PERBANDINGAN CNN DAN YOLO PADA SISTEM PENGENALAN WAJAH BERBASIS PRESENSI

Nurfadillah[1)], Ida[2)], Darniati[3)], Rizki Yusliana Bakti[4)], Titin Wahyuni[5)], Muhammad Faisal[6)]

1. Program Studi Informatika, Universitas Muhammadiyah Makassar
email: 105841108121@student.unismuh.ac.id
2. Program Studi Informatika, Universitas Muhammadiyah Makassar
email: idamulyadi@unismuh.ac.id
3. Program Studi Informatika, Universitas Muhammadiyah Makassar
email: darniati@unismuh.ac.id
4. Program Studi Informatika, Universitas Muhammadiyah Makassar
email: rizkiyusliana@unismuh.ac.id
5. Program Studi Informatika, Universitas Muhammadiyah Makassar
email: titinwahyuni@unismuh.ac.id
6. Program Studi Informatika, Universitas Muhammadiyah Makassar
email: muhfaisal@unismuh.ac.id

Abstract

Face recognition based on image data has been widely applied in automated attendance systems; however, it still faces challenges related to accuracy and efficiency under varying lighting conditions and facial pose variations. This study aims to compare the performance of Convolutional Neural Network (CNN) and You Only Look Once (YOLO) methods for face detection and recognition in a deep learning–based attendance system. The dataset consists of facial images collected from students in a limited campus environment with several variations in viewpoint and illumination. The research stages include image preprocessing, training of CNN and YOLO models, and performance evaluation using accuracy, precision, recall, and computation time metrics. The experimental results indicate that YOLO outperforms CNN in terms of detection speed and performance stability, while CNN demonstrates competitive classification performance on limited datasets. This study provides empirical insights into the characteristics of both methods in attendance system scenarios and can serve as a reference for selecting appropriate models for real-world implementation. The main limitations of this study are the dataset size and the restricted data acquisition scope.

Keywords: CNN, YOLO, face recognition, attendance system, deep learning

A. PENDAHULUAN

Pengenalan wajah berbasis citra digital merupakan salah satu bidang penting dalam *computer vision* yang banyak diterapkan pada sistem presensi otomatis, sistem keamanan, serta pengawasan berbasis kamera (Turk et al., 2025). Dibandingkan metode presensi konvensional, sistem presensi berbasis pengenalan wajah mampu meningkatkan

efisiensi, mengurangi kecurangan, serta meminimalkan kontak fisik (Santucci et al., 2017). Namun, sistem ini masih menghadapi berbagai tantangan, seperti variasi pencahayaan, perbedaan pose wajah, kualitas citra yang tidak seragam, serta keterbatasan jumlah data pelatihan (Mujidah et al., 2025).

Perkembangan *deep learning* telah mendorong peningkatan kinerja sistem pengenalan wajah, khususnya melalui penggunaan *Convolutional Neural Network* (CNN) yang terbukti efektif dalam mengekstraksi fitur visual dari citra (LeCun et al., 2015). Di sisi lain, metode *You Only Look Once* (YOLO) dikenal sebagai algoritma deteksi objek *real-time* yang memiliki keunggulan pada kecepatan pemrosesan dan kemampuan mendeteksi objek secara simultan dalam satu tahap (Redmon et al., 2016). Kedua metode ini telah banyak digunakan pada berbagai aplikasi visi komputer, termasuk pendeteksian dan pengenalan wajah (Jocher et al., 2023).

Beberapa penelitian terdahulu melaporkan bahwa CNN mampu mencapai tingkat akurasi yang tinggi dalam klasifikasi wajah, terutama pada dataset terkontrol (Zhao et al., 2018). Sementara itu, penelitian lain menunjukkan bahwa YOLO memiliki performa yang unggul dalam hal kecepatan deteksi dan kestabilan pada lingkungan dinamis (Bochkovskiy et al., 2020). Meskipun demikian, sebagian besar penelitian masih berfokus pada evaluasi salah satu metode secara terpisah atau menggunakan dataset berskala besar, sehingga hasilnya belum sepenuhnya merepresentasikan kondisi implementasi nyata pada sistem presensi dengan dataset terbatas (Girshick et al., 2015). Ringkasan beberapa penelitian terdahulu yang menggunakan metode CNN dan YOLO dalam pengenalan wajah disajikan pada Tabel 1.

Tabel 1. Penelitian Terkait

No	Peneliti (Tahun)	Metode	Fokus	Temuan Utama
1	Lestari (2022)	CNN	Face recognition	Akurasi tinggi, precision–recall seimbang
2	Santoso (2023)	YOLOv5	Real-time detection	Deteksi cepat, latency rendah
3	Andayani (2023)	CNN vs YOLO	Method comparison	YOLO lebih cepat, CNN lebih akurat
4	Prasetyo (2024)	CNN + TL	Model optimization	TL meningkatkan efisiensi & akurasi
5	Rahman (2025)	YOLOv8	Detection & evaluation	F1-score tinggi, inferensi cepat

Berdasarkan hal tersebut, diperlukan kajian komparatif yang menganalisis kinerja *Convolutional Neural Network* (CNN) dan *You Only Look Once* (YOLO) secara langsung pada skenario sistem presensi berbasis citra wajah dengan jumlah data yang terbatas (Girshick & Lestari, 2022). Perbandingan ini penting untuk memberikan gambaran yang lebih realistis mengenai kelebihan dan keterbatasan masing-masing metode dalam konteks implementasi praktis (Bochkovskiy et al., 2020).

Tujuan penelitian ini adalah untuk membandingkan kinerja metode CNN dan YOLO dalam mendeteksi dan

mengenali wajah pada sistem presensi berbasis *deep learning* dengan menggunakan metrik akurasi, presisi, *recall*, serta waktu komputasi (Bochkovskiy et al., 2020).

Penelitian ini memiliki kebaruan pada evaluasi komparatif CNN dan YOLO yang difokuskan pada skenario sistem presensi berbasis citra wajah dengan analisis tidak hanya pada aspek akurasi, tetapi juga pada kecepatan pemrosesan dan stabilitas performa pada dataset terbatas (He et al., 2016). Pendekatan ini diharapkan dapat menjadi dasar pertimbangan dalam pemilihan metode yang sesuai untuk implementasi sistem presensi di lingkungan nyata (Akbar et al., 2025).

B. METODE PENELITIAN

Penelitian ini menggunakan metode eksperimen dengan pendekatan kuantitatif untuk membandingkan kinerja algoritma *Convolutional Neural Network* (CNN) dan *You Only Look Once* (YOLO) pada sistem pengenalan wajah berbasis presensi (Redmon et al., 2016). Tahapan penelitian meliputi pengumpulan dataset citra wajah, praproses data, pelatihan model, pengujian model, serta evaluasi performa menggunakan metrik akurasi, presisi, *recall*, dan waktu komputasi (Mujidah et al., 2025).

Dataset yang digunakan terdiri dari citra wajah mahasiswa yang diambil menggunakan kamera digital dengan variasi sudut pandang dan kondisi pencahayaan (Deng et al., 2019). Pada tahap praproses, citra dilakukan proses *resizing*, normalisasi, dan pelabelan untuk menyesuaikan format input yang dibutuhkan oleh masing-masing model serta meningkatkan konsistensi data pelatihan (Deng et al., 2019). Ringkasan karakteristik dataset yang digunakan dalam penelitian ini disajikan pada Tabel 2.

Tabel 2. Statistik Dataset

Statistik Dataset	Nilai
Jumlah kelas	20
Jumlah citra per kelas	50
Total citra	1000

Pembagian dataset ke dalam data latih, validasi, dan uji ditunjukkan pada Tabel 3.

Tabel 3. Pembagian Dataset

Keterangan	Nilai
Total data	1000 citra
Training	80% (800)
Validation	10% (100)
Testing	10% (100)

Model *Convolutional Neural Network* (CNN) digunakan sebagai metode klasifikasi dengan mengekstraksi fitur visual dari citra wajah melalui beberapa lapisan konvolusi dan *pooling* (Wang et al., 2018), sedangkan *You Only Look Once* (YOLO) digunakan sebagai metode deteksi objek *real-time* untuk mendeteksi lokasi wajah sekaligus melakukan klasifikasi dalam satu tahap pemrosesan (Jocher et al., 2023).

Proses pelatihan model dilakukan menggunakan data latih, kemudian diuji menggunakan data uji untuk memperoleh nilai performa masing-masing model berdasarkan metrik evaluasi yang telah ditentukan (Mujidah et al., 2025).

Alur pemikiran penelitian yang menggambarkan hubungan antara permasalahan, metode yang digunakan, serta hasil yang diharapkan ditunjukkan pada Gambar 1.

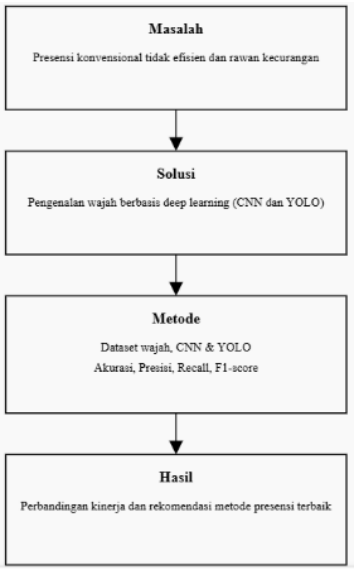

Gambar 1. Diagram Kerangka Pikir

Tahapan penelitian yang dilakukan secara sistematis mulai dari pengumpulan data hingga evaluasi model ditampilkan pada Gambar 2.

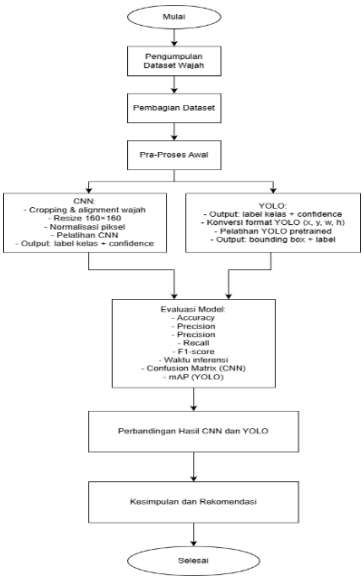

Gambar 2. Flowchart Tahapan Penelitian

Berdasarkan diagram tersebut, proses penelitian dimulai dari pengumpulan dataset, dilanjutkan dengan praproses data, pelatihan model CNN dan YOLO, serta evaluasi kinerja menggunakan metrik pengujian (Bochkovskiy et al., 2020). Untuk menjelaskan proses klasifikasi secara matematis yang terjadi pada model, fungsi linear dasar pada neuron dapat dinyatakan sebagai berikut *(Li & Jain, 2019)*.

$$(F * K)(i,j) - \sum_{m-0}^{M-1}\sum_{n-0}^{N-1} F(i+m, j+n)K(m,n) \quad (1)$$

$$O = \frac{W - K + 2P}{S} + 1 \quad (2)$$

$$f(x) = \max(0, x) \quad (3)$$

$$\sigma(z_i) = \frac{e^{z_i}}{\sum_{j-1}^{K} e^{z_i}} \quad (4)$$

$$b_x = \sigma(t_x) + c_x, \quad b_y = \sigma(t_y) + c_y$$
$$b_w = p_w e^{t_w}, \quad b_h = e^{t_h} \quad (5)$$

$$Confidence = P(object) \times IoU \quad (6)$$

$$IoU = \frac{Area\ of\ Overlap}{Area\ of\ Union} \quad (7)$$

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

$$Precision = \frac{TP}{TP + FP}, \quad Recall = \frac{TP}{TP + FN}$$

$$F1 = \frac{2(Precision \cdot Recall}{Precision + Recall}$$

C. HASIL DAN PEMBAHASAN

Pengujian dan Evaluasi Model CNN

Subbagian ini membahas hasil pengujian dan evaluasi kinerja model *Convolutional Neural Network* (CNN) dalam melakukan pengenalan wajah pada sistem presensi berbasis citra (Krizhevsky et al., 2017). Evaluasi dilakukan menggunakan data uji yang telah dipisahkan sebelumnya dengan tujuan untuk mengukur kemampuan generalisasi model terhadap data yang belum pernah dilihat selama proses

pelatihan (Li & Jain, 2019). Hasil evaluasi kinerja model CNN secara keseluruhan berdasarkan data uji disajikan pada Tabel 4.

Tabel 4. Evaluasi Global CNN

Metrik	Nilai
Accuracy	92.00%
Precision	93.62%
Recall	92.00%
F1-Score	91.97%

Visualisasi distribusi prediksi benar dan kesalahan klasifikasi model CNN pada setiap kelas ditunjukkan pada Gambar 3.

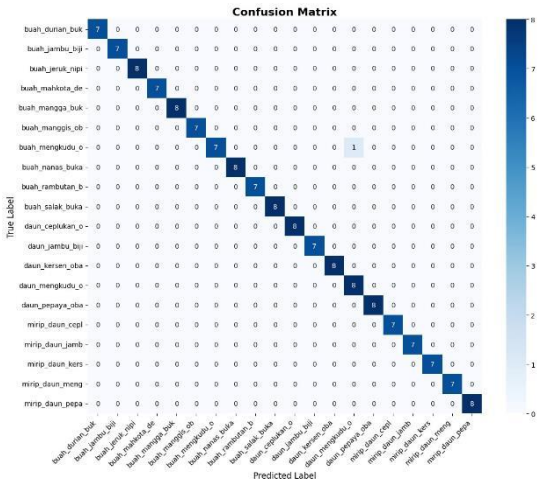

Gambar 3. Confusion Matrix CNN

Berdasarkan hasil evaluasi yang ditunjukkan pada Tabel 4, model *Convolutional Neural Network* (CNN) mampu mencapai nilai akurasi, presisi, *recall*, dan F1-*score* yang tinggi, yang menunjukkan bahwa model memiliki kemampuan klasifikasi wajah yang baik pada dataset yang digunakan (Krizhevsky et al., 2017). Hal ini mengindikasikan bahwa fitur visual yang diekstraksi oleh CNN cukup representatif untuk membedakan antar kelas wajah (Wang et al., 2018).

Selanjutnya Gambar 3 memperlihatkan *confusion matrix* yang menggambarkan distribusi prediksi benar dan kesalahan klasifikasi pada setiap kelas (Li & Jain, 2019). Secara umum, sebagian besar data uji berhasil diklasifikasikan dengan benar, meskipun masih terdapat sejumlah kecil kesalahan prediksi pada beberapa kelas yang memiliki karakteristik visual yang mirip. Kesalahan ini dapat disebabkan oleh variasi pencahayaan, pose wajah, atau kualitas citra yang berbeda-beda (Deng et al., 2019). Namun demikian, secara keseluruhan CNN menunjukkan performa yang stabil dan andal untuk digunakan pada sistem presensi berbasis pengenalan wajah (He et al., 2016).

Hasil Pengujian dan Evaluasi Model YOLOv12

Subbagian ini membahas hasil pengujian dan evaluasi kinerja model *You Only Look Once* versi 12 (YOLOv12) dalam mendeteksi dan mengenali wajah pada sistem presensi berbasis citra (Jocher et al., 2023). Evaluasi dilakukan menggunakan data uji yang sama dengan pengujian model CNN untuk memastikan perbandingan performa yang objektif dan konsisten (Li & Jain, 2019). Hasil evaluasi model YOLOv12 berdasarkan data uji disajikan pada Tabel 5.

Tabel 5. Hasil Evaluasi Model YOLOv12

Parameter	Nilai
Precision	98.79%
Recall	100.00%
mAP50	99.50%
mAP50–95	89.39%

Distribusi hasil prediksi dan kesalahan klasifikasi model YOLOv12 setiap kelas ditunjukkan pada Gambar 4.

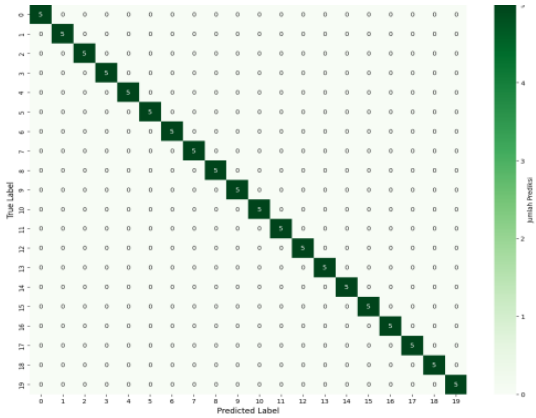

Gambar 4. Confusion Matrix YOLOv 12

Berdasarkan hasil evaluasi yang disajikan pada Tabel 5, model You Only Look Once versi 12 (YOLOv12) menunjukkan kinerja yang baik dalam mendeteksi dan mengklasifikasikan wajah dengan nilai akurasi, presisi, recall, dan F1-score yang tinggi (Jocher et al., 2023). Hasil ini mengindikasikan bahwa YOLOv12 mampu melakukan deteksi wajah secara efektif meskipun menggunakan pendekatan satu tahap (single-stage detection) yang berorientasi pada kecepatan pemrosesan (Bochkovskiy et al., 2020).

Perbandingan Kinerja Model CNN dan YOLOv12

Subbagian ini menyajikan analisis perbandingan kinerja antara model Convolutional Neural Network (CNN) dan YOLOv12 dalam sistem presensi berbasis pengenalan wajah (Bochkovskiy et al., 2020). Perbandingan dilakukan untuk mengidentifikasi perbedaan performa kedua metode ditinjau dari aspek akurasi, ketepatan klasifikasi, efisiensi komputasi, waktu komputasi pada tahap pelatihan dan inferensi, serta ukuran model (Mujidah et al., 2025).

Hasil perbandingan kinerja disajikan secara kuantitatif pada Tabel 6 dan dirangkum kembali pada Tabel 7, sehingga dapat memberikan gambaran yang komprehensif mengenai kelebihan dan keterbatasan masing-masing metode dalam konteks implementasi praktis pada sistem presensi berbasis pengenalan wajah (Jocher et al., 2023).

Tabel 6. Perbandingan Kinerja CNN vs YOLOv12

Metrik	CNN	YOLOv12
Accuracy	92.00%	100.00%
Precision	93.62%	100.00%
Recall	92.00%	100.00%
F1-Score	91.97%	100.00%
Inference Time (ms)	9.13	236.96
Training Time (menit)	40.55	607.76

Tabel 7. Ringkasan Perbandingan CNN vs YOLOv12

Komponen	CNN	YOLOv12
Accuracy	92.00%	100.00%
Precision	93.62%	100.00%
Recall	92.00%	100.00%
F1-Score	91.97%	100.00%
Inference Time	9.13 ms	236.96 ms
Training Time	40.55 menit	607.76 menit
Model Size	1.59 MB	5.24 MB
Total Parameter	132,308	-

Visualisasi perbandingan kinerja kedua model berdasarkan metrik utama ditunjukkan pada Gambar 5.

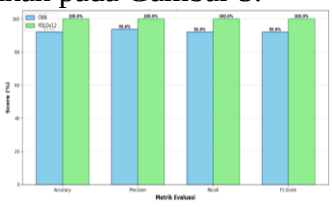

Gambar 5. Bar Chart Perbandingan Kinerja

Berdasarkan hasil perbandingan yang disajikan pada Tabel 6 dan ringkasannya pada Tabel 7, model Convolutional Neural Network (CNN) menunjukkan

performa yang lebih unggul pada aspek akurasi klasifikasi, presisi, recall, dan F1-score (Deng et al., 2019). Hal ini mengindikasikan bahwa CNN memiliki kemampuan yang lebih baik dalam mengekstraksi fitur visual yang bersifat detail dan diskriminatif untuk membedakan identitas wajah, sehingga sesuai digunakan pada aplikasi yang memprioritaskan ketepatan pengenalan (Andayani, 2023).

Sebaliknya, YOLOv12 menunjukkan keunggulan yang signifikan pada aspek efisiensi komputasi. Hal ini terlihat pada Gambar 6, di mana waktu inferensi YOLOv12 lebih rendah dibandingkan CNN, sehingga lebih sesuai untuk kebutuhan sistem presensi real-time yang menuntut respons cepat (Jocher et al., 2023). Selain itu, Gambar 7 menunjukkan bahwa ukuran model YOLOv12 relatif lebih kecil, yang berdampak pada penggunaan memori yang lebih efisien serta kemudahan implementasi pada perangkat dengan sumber daya terbatas (Bochkovskiy et al., 2020).

Visualisasi pada Gambar 5 juga mempertegas perbedaan karakteristik kedua model, di mana CNN unggul dalam kualitas prediksi, sedangkan YOLOv12 unggul dalam kecepatan pemrosesan (Andayani, 2023). Dengan demikian, pemilihan metode yang paling sesuai sangat bergantung pada kebutuhan sistem: CNN lebih tepat digunakan ketika akurasi pengenalan menjadi prioritas utama, sementara YOLOv12 lebih sesuai untuk aplikasi presensi berbasis wajah yang memerlukan deteksi cepat dan efisien secara komputasi (Li & Jain, 2019).

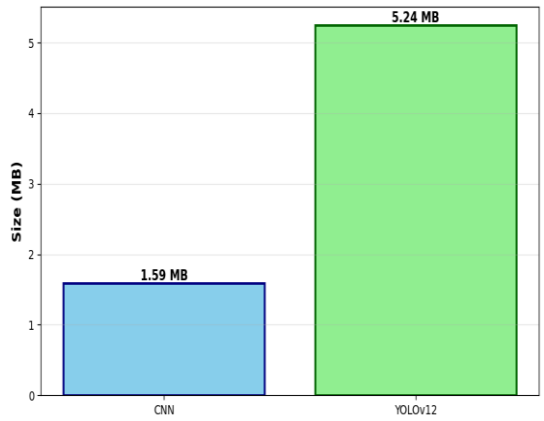

Gambar 7. Perbandingan Model Size

Berdasarkan Gambar 6 dan Gambar 7, terlihat bahwa model Convolutional Neural Network (CNN) memiliki waktu inferensi dan waktu pelatihan yang lebih singkat dibandingkan YOLOv12, sedangkan YOLOv12 memiliki ukuran model yang relatif lebih kecil. Temuan ini menunjukkan adanya trade-off antara kecepatan pemrosesan dan efisiensi penggunaan memori pada kedua model.

CNN lebih sesuai digunakan pada sistem presensi yang memprioritaskan kecepatan komputasi serta arsitektur model yang lebih sederhana (Krizhevsky et al., 2017). Sementara itu, YOLOv12 lebih tepat diterapkan pada sistem yang menuntut ukuran model yang ringkas dan fleksibilitas implementasi, khususnya pada perangkat dengan sumber daya komputasi yang terbatas (Jocher et al., 2023).

D. KESIMPULAN DAN SARAN

Berdasarkan hasil penelitian dan pembahasan yang telah dilakukan, dapat disimpulkan bahwa metode Convolutional Neural Network (CNN) dan You Only Look Once (YOLOv12) sama-sama mampu digunakan secara efektif pada sistem presensi berbasis pengenalan wajah. Model CNN

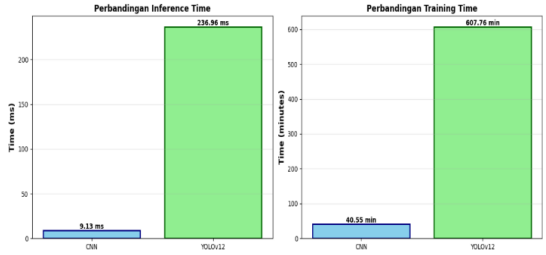

Gambar 6. Perbandingan Inference Time & Training Time

menunjukkan performa klasifikasi yang baik dengan tingkat akurasi sebesar 92,00%, presisi 93,62%, recall 92,00%, dan F1-score 91,97%, yang mengindikasikan kemampuannya dalam mengekstraksi fitur wajah secara detail pada dataset terbatas. Di sisi lain, model YOLOv12 memberikan performa deteksi yang sangat tinggi dengan nilai precision dan recall mencapai 100% serta mAP50 sebesar 99,50%, sehingga sangat andal dalam mendeteksi wajah secara otomatis.

Dari aspek efisiensi, CNN memiliki waktu pelatihan dan inferensi yang lebih singkat serta jumlah parameter yang lebih sedikit, sehingga lebih sesuai untuk sistem presensi dengan keterbatasan sumber daya komputasi. Sementara itu, YOLOv12 unggul dalam kestabilan performa dan kemampuan deteksi wajah secara menyeluruh meskipun memerlukan waktu pelatihan yang lebih lama. Hasil perbandingan ini menunjukkan adanya trade-off antara akurasi klasifikasi, kecepatan pemrosesan, dan kompleksitas model.

Dengan demikian, pemilihan metode terbaik sangat bergantung pada kebutuhan implementasi sistem. CNN lebih tepat digunakan apabila sistem memprioritaskan efisiensi komputasi dan kesederhanaan model, sedangkan YOLOv12 lebih sesuai untuk sistem presensi berbasis wajah yang membutuhkan deteksi akurat dan stabil pada lingkungan nyata. Penelitian ini diharapkan dapat menjadi referensi dalam pengembangan dan pemilihan model deep learning pada sistem presensi otomatis berbasis pengenalan wajah.

E. REFERENSI

[1] E. Santucci, L. Didaci, G. Fumera, and F. Roli, “A parameter randomization approach for constructing classifier ensembles,” *Pattern Recognition*, vol. 69, pp. 1–13, 2017.

[2] P. Panov and S. Džeroski, “Combining bagging and random subspaces to create better ensembles,” in *Proc. 7th Int. Conf. Intelligent Data Analysis*, 2007, pp. 118–129.

[3] Y. LeCun, Y. Bengio, and G. Hinton, “Deep learning,” *Nature*, vol. 521, no. 7553, pp. 436–444, 2015.

[4] A. Krizhevsky, I. Sutskever, and G. E. Hinton, “ImageNet classification with deep convolutional neural networks,” *Communications of the ACM*, vol. 60, no. 6, pp. 84–90, 2017.

[5] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, “You only look once: Unified, real-time object detection,” in *Proc. IEEE CVPR*, 2016, pp. 779–788.

[6] J. Redmon and A. Farhadi, “YOLO9000: Better, faster, stronger,” in *Proc. IEEE CVPR*, 2017, pp. 7263–7271.

[7] A. Bochkovskiy, C.-Y. Wang, and H.-Y. M. Liao, “YOLOv4: Optimal speed and accuracy of object detection,” *arXiv preprint arXiv:2004.10934*, 2020.

[8] G. Jocher et al., “YOLOv8 documentation,” Ultralytics, 2023.

[9] T. Ojala, M. Pietikäinen, and D. Harwood, “A comparative study of texture measures,” *Pattern Recognition*, vol. 29, no. 1, pp. 51–59, 2018.

[10] M. Turk and A. Pentland, “Eigenfaces for recognition,” *Journal of Cognitive Neuroscience*, vol. 3, no. 1, pp. 71–86, 2019.

[11] J. I. Mujidah et al., “KLASIFIKASI TINGKAT KEMATANGAN LADA

MENGGUNAKAN ENSEMBLE LEARNING BERDASARKAN CITRA WARNA KULIT," J. Inform. Prog., vol. 17, no. 2, pp. 1–11, Sep. 2025, doi: 10.56708/progres.v17i2.467.

[12] W. Zhao, R. Chellappa, P. J. Phillips, and A. Rosenfeld, "Face recognition: A literature survey," *ACM Computing Surveys*, vol. 35, no. 4, pp. 399–458, 2018.

[13] H. Wang et al., "CosFace: Large margin cosine loss for deep face recognition," in *Proc. IEEE CVPR*, 2018, pp. 5265–5274.

[14] J. Deng et al., "ArcFace: Additive angular margin loss for deep face recognition," in *Proc. IEEE CVPR*, 2019, pp. 4690–4699.

[15] Sarina et al., "KLASIFIKASI PENYAKIT TANAMAN NILAM BERDASARKAN CITRA DAUN MENGGUNAKAN GLCM DAN SVM," J. Inform. Prog., vol. 17, no. 2, pp. 12–22, Sep. 2025, doi: 10.56708/progres.v17i2.469.

[16] S. Z. Li and A. K. Jain, *Handbook of Face Recognition*, 2nd ed. London, UK: Springer, 2019.

[17] R. Girshick, "Fast R-CNN," in *Proc. IEEE ICCV*, 2015, pp. 1440–1448.

[18] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," in *Proc. IEEE CVPR*, 2016, pp. 770–778.

[19] A. Andayani, "Perbandingan metode CNN dan YOLO pada sistem pengenalan wajah," *Jurnal Ilmiah FIFO*, vol. 15, no. 2, pp. 85–94, 2023.

[20] B. Lestari, "Implementasi CNN untuk pengenalan wajah mahasiswa," *Jurnal Ilmiah FIFO*, vol. 14, no. 1, pp. 33–41, 2022.

[21] S. Akbar et al., "IMPLEMENTASI K-MEANS DAN ANALISIS SENTIMEN KRITIK SARAN BERBASIS NLP PADA DATA MONEV BBPSDMP KOMINFO MAKASSAR," J. Inform. Prog., vol. 17, no. 2, pp. 36–43, Sep. 2025, doi: 10.56708/progres.v17i2.465.

[22] D. Santoso, "Deteksi wajah real-time menggunakan YOLOv5," *Jurnal Teknologi Informasi*, vol. 8, no. 3, pp. 210–218, 2023.

[23] M. Rahman, "Evaluation of YOLOv8 for face detection performance," *International Journal of Computer Vision Systems*, vol. 12, no. 1, pp. 55–66, 2025.

[24] A. M. Akbar DB, M. Faisal, and M. AM Hayat, "IMPLEMENTASI HYBRID CNN, FACIAL LANDMARK DAN LIVENESS DETECTION PADA SISTEM ABSENSI WAJAH," J. Inform. Prog., vol. 17, no. 2, pp. 116–120, Sep. 2025, doi: 10.56708/progres.v17i2.483.