Kode
1	Retak <i>Linear Longitudinal</i>	Bekas roda kendaraan	D00
2	Retak <i>Linear Longitudinal</i>	Sambungan konstruksi	D01
3	Retak <i>Linear Lateral</i>	Interval sama	D10
4	Retak Buaya	Parsial dan menyeluruh	D20
5	Kerusakan lain	Benjolan dan lubang	D40

Keterangan: Digunakan sebagai acuan sistem deteksi kerusakan jalan berbasis YOLO untuk mendukung pemeliharaan infrastuktur secara otomatis

Tabel 5. Nilai Data Test pada Model Layered CNN (Studi Kasus Agraria)

No	Kelas	Precision	Recall	F1-Score	Support
1	A-SCAB( <i>Apple scab</i> )	1.00	0.92	0.96	51
2	P-LBT ( <i>Potato Late Blight</i> )	0.96	0.94	0.95	49
3	T-HLTH ( <i>Tomato Healthy</i> )	1.00	1.00	1.00	49
4	T-LM ( <i>Tomato Leaf Mold</i> )	0.98	1.00	0.99	47
5	A-ROT ( <i>Apple Black Rot</i> )	0.92	0.92	0.92	50
6	Accuracy			0.95	1175
7	Macro Avg	0.95	0.95	0.95	1175
8	Weighted Avg	0.95	0.95	0.95	1175

Keterangan: menunjukkan bahwa model LCNN memiliki kinerja sangat baik dengan akurasi keseluruhan mencapai 95% dalam klasifikasi 25 kelas

### 3. HASIL DAN PEMBAHASAN

Bagian ini menguraikan analisis komparatif penerapan metode *Deep Learning* pada tiga sektor utama yaitu : Agraria, Medis, dan industri cerdas. Tinjauan ini menyoroti evolusi penggunaan arsitektur *Convolutional Neural Network* (CNN) konvensional menuju model deteksi objek satu seperti YOLO (*You Only Look Once*) dan model segmentasi instan.

#### 3.1. Sektor Agraria

Sektor agraria menghadapi tantangan berupa variasi bentuk, warna, dan tekstur objek biologis yang tinggi. Berdasarkan studi ini, metode *deep learning* terbukti efektif dalam menangani kompleksitas yang ada.

##### a. Metode dan Tugas Pengolahan Citra

Mayoritas penelitian pada studi ini menggunakan CNN untuk tugas klasifikasinya dan YOLO untuk deteksi objeknya. Pada klasifikasi penyakit tanaman, arsitektur CNN (MobileNET, ResNet, atau model kostum) digunakan untuk membedakan daun sehat dan sakit pada tanaman jagung dan paprika dengan akurasi tinggi [6],[9]. Tapi, untuk tugas yang lebih kompleks seperti deteksi tingkat kematangan buah, algoritma terbaru YOLO11 diterapkan untuk mengklasifikasikan fase empat kematangan secara *real-time* [21]. CNN juga digunakan mengklasifikasikan keberadaan lilin pada buah apel [22].

##### b. Dataset dan Karakteristik

Data didominasi oleh citra makro daun dan buah. Tantangan utama adalah kemiripan visual antar kelas penyakit, seperti pada kasus penyakit *late blight* pada kentang mirip dengan *early blight* [18]. Di perikanan, variasi latar belakang dan pencahayaan menjadi isu kritis dalam deteksi kesegaran ikan beku[23].

##### c. Kelebihan dan Keterbatasan

Kelebihan utama di metode ini yaitu mampu ekstraksi fitur otomatis yang mengurangi bias inspeksi manual. Model YOLO11, capai presisi 97,5% pada mangga[21]. Selain itu, penelitian dilakukan Ayu menggunakan model *Convolutional Neural Network* (CNN) untuk mendiagnosa daun mangga, menunjukkan hasil begitu menjanjikan namun terbatas pada jenis daun tertentu[24].

#### 3.2. Sektor Medis

Untuk *Deep learning* penerapan di sektor medisnya adalah menuntut standar akurasi dan *recall* (sensitivitas yang sangat tinggi untuk menghindari kesalahan diagnosis (*false negative*)).

##### a. Metode dan Tugas Pengelolaan Citra

CNN serta variasi (MobileNetV2) banyak digunakan untuk klasifikasi biner, seperti pada identifikasi stroke iskemik dari citra *CT scan*[19]. Untuk tugas yang membutuhkan detail geometris, seperti pemisahan objek gigi dari gusi pada citra panoramik, algoritma YOLOv8 digunakan untuk tugas segmentasi instan (*instance segmentation*) [12]. Selain itu, Mask R-CNN dieksplorasi untuk deteksi penyakit kulit akibat jamur kamera kemampuannya memisahkan area lesi dari kulit sehat secara piksel [20].

##### b. Dataset dan Karakteristik

Data medis memiliki karakteristik *noise* yang tinggi dan kontras yang rendah (semisal di *CT scan* atau *X-Ray*). Kajian pustaka menunjukkan bahwa U-Net dan turunannya sering menjadi standar untuk segmentasi medis karena arsitekturnya yang efisien dalam menangkap konteks dan *global* [25].

##### c. Kelebihan dan keterbatasan

Keunggulan utama ialah efisiensi waktu diagnosis. Model YOLOv8 pada segmentasi gigi capai mAP 95,8%, sangat membantu dokter gigi untuk cepat dalam identifikasi[12]. Tetapi, keterbatasan terlihat pada ketidakseimbangan data (*imbalance* dataset) dan kesulitan model mendeteksi objek dengan anomali bentuk, seperti gigi yang hanya tersisa akar atau posisi gigi miring[12].

### 3.3. Industri Cerdas

Sektor industri cerdas dan keamanan berfokus pada kecepatan inferensi (*real-time*) dan ketahanan model terhadap lingkungan yang tidak terkontrol

#### a. Metode dan Pengelolaan Citra

Berdasarkan literatur yang telah dilakukan YOLO mendominasi sektor ini karena cepat. YOLOv11 digunakan untuk mendeteksi cacat pada produk garmen (*rok A-Line*) [14]. Untuk YOLOv7 digunakan sebagai deteksi masker wajah[26]. Dalam biometrik wajah, CNN, FaceNet, dan ArcFace dibandingkan, di mana CNN unggul dalam variasi pencahayaan, FaceNet dalam sistem absensi, dan ArcFace pada dataset besar [17][1]. Untuk infrastruktur, Mask R-CNN digunakan untuk memodelkan bangunan 3D dari foto udara UAV[27], dan YOLOv4-Tiny digunakan untuk mendeteksi kerusakan di jalan[13]

#### b. Dataset dan Karakteristik

Data industri seringkali diambil dalam kondisi lingkungan yang dinamis (CCTV, *drone*, kamera industri). Hal ini menuntut model yang *robust* terhadap perubahan sudut pandang dan pencahayaan. Pada validasi uang rupiah, dataset mencakup citra di bawah sinar UB untuk fitur tak kasat mata[16].

#### c. Kelebihan dan Keterbatasan

Penerapan YOLO dan Mask R-CNN mampu memangkas biaya operasional, seperti pada pemetaan bangunan yang menghemat biaya hingga 13% dibanding cara manual[27]. Tantangan muncul pada deteksi objek kecil atau samar, seperti noda tipis di kain[14] dan juga pada saat deteksi retakan jalan dengan latar belakang kompleks yang menurunkan akurasi[13].

### 3.4. Research Gap

Tabel 6. Perbandingan Literatur Penerapan *Deep Learning* dengan metode yang berbeda-beda

Penulis & Tahun	Metode	Sektor	Jenis Tugas	Dataset	Metrik Evaluasi	Temuan Utama	Keterbatasan
Mimi Nurhidayanti, 2025[1]	CNN	Industri Keamanan	Klasifikasi	Wajah (Lokal & Publik)	Akurasi 99.84%	CNN unggul pada variasi cahaya, FaceNet 100% pada absensi	Performa turun pada rotasi wajah ekstrem
Faqih & Avianto, 2020 [18]	CNN Kustom (DFE dan LCNN)	Agraria	Klasifikasi	Daun Solanaceae & Rosaceae	Akurasi 95%	LCNN mengungguli IceptionV3 dan DFE	Kesulitan membedakan <i>late blight</i> vs sehat pada kentang
Aziz , Novamizanti, Suryo 2025[23]	YOLOv8	Agraria Perikanan	Deteksi Objek	Ikan Cakalang beku	mAP 94.7%	Efektif mendeteksi kesegaran ikan beku	Hanya fokus pada satu jenis ikan cakalang
Siti,Rangga, Evita, 2023[9]	CNN Sequential	Agraria	Klasifikasi	Daun Paprika	Akurasi 99%	Sangat akurat membedakan daun sehat vs sakit	Belum diuji pada dataset dengan <i>noise</i> tinggi
Ade&Billy, 2025[17]	CNN,FaceNet, ArcFace	Industri Keamanan	Pengenalan Wajah	Review Literatur	Akurasi 91-100%	ArcFace unggul di dataset besar, CNN di pencahayaan	Kinerja FaceNet bergantung pada jarak kamera
Misbahuddin, Septa, Slamet, Yahya, & shilvy, 2025[27]	Mask R-CNN (ResNet101)	Industri Infrastruktur	Segmentasi Instan	Foto Udara UAV	Presisi 0.794	Menghemat biaya 13% vs digitasi manual	Deteksi Bangunan padat/tidak teratur masih rendah (55%)
Darmawan, Widyadhana, & Eko,2022[16]	YOLOv4-Tiny	Industri Infrastruktur	Deteksi Objek	Citra Jalan	mAP 41%	Deteksi kerusakan jalan dengan geolokasi	Akurasi mAP rendah karena latar belakang kompleks
Basyir& Supiyandi, 2022 [28]	YOLOv11	Industri Garmen	Deteksi Cacat	Rok A-Line	Akurasi 94%	Deteksi cacat fisik (lubang/potongan) 100%	Deteksi noda ( <i>stain</i> ) kurang akurat (89%)

Berdasarkan sintesis data dari tabel dan literatur, ditemukan empat kesenjangan utama dalam penerapan CNN dan YOLO pada sektor Agraria, Medis dan Industri Cerdas

### 3.4.1 (*Environmental Gap*) Kesenjangan *Robustness* terhadap Variasi Kondisi Citra

Meskipun akurasi model pada data uji rata-rata tinggi (>90%), kinerja model menurun signifikan ketika dihadapkan pada variasi kondisi pengambilan gambar yang ekstrem.

#### a. Fakta

Pada sektor keamanan industri, model CNN memang capai akurasi 99,84%, namun performanya menurun pada kondisi rotasi wajah yang ekstrem[1].Lalu pada klasifikasi daun paprika, model belum teruji sepenuhnya pada dataset dengan *noise* tinggi[9].

#### b. Celah

Berdasarkan jurnal referensi yang digunakan belum banyak penelitian yang menerapkan teknik data *augmentation* tingkat lanjut atau arsitektur *spatial transformer network* yang mampu menangani *invariance* (ketahanan) terhadap rotasi ekstrem, *noise* tinggi, dan perubahan jarak kamera secara dinamis pada perangkat *low-end*

### 3.4.2 (*Fine Grained Classification Gap*) Kesulitan Membedakan Fitur Visual yang Samar

Ada tantangan konsisten dalam membedakan objek yang memiliki kemiripan visual tinggi atau fitur yang sangat halus (samar)

#### a. Fakta

Disektor agraria, model CNN Kustom (DFE & LCNN) kesulitan membedakan antara daun kentang sehat dengan daun yang terinfeksi penyakit *late blight* karena kemiripan visual [18]. Lalu di sektor industri garmen, meskipun YOLOv11 sangat akurat untuk cacat fisik (lubang), akurasinya turun menjadi 89% untuk deteksi noda (*stain*) yang samar[14].

#### b. Celah

Perlu dikembangkan metode *preprocessing* khusus (seperti penajaman kontras adaptif) atau penggunaan arsitektur *Attention Mechanism* yang lebih dalam untuk memfokuskan model pada fitur-fitur halus yang sering terlewatkan oleh CNN standar maupun YOLO.

### 3.4.3 (*Background & Density Gap*) Keterbatasan Deteksi pada Latar Belakang Kompleks dan Objek Padat

Model deteksi objek dan segmentasi sering mengalami penurunan performa dratis ketika objek target berada di lingkungan yang tidak terstruktur

#### a. Fakta

Di deteksi kerusakan jalan, menggunakan YOLOv4-Tiny menghasilkan mAP yang rendah (41%) akibat kompleksitas latar belakang jalan [13]. Lalu di model lain yang serupa, metode Mask R-CNN di pemetaannya infrastruktur memiliki performa rendah ( presisi deteksi 55%) ketika mendeteksi bangunan yang sangat padat dan tidak teratur[27]

#### c. Celah

Adanya kebutuhan untuk mengembangkan model *hybrid* menggabungkan deteksi objek dengan peisahan latar belakang (*background subtraction*) yang lebih canggih atau menggunakan arsitektur yang lebih canggih atau menggunakan arsitektur yang lebih kuat dalam menganai *occlusion* (objek yang saling menutupi) di area padat

## 4. KESIMPULAN

Dari hasil tinjauan pustaka sistematis yang penulis lakukan, dapat disimpulkan bahwa penerapan algoritma *Deep Learning*, khususnya *Convolutional Neural Network* (CNN) dan *You Only Look One* (YOLO), telah memberikan kontribusi signifikan dalam meningkatkan efektivitas pengolahan citra pada sektor agraria, medis, dan industri cerdas. Disini bukti CNN begitu andal dalam tugas klasifikasi citra dengan tingkat akurasi tinggi, terutama pada data yang memiliki pola visual konsisten, sedangkan YOLO unggul dalam deteksi objek secara *real-time* dengan efisiensi komputasi yang tinggi.

Tinjauan ini juga mengungkapkan adanya keterbatasan yang masih menjadi tantangan utama, seperti penurunan performa pada kondisi pencahayaan ekstrem, latar belakang kompleks, objek berukuran kecil, serta kesulitan dalam membedakan fitur visual yang begitu mirip. Tantangan tersebut menunjukkan bahwa satu arsitektur tunggal belum sepenuhnya mampu beradaptasi secara optimal pada seluruh karakteristik data lintas sektor.

Penelitian ini menerangkan bahwa pentingnya pemilihan arsitektur yang kontekstual terhadap kebutuhan aplikasi, mendorong pengembangan pendekatan lanjutan, mekanisme perhatian (*attention mechanism*), dan strategi data *augmentation* adaptif. Dengan pendekatan tersebut, sistem pengolahan citra berbasis *Deep Learning* diharapkan dapat menggantikan inspeksi secara

lebih akurat, efisien, dan berkelanjutan di berbagai sektor strategis.

## DAFTAR PUSTAKA

- [1] N. El Furqani, "Penerapan Teknologi Deep Learning Dalam Pengenalan Wajah Untuk Sistem Keamanan," *Tugas Mhs. Progr. Stud. Inform.*, vol. 1, no. 1, pp. 29–37, 2024.
- [2] T. Kusuma, "Studi Algoritma Deep Learning Dalam Pengolahan Citra Digital," *J. Dunia Data*, vol. 1, no. 5, pp. 1–15, 2024, [Online]. Available: <http://www.pusdansi.org/index.php/duniadata/article/view/108>
- [3] Riri, Syahrir, and M. M. Parenreng, "Klasifikasi penyakit tanaman jagung melalui citra daun dengan menggunakan metode <i>deep learning</i>," *J. Teknol. Elekerika*, 20xx, vol. 1, no. 3, pp. 64–75, 2022, [Online]. Available: <http://dx.doi.org/xxxxxx>
- [4] M. Tamba, "Analisis dan implementasi teknologi deep learning dalam pengolahan citra digital," *Circ. Arch.*, vol. 1, no. 6, pp. 1–7, 2024, [Online]. Available: <http://circle-archive.com/index.php/carc/article/view/290>
- [5] D. Rahmanda, P. Mahendri, and T. Y. Hadiwandura, "Jurnal Computer Science and Information Technology ( CoSciTech ) Implementasi Deep Learning Untuk Identifikasi Tanaman Rimpang Menggunakan Metode Convolutional Neural Network Implementation of Deep Learning for Identification of Rhizome Plants Using Convo," vol. 6, no. 1, pp. 1–8, 2025.
- [6] I. Wirabowo and I. Susilawati, "Implementasi Convolution Neural Network (CNN) untuk Deteksi Penyakit pada Daun Jagung Berbasis Citra Digital," *J. Pustaka Data (Pusat Akses Kaji. Database, Anal. Teknol. dan Arsit. Komputer)*, vol. 5, no. 1, pp. 233–241, 2025, doi: 10.55382/jurnalpustakadata.v5i1.1046.
- [7] Raynold and A. H. Muhammad, "Jurnal Computer Science and Information Technology ( CoSciTech ) Detection And Classification Tomato Leaf Disease Using ResNet-50," vol. 6, no. 1, pp. 9–20, 2025.
- [8] M. F. Azhari, "Deteksi & Kuantifikasi Trikoma Tipe Glandular (Bulbose) pada Citra Daun Tanaman Kentang Menggunakan Deep Learning," *Tesis*, pp. 1–18, 2024.
- [9] S. N. Nugraha, R. Pebrianto, and E. Fitri, "Penerapan Deep Learning Pada Klasifikasi Tanaman Paprika Berdasarkan Citra Daun Menggunakan Metode CNN," *Inf. Syst. Educ. Prof. J. Inf. Syst.*, vol. 8, no. 2, p. 15, 2023, doi: 10.51211/isbi.v8i2.2671.
- [10] Zulfagar, Ananda, and Memen Akbar, "Literature Review Metode Pengolahan Citra Pada Udang Danikan," *11th Appliedbus. Eng.*, no. September 2023, pp. 148–160, 2023.
- [11] F. Santoso, "Supandi, 2) Abd. Ghofur, 3) Firman Santoso," vol. 10, no. 2, pp. 604–614, 2025.
- [12] L. Mahdiyah, S. Oktamuliani, and W. L. Putri, "Penerapan Algoritma Deep Learning YOLOv8 pada Platform Roboflow untuk Segmentasi Citra Panoramik," *J. Fis. Unand*, vol. 14, no. 3, pp. 228–234, 2025, doi: 10.25077/jfu.14.3.228-234.2025.
- [13] B. Sasmito, B. H. Setiadji, and R. Isnanto, "Deteksi Kerusakan Jalan Menggunakan Pengolahan Citra Deep Learning di Kota Semarang," *Teknik*, vol. 44, no. 1, pp. 7–14, 2023, doi: 10.14710/teknik.v44i1.51908.
- [14] I. Cacat and P. Produk, "SMART VISUAL DETECTION BERBASIS DEEP LEARNING," vol. 10, no. 4, pp. 3704–3713, 2025.
- [15] D. I. Mulyana and I. Wahyudi, "Deteksi Kerusakan Jalan Berdasarkan Citra Digital Menggunakan Convolutional Neural Network (CNN)," *J. Indones. Manaj. Inform. dan Komun.*, vol. 6, no. 1, pp. 294–302, 2025, doi: 10.35870/jimik.v6i1.1192.
- [16] A. Darmawan, I. G. N. G. A. Widyadhana, and E. H. Binugroho, "Implementasi Metode Deep Learning Pada Prototipe Validator Uang Rupiah," *Sebatik*, vol. 26, no. 2, pp. 535–542, 2022, doi: 10.46984/sebatik.v26i2.2101.
- [17] A. P. Sari and B. Hendrik, "Analisis Komparatif Algoritma Deep Learning untuk Pengenalan Wajah: CNN, FaceNet, dan ArcFace," *J. Educ. Res.*, vol. 6, no. 4, pp. 1029–1036, 2025, doi: 10.37985/jer.v6i4.2178.
- [18] M. H. P. S. Ikhya Ulumuddin, Anggraini Puspita Sari, "Identifikasi Penyakit Daun Pada Tanaman Solanaceae Dan Rosaceae Menggunakan Deep Learning," *J. Teknol. Terpadu WATERFALL*, vol. 6, no. 22, pp. 72–78, 2020.
- [19] A. Fatur Rahman, D. Anggreani, and R. Y. Bakt, "E ISSN : 2809-4069 Model Deep Learning Berbasis Convolutional Neural Network Untuk Identifikasi Stroke Iskemik Pada Citra CT Scan," vol. 5, no. 2, pp. 290–297, 2025.
- [20] S. Wulan Dari and J. Triloka, "Kajian Algoritme Mask Region-Based Convolutional Neural Network (Mask R-CNN) dan You Look Only Once (YOLO) Untuk Deteksi Penyakit Kulit Akibat Infeksi Jamur," *Semin. Nas. Has. Penelit. dan Pengabd. Masy.*, pp. 2598–0256, 2022.
- [21] F. Gusnanto, N. Rahaningsih, R. Danar Dana, and M. Mulyawan, "Optimasi Model Klasifikasi Tingkat Kematangan Buah Mangga Dengan Metode Yolo11," *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 9, no. 1, pp. 1773–1780, 2025, doi: 10.36040/jati.v9i1.12591.
- [22] D. O. Alvira, Rachmansyah, and R. M. Fajri, "Klasifikasi Lapisan Lilin Pada Buah Apel Menggunakan Pengolahan Citra Digital Dengan Metode Convolutional Neural Network," *J. Intell. Networks IoT Glob.*, vol. 1, no. 2, pp. 92–97, 2023, doi: 10.36982/jinig.v1i2.3644.
- [23] Aldra Kasyfil Aziz, Ledy Novamizanti, and Suryo Adhi Wibowo, "Perancangan dan Implementasi Deep Learning untuk Deteksi Kesegaran Ikan Beku pada Aplikasi FishQ menggunakan YOLOv8," *J. Nas. SAINS dan Tek.*, vol. 2, no. 2, pp. 1–6, 2025, doi: 10.25124/jnst.v2i2.8746.
- [24] T. Ayu, V. Dwi, and A. E. Minarno, "Pendiagnosa Daun Mangga Dengan Model Convolutional Neural Network," *CESS (Journal Comput. Eng. Syst. Sci.)*, vol. 6, no. 2, p. 230, 2021, doi: 10.24114/cess.v6i2.22857.
- [25] S. Jiwandana Pinasthika, "Aplikasi Pembelajaran Mesin dalam Pengolahan Data Citra untuk Bidang Medis: Sebuah Kajian Pustaka," *J. Inf. Eng. Technol.*, vol. 2, no. 1, pp. 1–16, 2024, doi: 10.21831/jiety.v2i1.249.
- [26] P. Adelia Khairunnisa *et al.*, "Sistem Pengolahan Citra Digital Untuk Mendeteksi Ekspresi Wajah Secara Real-Time Menggunakan Deep Learning YOLOv5," *J. Ilm. Res. Student*, vol. 2, no. 1, pp. 594–607, 2025, [Online]. Available: <https://doi.org/10.61722/jirs.v2i1.3917>
- [27] M. Misbahuddin, S. E. Prabawa, S. Riadi, Y. A. Koroh, and S. C. Navisa, "Integrasi Deep Learning Mask R-CNN dalam Pemodelan 3D LOD1 Berbasis Citra Foto Udara UAV," *El-Jughrafiyah*, vol. 5, no. 2, p. 378, 2025, doi: 10.24014/jej.v5i2.37883.
- [28] M. K. Basyir and Supiyandi, "Klasifikasi Ras Anjing Menggunakan CNN Pada Citra Digital," *J. Soc. Sci. Res. Vol.*, vol. 5, pp. 99–109, 2025.