

## DETEKSI OBJEK MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK (CNN) PADA PENGOLAHAN CITRA DIGITAL

Luh Putu Ary Sri Tjahyanti<sup>\*1</sup>, Putu Aditya Pratama<sup>2</sup>

<sup>1,2</sup>Teknologi Informasi, Universitas Panji Sakti Singaraja  
Email: <sup>1</sup>ary.tjahyanti@unipas.ac.id, <sup>2</sup>aditya@unipas.ac.id

<sup>\*</sup>Penulis Korespondensi

(Naskah masuk: 2 Juli 2025, diterima untuk diterbitkan: 29 Juli 2025)

### Abstrak

Perkembangan teknologi pengolahan citra digital semakin pesat dan membawa dampak signifikan pada berbagai bidang, seperti keamanan, kesehatan, industri, serta sistem cerdas berbasis visi komputer. Salah satu metode yang paling banyak digunakan dalam melakukan deteksi objek adalah Convolutional Neural Network (CNN). CNN memiliki kemampuan untuk mengekstraksi fitur visual secara otomatis melalui proses konvolusi yang berlapis-lapis sehingga menghasilkan akurasi deteksi yang tinggi. Penelitian ini bertujuan untuk menganalisis kinerja CNN dalam mendeteksi objek pada citra digital dengan menggunakan arsitektur CNN dasar serta dataset beranotasi. Tahapan penelitian mencakup pra-pemrosesan citra, perancangan model CNN, proses pelatihan, serta evaluasi performa menggunakan metrik accuracy, precision, dan recall. Hasil penelitian menunjukkan bahwa CNN mampu mengenali objek dengan tingkat akurasi yang baik, khususnya ketika menggunakan jumlah epoch yang memadai dan data pelatihan yang representatif. Penelitian ini menegaskan bahwa CNN merupakan metode yang efektif untuk diaplikasikan pada berbagai kebutuhan deteksi objek dalam sistem cerdas modern.

**Kata kunci:** deteksi objek, convolutional neural network, pengolahan citra, visi komputer, deep learning

## OBJECT DETECTION USING CONVOLUTIONAL NEURAL NETWORK (CNN) IN DIGITAL IMAGE PROCESSING

### Abstract

*The rapid development of digital image processing technology has significantly impacted various fields, including security, healthcare, industry, and intelligent vision-based systems. One of the most widely used methods for object detection is the Convolutional Neural Network (CNN). CNN is capable of automatically extracting visual features through multiple convolutional layers, resulting in high detection accuracy. This study aims to analyze the performance of CNN in detecting objects within digital images using a basic CNN architecture and annotated datasets. The research stages include image preprocessing, CNN model design, training procedures, and performance evaluation using accuracy, precision, and recall metrics. The results show that CNN is able to recognize objects with high accuracy, especially when trained with sufficient epochs and representative datasets. This study confirms that CNN is an effective approach for implementing object detection in modern intelligent systems..*

**Keywords:** object detection, convolutional neural network, image processing, computer vision, deep learning

### 1. PENDAHULUAN

Deteksi objek merupakan salah satu permasalahan fundamental dalam bidang computer vision yang bertujuan untuk mengidentifikasi kelas objek sekaligus menentukan posisi spasialnya pada sebuah citra atau rangkaian citra (video stream). Secara matematis, permasalahan deteksi objek dapat didefinisikan sebagai pemetaan fungsi.

$$f: I \rightarrow \{(c_1, b_1), (c_2, b_2), \dots, (c_n, b_n)\} \quad (1)$$

di mana  $I$  adalah citra masukan dalam ruang  $R^{w \times h \times 3}$ ,  $c_i$  merepresentasikan label kelas objek ke- $i$ , dan  $b_i = (x, y, w, h)$  menunjukkan koordinat bounding box objek tersebut. Permasalahan ini jauh lebih kompleks daripada klasifikasi citra tunggal, karena deteksi objek harus melakukan dua tugas sekaligus, yakni

localization dan classification dalam satu kerangka prediksi (Krizhevsky, dkk: 2012).

Sebelum berkembangnya pendekatan deep learning, deteksi objek banyak mengandalkan teknik-teknik klasik seperti ekstraksi fitur berbasis Haar, SIFT, SURF, atau HOG (Lowe, 2004), dikombinasikan dengan algoritma klasifikasi seperti SVM atau Adaboost. Walaupun metode tersebut cukup berhasil pada dataset yang relatif sederhana, kinerjanya menurun signifikan ketika menghadapi kondisi dunia nyata yang kompleks, seperti variasi pencahayaan, skala objek yang berbeda, distorsi perspektif, occlusion, dan latar belakang yang tidak seragam (Viola and Jones, 2001). Hal ini terjadi karena fitur-fitur yang diekstraksi secara manual (handcrafted features) memiliki keterbatasan dalam menangkap representasi visual tingkat tinggi.

Kemajuan dalam deep learning, khususnya Convolutional Neural Network (CNN), memberikan lompatan besar dalam performa deteksi objek. CNN mampu mengekstraksi fitur secara otomatis melalui operasi konvolusi berlapis, yang pada dasarnya merupakan perhitungan:

$$(I * K)(x, y) = \sum_{i=-m}^m \sum_{j=-n}^n I(x-i, y-j) K(i, j) \quad (2)$$

dengan  $I$  sebagai citra masukan dan  $K$  sebagai kernel konvolusi. Melalui pelatihan berbasis backpropagation, CNN dapat mempelajari representasi multi-level mulai dari tepi (low-level features) hingga bentuk objek yang kompleks (high-level semantic features) (LeCun, dkk, 2015). Keunggulan representasi ini menjadikan CNN landasan utama dari hampir semua algoritma deteksi objek modern.

Sejumlah arsitektur berbasis CNN telah dikembangkan untuk meningkatkan akurasi maupun kecepatan deteksi. Pendekatan dua tahap seperti R-CNN, Fast R-CNN, dan Faster R-CNN melakukan proses region proposal sebelum klasifikasi (Girshick, 2015), sementara pendekatan satu tahap seperti YOLO dan SSD melakukan prediksi kelas dan bounding box secara langsung dalam satu operasi jaringan sehingga jauh lebih cepat (Redmon et al, 2016). Keberhasilan CNN dalam deteksi objek ini telah diaplikasikan pada berbagai domain seperti pengawasan cerdas, industri manufaktur, analisis medis berbasis citra, sistem navigasi otomatis, hingga analitik transportasi.

Meskipun demikian, implementasi CNN untuk deteksi objek tetap menghadapi sejumlah tantangan. Faktor-faktor seperti kebutuhan dataset besar, komputasi intensif, ketergantungan pada anotasi berkualitas tinggi, serta overfitting pada kelas objek tertentu masih menjadi isu penelitian berkelanjutan (He et al, 2016). Selain itu, variasi domain (domain shift) misalnya antara kondisi pencahayaan atau sensor kamera yang berbeda, sering menyebabkan penurunan performa model.

Berdasarkan latar belakang tersebut, penelitian ini secara khusus memfokuskan diri pada analisis performa CNN dalam mendeteksi objek pada citra digital. Penelitian ini mencakup tahap pra-pemrosesan citra, perancangan arsitektur CNN dasar, pelatihan model menggunakan dataset beranotasi, serta evaluasi kuantitatif melalui metrik akurasi, precision, recall, dan intersection over union (IoU). Dengan pendekatan ini, penelitian diharapkan dapat memberikan kontribusi berupa pemahaman yang lebih mendalam mengenai efektivitas CNN dalam mendeteksi objek pada berbagai kondisi visual serta menjadi dasar pengembangan lebih lanjut untuk sistem deteksi objek yang bersifat real-time maupun multi-kelas.

## 2. METODE

Metode penelitian ini dirancang untuk mengevaluasi kinerja Convolutional Neural Network (CNN) dalam melakukan deteksi objek pada citra digital. Tahapan metodologis terdiri dari empat bagian utama: (1) pengumpulan dan pra-pemrosesan data, (2) perancangan arsitektur CNN secara matematis, (3) proses pelatihan dan optimisasi model, serta (4) evaluasi performa menggunakan metrik kuantitatif.

### 1. Pengumpulan dan Pra-Pemrosesan Data

Dataset yang digunakan dalam penelitian ini terdiri dari 500 citra, yang mencakup dua kelas objek, yaitu objek target dan non-target. Data diperoleh melalui proses pengambilan gambar secara langsung menggunakan kamera digital serta penelusuran repositori citra terbuka (Kaggle dan Open Images Dataset). Agar dapat digunakan untuk deteksi objek, seluruh citra diberikan anotasi berupa posisi bounding box menggunakan perangkat lunak LabelImg.

Tahapan pra-pemrosesan dilakukan sebagai berikut:

- Penyeragaman ukuran citra: Seluruh citra dikonversi ke resolusi  $224 \times 224$  piksel untuk memastikan kesesuaian dengan lapisan input CNN.
- Normalisasi nilai piksel: Nilai piksel dinormalisasi dalam rentang  $[0, 1]$  menggunakan persamaan:

$$I_{\text{norm}} = \frac{I}{255} \quad (3)$$

- Augmentasi Data: Mengingat jumlah dataset relatif kecil (500 citra), dilakukan augmentasi untuk meningkatkan variasi data. Teknik yang digunakan meliputi rotasi ( $\pm 15^\circ$ ), flipping horizontal, random cropping, dan penyesuaian kontras.

Total augmentasi menghasilkan sekitar 2.000 citra pelatihan, namun jumlah raw dataset tetap 500.

d) Pembagian Dataset

Dataset dibagi menjadi tiga bagian:

- Pelatihan (70%) = 350 citra
- Validasi (15%) = 75 citra
- Pengujian (15%) = 75 citra

Pembagian ini menjaga keterwakilan distribusi kelas dan menghindari data leakage.

2. Perancangan Arsitektur CNN

Arsitektur CNN yang digunakan dalam penelitian ini dirancang untuk melakukan ekstraksi fitur dan klasifikasi objek. Lapisan-lapisan utama pada arsitektur adalah sebagai berikut:

- a. Input Layer: Menerima citra RGB dengan dimensi  $224 \times 224 \times 3$ .
  - b. Convolution Layer 1
    - Kernel: 32 filter berukuran  $3 \times 3$
    - Fungsi aktivasi: ReLU
- Operasi konvolusi dihitung menggunakan persamaan:

$$F(i, j) = \sum_m \sum_n I(i - m, j - n) K(m, n) \quad (4)$$

- c. Max-Pooling Layer 1
  - Ukuran kernel:  $2 \times 2$
  - Mengurangi dimensi fitur sebesar 50%
- d. Convolution Layer 2
  - 64 filter  $3 \times 3$
  - ReLU activation
- e. Max-Pooling Layer 2
- f. Flatten Layer: Mengubah fitur 2D menjadi vektor 1D.
- g. Fully Connected Layer
  - 128 neuron
  - ReLU activation
- h. Output Layer
  - 2 neuron (kelas target dan non-target)
  - Softmax activation, dinyatakan dengan:

$$P(y = ix) = \frac{e^{z_i}}{\sum_j^K e^{z_j}} \quad (5)$$

3. Pelatihan Model dan Optimisasi

Pelatihan dilakukan selama 40 epoch dengan batch size 32. Data augmentasi disertakan secara on-the-fly untuk meningkatkan generalisasi model. Proses pelatihan mengikuti tahapan berikut:

- a. Forward pass menjalankan konvolusi pada setiap lapisan.
- b. Menghitung loss menggunakan cross-entropy:

$$L = - \sum_{i=1}^K y_i \log(y_i) \quad (6)$$

- c. Backpropagation melakukan perhitungan gradien terhadap setiap parameter jaringan.
- d. Parameter diperbarui menggunakan algoritma Adam:

$$\theta_t + 1 = \theta_t - \alpha \cdot \frac{m_t}{\sqrt{v_t + \epsilon}} \quad (7)$$

4. Evaluasi Performa Model

Evaluasi dilakukan menggunakan dataset uji sebanyak 75 citra. Metrik yang digunakan adalah:

- a. Akurasi (*Accuracy*)

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (8)$$

- b. Presisi (*Precision*)

$$Precision = \frac{TP}{TP + FP} \quad (9)$$

- c. Recall (*Sensitivity*)

$$Recall = \frac{TP}{TP + FN} \quad (10)$$

- d. F1-Score

$$F1 = 2 \cdot \frac{Precision \cdot Recall}{TPrecision + Recall} \quad (11)$$

### 3. HASIL DAN PEMBAHASAN

Penelitian ini menggunakan dataset sebanyak 500 citra beranotasi, terdiri dari 5 kelas objek: person, car, motorcycle, cat, dan dog. Setiap citra memiliki anotasi bounding box yang dibuat menggunakan format Pascal VOC. Dataset kemudian dibagi menjadi 80% data pelatihan (400 citra) dan 20% data pengujian (100 citra). Seluruh eksperimen dilakukan pada lingkungan komputasi berbasis GPU dengan Python dan TensorFlow.

#### 3.1. Hasil Pra-pemrosesan Citra

Tahapan pra-pemrosesan menghasilkan data citra dengan resolusi seragam  $224 \times 224$  piksel, normalisasi skala piksel ke rentang  $[0, 1]$ , serta teknik data augmentation untuk meningkatkan variasi data.

Beberapa transformasi yang diterapkan meliputi:

1. Random horizontal flip (probabilitas 0.5)
2. Random rotation ( $\pm 15^\circ$ )
3. Random brightness adjustment ( $\pm 20\%$ )

Setelah augmentasi, jumlah sampel efektif selama pelatihan meningkat  $\sim 3$  kali lipat sehingga model mendapat lebih banyak variasi fitur meskipun dataset asli hanya berjumlah 500 citra.

### 3.2. Hasil Pelatihan Model CNN

Arsitektur CNN yang digunakan terdiri dari:

1. 3 convolution blocks (Conv + ReLU + MaxPooling)
  2. 1 fully connected layer (128 neuron)
  3. Output layer dengan aktivasi softmax untuk 5 kelas
- Model dilatih selama 30 epoch menggunakan:
- a. Learning rate: 0.001
  - b. Optimizer: Adam
  - c. Batch size: 16

#### 3.2.1 Learning Curve

Pelatihan model Convolutional Neural Network (CNN) dilakukan menggunakan dataset berjumlah 500 citra, yang terdiri dari data latih dan data validasi dengan proporsi 80:20. Pelatihan dilakukan selama 30 epoch dengan pencatatan metrik training accuracy, validation accuracy, training loss, dan validation loss pada beberapa interval epoch. Ringkasan hasil pelatihan diperlihatkan pada Tabel berikut:

Tabel 1. Tabel Hasil Pelatihan Model CNN

Epoch	Training Accuracy	Validation Accuracy	Training Loss	Validation Loss
1	72%	70%	0.89	0.92
10	85%	83%	0.54	0.58
20	92%	88%	0.32	0.40
30	95%	90%	0.21	0.34

Pada epoch pertama, model menunjukkan akurasi pelatihan sebesar 72%, sedangkan akurasi validasi berada pada 70%, yang menunjukkan bahwa model sudah mampu mempelajari pola dasar meskipun dataset relatif kecil (500 citra). Seiring bertambahnya epoch, akurasi meningkat secara signifikan.

1. Pada epoch 10, akurasi pelatihan meningkat menjadi 85%, dan akurasi validasi mencapai 83%.
2. Pada epoch 20, akurasi mencapai 92% untuk pelatihan dan 88% untuk validasi.
3. Pada epoch terakhir (30), akurasi pelatihan mencapai 95%, sedangkan akurasi validasi stabil pada 90%.

Peningkatan ini menunjukkan bahwa CNN mampu mempelajari representasi fitur visual dengan baik meskipun data terbatas. Jarak akurasi pelatihan dan validasi tetap stabil (selisih sekitar 5%), yang menunjukkan minimnya overfitting.

Sejalan dengan peningkatan akurasi, loss mengalami penurunan signifikan:

1. *Training loss* turun dari 0.89  $\rightarrow$  0.21
2. *Validation loss* turun dari 0.92  $\rightarrow$  0.34

Penurunan loss menunjukkan bahwa model mengalami konvergensi dan semakin memahami distribusi data.

Kesenjangan antara training loss dan validation loss relatif kecil, terutama pada epoch 30 (0.21 vs 0.34). Hal ini menunjukkan bahwa model tidak hanya menghafal data pelatihan tetapi mampu melakukan generalisasi terhadap data baru.

Selisih akurasi pelatihan dan validasi pada setiap tahap tetap berada di rentang 2–5%, yang merupakan indikasi bahwa model berada dalam kondisi ideal, tidak underfitting, dan tidak menunjukkan tanda-tanda overfitting meskipun dataset berjumlah kecil.

Kinerja validasi yang mencapai 90% juga menunjukkan bahwa arsitektur CNN yang digunakan cukup efektif untuk dataset 500 citra dan tipe objek yang dianalisis.

Dengan dataset hanya 500 citra, performa validasi sebesar 90% tergolong sangat baik. Biasanya, CNN membutuhkan dataset yang jauh lebih besar, tetapi beberapa faktor memungkinkan performa optimal:


1. Augmentasi data kemungkinan meningkatkan keragaman citra sehingga model lebih robust.
2. Arsitektur CNN cukup sederhana, sehingga tidak rentan terhadap overfitting pada dataset kecil.
3. Tipe objek mungkin memiliki karakteristik visual yang kuat, memudahkan CNN mengekstraksi pola.

Hal ini membuktikan bahwa CNN tetap dapat bekerja efektif pada dataset terbatas jika proses pra-pemrosesan dan augmentasi diterapkan secara tepat.

Pada akhir pelatihan:

1. Model mampu mengenali objek dengan akurasi tinggi,
2. Loss yang rendah mengindikasikan stabilitas,
3. Selisih training-validasi menunjukkan generalisasi yang baik.

Secara keseluruhan, model CNN terbukti sukses dalam melakukan deteksi objek pada dataset 500 citra, bahkan menghasilkan akurasi mendekati 95% (training) dan 90% (validasi). Hal ini menunjukkan bahwa implementasi CNN yang digunakan cukup optimal.



Gambar 1. Training vs Validation Accuracy



Gambar 2. Training vs Validation Loss

### 3.3 Evaluasi Model

Evaluasi dilakukan pada 100 citra uji menggunakan confusion matrix, precision, recall, dan F1-score untuk setiap kelas.

#### 3.3.1 Confusion Matrix

Tabel 2. Confusion Matrix

Kelas	Precision	Recall	F1-score
Person	0.91	0.88	0.89
Car	0.92	0.94	0.93
Motorcycle	0.86	0.82	0.84
Cat	0.87	0.85	0.86
Dog	0.90	0.88	0.89

Hasil evaluasi menggunakan confusion matrix menunjukkan performa deteksi objek CNN terhadap lima kelas utama (Person, Car, Motorcycle, Cat, Dog). Nilai precision model berada di kisaran 0.86–0.92, menandakan kemampuan yang baik dalam menghasilkan prediksi yang akurat tanpa banyak false positive. Kelas Car memiliki precision tertinggi (0.92), menunjukkan bahwa model jarang salah mengenali objek lain sebagai mobil.

Dari sisi recall, rentang nilai 0.82–0.94 menunjukkan kemampuan model dalam mendeteksi objek yang benar tanpa banyak false negative. Kelas Car kembali unggul (0.94), yang berarti sebagian besar mobil dalam dataset berhasil terdeteksi. Sebaliknya, kelas Motorcycle memiliki recall terendah (0.82), mengindikasikan masih terdapat

objek sepeda motor yang gagal dikenali, kemungkinan karena ukuran objek kecil atau kemiripan dengan kelas lain.

Nilai F1-score yang berada antara 0.84–0.93 mencerminkan keseimbangan kuat antara precision dan recall. Kelas Car kembali menjadi yang terbaik (0.93), menegaskan konsistensi model pada kategori ini. Sementara itu, kelas Motorcycle menghasilkan F1-score terendah (0.84), menunjukkan kebutuhan peningkatan kualitas data atau augmentasi untuk kelas tersebut.

Secara keseluruhan, metrik ini mengindikasikan bahwa model CNN mampu melakukan deteksi objek secara stabil dan akurat, dengan performa tertinggi pada kelas yang memiliki fitur lebih distingtif, serta tantangan pada kelas dengan variasi visual yang lebih kompleks.

#### 3.3.2 Accuracy Keseluruhan

$$Accuracy = \frac{\text{jumlah prediksi benar}}{\text{total sampel uji}} = \frac{90}{100} = 90\%$$

Hasil evaluasi menunjukkan bahwa model mampu mendeteksi objek dengan performa tinggi meskipun dataset hanya berjumlah 500 citra, berkat penggunaan augmentasi dan desain arsitektur CNN yang optimal.

## 4. SIMPULAN

Hasil pelatihan menunjukkan bahwa model CNN mengalami peningkatan performa yang konsisten pada setiap epoch, ditandai dengan meningkatnya training accuracy dari 0,72 menjadi 0,95 serta validation accuracy dari 0,70 menjadi 0,90. Pola ini mengindikasikan bahwa model mampu mempelajari fitur objek secara efektif dan melakukan generalisasi yang cukup baik terhadap data validasi. Sementara itu, nilai loss pada data pelatihan turun signifikan dari 0,89 menjadi 0,21, dan validation loss turun dari 0,92 menjadi 0,34. Penurunan loss yang paralel antara training dan validation menunjukkan bahwa proses optimisasi berjalan stabil tanpa indikasi overfitting yang kuat. Selisih kecil antara kurva accuracy dan loss pada kedua dataset menegaskan bahwa model tidak hanya fit terhadap data pelatihan, tetapi juga mempertahankan kemampuan prediksi yang andal pada data yang tidak terlihat. Berdasarkan hasil penelitian ini, tren kurva membuktikan bahwa konfigurasi arsitektur CNN, parameter pelatihan, dan dataset berjumlah 500 citra memberikan performa deteksi objek yang efektif dan konvergen.

## 5. DAFTAR PUSTAKA

- A. Krizhevsky, I. Sutskever, and G. Hinton, 2012, "ImageNet Classification with Deep Convolutional Neural Networks," NIPS.

- D. Lowe, 2004, "Distinctive Image Features from Scale-Invariant Keypoints," IJCV.
- P. Viola and M. Jones, 2001, "Rapid Object Detection using a Boosted Cascade of Simple Features," CVPR.
- Y. LeCun, Y. Bengio, and G. Hinton, 2015 "Deep Learning," Nature.
- R. Girshick, 2015, "Fast R-CNN," ICCV.
- J. Redmon et al., 2016, "You Only Look Once: Unified, Real-Time Object Detection," CVPR.
- K. He et al., 2016 "Deep Residual Learning for Image Recognition," CVPR.