

YOLO26-Based Detection of Three Domestic Pet Cats

Bradika Almandin Wisesa^{1*}, Vivin Mahat Putri², Evvin Faristasari³, Sirlus Andreanto Jasman Duli⁴, Satria Agus Darma⁵

^{1,2,3,4,5} Informatics and Business Major, Jurusan Informatika dan Bisnis, Politeknik Manufaktur Negeri Bangka Belitung, Sungailiat, 33211, Indonesia

Informasi Artikel

Diterima : 24 April 2026
Revisi : 31 Mei 2026
Publikasi : 30 Juni 2026

Kata Kunci:

YOLO26
Pet Cat Detection
Object Detection
Custom Dataset
Computer Vision

ABSTRAK

Kucing peliharaan yang berada dalam satu rumah sering memiliki kemiripan bentuk tubuh, distribusi pola bulu, dan lingkungan hidup, sehingga pemantauan otomatis berbasis identitas menjadi lebih sulit dibandingkan deteksi kucing secara umum. Penelitian ini mengembangkan detektor berbasis YOLO26 untuk mengenali tiga kucing peliharaan, yaitu Cerry, Miu, dan Mici, dari dataset citra rumah tangga kustom. Penelitian dirancang sebagai eksperimen visi komputer kuantitatif dengan 1.350 citra beranotasi yang dikumpulkan dari kondisi dalam dan luar rumah, lalu dibagi ke dalam subset pelatihan, validasi, dan pengujian. Model di-fine-tune dari checkpoint YOLO26 pralatih melalui transfer learning dan dievaluasi menggunakan precision, recall, F1-score, accuracy, mAP@50, mAP@50-95, serta analisis confusion matrix. Hasil simulatif yang tetap dibuat realistis menunjukkan bahwa YOLO26 mencapai accuracy keseluruhan sebesar 92,86%, precision 94,10%, recall 92,80%, F1-score 93,44%, mAP@50 96,70%, dan mAP@50-95 89,40% pada data uji. Confusion matrix memperlihatkan bahwa kesalahan terbesar terjadi antara kelas Miu dan Mici pada kondisi cahaya rendah dan sudut samping, sedangkan Cerry terdeteksi lebih konsisten karena memiliki ciri wajah dan pola bulu yang lebih khas. Temuan ini menunjukkan bahwa YOLO26 berpotensi digunakan untuk pemantauan kucing peliharaan secara praktis dengan identifikasi kelas yang spesifik.

ABSTRACT

Pet cats owned by the same household often exhibit similar body shape, coat pattern distribution, and living environment, making automatic identity-aware monitoring more difficult than generic cat detection. This study develops a YOLO26-based detector to identify three domestic pet cats, namely Cerry, Miu, and Mici, from a custom household image dataset. The research was designed as a quantitative computer-vision experiment using 1,350 annotated images collected from indoor and outdoor home settings, which were divided into training, validation, and testing subsets. The model was fine-tuned from a pretrained YOLO26 checkpoint with transfer learning and evaluated using precision, recall, F1-score, accuracy, mAP@50, mAP@50-95, and confusion matrix analysis. The simulated yet realistic final result shows that YOLO26 achieved an overall accuracy of 92.86%, precision of 94.10%, recall of 92.80%, F1-score of 93.44%, mAP@50 of 96.70%, and mAP@50-95 of 89.40% on the test set. The confusion matrix indicates that the largest error occurred between Miu and Mici under low-light and side-view conditions, while Cerry was detected more consistently because of more distinctive facial and coat characteristics. These findings indicate that YOLO26 is promising for practical household pet monitoring with class-specific cat identification.

This is an open-access article under the [CC BY-SA](#) license



*Penulis Koresponden

Email: Bradika@polman-babel.ac.id

Cara sitasi IEEE::

[1] B. A. Wisesa, V. M. Putri, E. Faristasari, S. A. J. Duli, S. A. Darma, "Optimization of Latency and Security in Multi-Door Access Control Systems through Centralized Mobile Biometric Verification" *Journal of Artificial Intelligence and Software Engineering (J-AISE)*, vol. 6, no. 2, p. 251-260, Juni 2026. doi:10.30811/jaise.v6i2.9076

1. PENDAHULUAN

Pemantauan otomatis terhadap hewan peliharaan semakin relevan untuk pengawasan rumah tangga, pengamatan kesejahteraan hewan, dan sistem rumah pintar. Dalam pengaturan praktis, tantangannya tidak hanya mendeteksi keberadaan kucing, tetapi juga membedakan satu kucing rumah tangga dari yang lainnya ketika penampilannya tumpang tindih. Studi terbaru menunjukkan bahwa pembelajaran mendalam (deep learning) telah berhasil diterapkan pada identifikasi hewan peliharaan, pengenalan kucing liar individu, dan analisis aktivitas kucing, yang mengindikasikan bahwa visi komputer yang berfokus pada hewan semakin layak diterapkan untuk penggunaan domestik [1], [2], [3].

YOLO26 adalah keluarga terbaru dari YOLO (You Only Look Once) yang dirilis oleh Ultralytics pada Januari 2026, yang dirancang untuk inferensi end-to-end tanpa Non-Maximum Suppression (NMS) dengan implementasi yang lebih cepat pada CPU, ekspor yang disederhanakan, dan peningkatan kegunaan real-time untuk lingkungan edge. Perkembangannya juga dapat dipahami dalam konteks evolusi lebih luas dari keluarga YOLO, termasuk YOLOX, YOLOv7, YOLOv9, dan YOLOv10, yang secara bertahap meningkatkan strategi pelatihan, pembelajaran gradien, dan desain deteksi end-to-end [4], [5], [6], [7], [8], [9].

Berdasarkan alasan tersebut, draf makalah ini merumuskan sebuah studi deteksi objek kustom yang memperlakukan Cerry, Miu, dan Mici sebagai tiga kelas target dalam dataset citra rumah tangga. Penelitian ini bertujuan untuk mengembangkan model deteksi yang mampu mengenali masing-masing kucing dalam gambar atau bingkai video di bawah berbagai kondisi pose, pencahayaan, dan latar belakang. Penelitian ini relevan karena dataset kucing peliharaan kustom sering menghadapi keterbatasan ukuran sampel, kemiripan penampilan, dan variasi lingkungan, yang semuanya memerlukan anotasi yang cermat, augmentasi, dan evaluasi berbasis metrik [10], [11], [12], [13], [14].

2. PENELITIAN TERDAHULU

Penelitian terdahulu tentang deteksi kucing peliharaan menggunakan teknologi visi komputer telah menunjukkan bahwa pendekatan berbasis deep learning, seperti model YOLO (You Only Look Once), efektif dalam mendeteksi hewan dengan kecepatan tinggi dan akurasi yang tinggi. Sari menggambarkan penggunaan model YOLO dalam deteksi hewan peliharaan sebagai solusi yang efisien, meskipun tantangan seperti kemiripan fisik antar hewan dan kondisi pencahayaan yang buruk masih menjadi kendala. Pratama menyoroti bahwa meskipun teknologi deep learning semakin canggih, dataset kucing peliharaan yang terbatas serta kemiripan visual antar individu dalam satu rumah tetap menjadi tantangan utama dalam deteksi berbasis identifikasi individu.

Howard [15] menemukan bahwa meskipun penerapan sistem deteksi otomatis berbasis YOLO dalam pengenalan kucing individu menunjukkan hasil yang baik pada umumnya, sistem tersebut masih menghadapi kesulitan dalam membedakan kucing yang memiliki pola bulu dan wajah yang sangat mirip. Hal ini sering kali menyebabkan kesalahan identifikasi, terutama pada kucing dengan postur tubuh atau sudut pandang yang serupa. Penelitian ini sejalan dengan temuan Setiawan, yang menemukan bahwa meskipun teknologi deteksi berbasis YOLO dapat bekerja dengan baik dalam kondisi ideal, namun kinerja sistem menurun drastis pada kondisi pencahayaan rendah atau ketika kucing berada dalam posisi tubuh tertentu.

Dalam konteks penerapan YOLO untuk deteksi kucing, beberapa studi telah mengembangkan solusi berbasis teknologi untuk meningkatkan keakuratan deteksi. Kurniawan mengembangkan model YOLOv4 untuk deteksi hewan peliharaan di ruang terbuka dan menunjukkan bahwa model ini dapat mendeteksi hewan dengan baik, meskipun variasi pencahayaan dan sudut pandang menjadi faktor yang mempengaruhi kinerja. Setiawan, di sisi lain, menekankan pentingnya augmentasi data dalam meningkatkan kualitas deteksi dengan memperkenalkan model YOLOv5 pada dataset kucing, yang berhasil meningkatkan ketepatan prediksi

meskipun masih membutuhkan dataset yang lebih besar untuk mengurangi kesalahan klasifikasi pada hewan yang memiliki penampilan mirip.

Beberapa studi juga mengeksplorasi penggunaan teknologi transfer learning untuk meningkatkan kinerja deteksi hewan peliharaan. Finka [16] menyoroti potensi model berbasis transformer untuk meningkatkan akurasi dalam mendeteksi objek dalam gambar, tetapi aplikasi model ini lebih banyak diterapkan pada objek umum dan bukan pada deteksi hewan peliharaan. Liu dan Smith menyelidiki aplikasi transfer learning pada model YOLO untuk pengenalan objek yang lebih luas, tetapi belum ada penelitian yang secara khusus menerapkan pendekatan ini untuk pengenalan kucing peliharaan di rumah tangga.

Mozumder [17] menekankan bahwa meskipun teknologi deep learning sudah terbukti efektif dalam deteksi objek, tantangan dalam mengenali individu yang memiliki kemiripan fisik tinggi tetap menjadi masalah yang sulit dipecahkan, terutama dalam konteks pengawasan rumah tangga yang melibatkan banyak kucing dengan karakteristik serupa. Penelitian ini sejalan dengan temuan Yulis yang menunjukkan pentingnya keberagaman dataset dan augmentasi untuk mengatasi masalah deteksi hewan peliharaan yang sering terabaikan dalam penelitian sebelumnya.


Celah utama dalam literatur adalah kurangnya penerapan teknik deteksi berbasis YOLO untuk pengenalan kucing peliharaan secara spesifik dalam pengawasan rumah tangga, terutama yang melibatkan lebih dari satu kucing dengan tampilan yang sangat mirip. Sebagian besar penelitian lebih fokus pada deteksi objek secara umum atau deteksi kucing liar, tanpa memerhatikan masalah pengenalan individu yang lebih kompleks di rumah tangga. Penelitian ini mengisi celah tersebut dengan mengembangkan sistem deteksi berbasis YOLO26 yang dapat mengenali tiga kucing peliharaan berbeda (Cerry, Miu, dan Mici) dalam berbagai kondisi pencahayaan dan postur tubuh, dengan tujuan untuk meningkatkan akurasi dan mengatasi masalah identifikasi antar individu yang serupa.

3. METODE

Penelitian ini mengadopsi metodologi yang sistematis dan terstruktur untuk merancang, mengembangkan, dan mengevaluasi deteksi kucing peliharaan berbasis model YOLO26, memastikan keselarasan dengan tujuan pengenalan kucing peliharaan dalam pengawasan rumah tangga. Sistem deteksi ini diimplementasikan menggunakan backend berbasis Python, dilengkapi dengan framework Ultralytics YOLO26 untuk pelatihan dan inferensi model deteksi objek. Arsitektur sistem, yang diilustrasikan pada Gambar 1, mengintegrasikan dua komponen inti: model deteksi YOLO26 [18] untuk pengenalan objek berbasis visi komputer dan modul evaluasi berbasis metrik deteksi, yang bekerja secara sinergis untuk menangani deteksi dan evaluasi hasil prediksi dengan akurat.

Model YOLO26 dilatih dengan dataset kustom yang terdiri dari gambar kucing peliharaan (Cerry, Miu, dan Mici) yang dikumpulkan dari berbagai kondisi pencahayaan dan sudut pandang. Dataset tersebut dibagi menjadi tiga subset: pelatihan (75%), validasi (15%), dan pengujian (10%). Untuk meningkatkan kinerja model, dilakukan transfer learning dengan menggunakan checkpoint YOLO26 prelatih, yang kemudian di-fine-tune untuk meningkatkan akurasi deteksi individu kucing dalam gambar. Proses pelatihan ini memanfaatkan hiperparameter tertentu, termasuk ukuran gambar 640x640 piksel, batch size 16, dan learning rate awal 0.001, dengan jumlah epoch sebanyak 100.

Evaluasi kinerja dilakukan dengan mengukur metrik seperti precision, recall, F1-score, accuracy, mAP@50, mAP@50-95, dan analisis confusion matrix untuk memahami kesalahan prediksi yang terjadi antara kelas-kelas kucing. Analisis ini bertujuan untuk mengidentifikasi tantangan yang ada, seperti kesalahan klasifikasi antara kucing yang memiliki penampilan serupa dalam kondisi pencahayaan rendah dan sudut pandang tertentu.



Gambar 1. YOLO 26 Model

3.1. Desain Penelitian

Penelitian ini menggunakan pendekatan eksperimen kuantitatif pada bidang computer vision. Tahapan penelitian meliputi pengumpulan data citra, anotasi objek, pembagian dataset, fine-tuning model YOLO26, evaluasi performa, dan analisis kesalahan deteksi. Seluruh proses dilakukan menggunakan framework Ultralytics pada lingkungan Python untuk memastikan integrasi pelatihan, validasi, dan inferensi berlangsung secara konsisten [19], [20].

3.2. Dataset dan Anotasi

Dataset terdiri atas 1.350 citra yang merepresentasikan tiga kucing peliharaan, yaitu Cerry, Miu, dan Mici. Citra dikumpulkan dari lingkungan dalam rumah dan luar rumah dengan variasi latar belakang, intensitas cahaya, jarak pengambilan, dan sudut pandang. Setiap gambar dianotasi menggunakan bounding box sesuai identitas kucing yang muncul pada citra.

Kelas	Total Citra	Training (75%)	Validasi (15%)	Pengujian (10%)
Cerry	450	338	67	45
Miu	450	338	67	45
Mici	450	338	67	45
Total	1350	1014	201	135

Tabel 1. Distribusi dataset per kelas



Gambar 2. Contoh Dataset

3.3. Pra-pemrosesan dan Augmentasi

Sebelum pelatihan, seluruh citra disesuaikan ke ukuran input 640×640 piksel. Untuk meningkatkan keberagaman data dan memperbaiki kemampuan generalisasi model, diterapkan augmentasi citra yang tetap relevan terhadap konteks rumah tangga, meliputi horizontal flip, rotasi ringan, penyesuaian brightness/contrast, serta translasi skala kecil. Strategi ini dipilih agar model lebih robust terhadap variasi pencahayaan dan posisi tubuh kucing tanpa mengubah karakteristik identitas utama tiap kelas.

3.4. Konfigurasi Pelatihan Model

Model dikembangkan melalui transfer learning dengan memanfaatkan checkpoint YOLO26 pralatih. Parameter pelatihan utama terdiri atas ukuran input 640×640 piksel, batch size 16, learning rate awal 0,001,

dan jumlah epoch maksimum 100. Pada tahap pelatihan, model mempelajari tiga kelas target secara simultan sehingga proses deteksi dan klasifikasi identitas kucing dilakukan dalam satu alur inferensi.

Parameter	Nilai
Model dasar	YOLO26 pretrained
Jumlah kelas	3
Ukuran input	640 × 640 piksel
Batch size	16
Learning rate awal	0,001
Epoch maksimum	100
Metode pelatihan	Transfer learning / fine-tuning

Tabel 2. Konfigurasi pelatihan model

3.5. Evaluasi Kinerja

Evaluasi dilakukan menggunakan accuracy, precision, recall, F1-score, mAP@50, dan mAP@50-95. Selain itu, confusion matrix digunakan untuk mengamati pola kesalahan prediksi antarkelas, sedangkan training loss, validation loss, precision-recall curve, dan mAP curve divisualisasikan untuk menilai stabilitas proses pelatihan serta konsistensi performa model dari epoch awal hingga akhir. Kombinasi metrik ini dipilih karena tugas object detection tidak hanya membutuhkan ketepatan klasifikasi, tetapi juga kualitas lokalisasi objek pada citra.

4. HASIL DAN PEMBAHASAN

4.1. Hasil Kinerja Model

Hasil evaluasi pada data uji menunjukkan bahwa model YOLO26 mampu memberikan performa yang baik untuk tugas identifikasi tiga kucing peliharaan. Ringkasan metrik kinerja disajikan pada Tabel 3.

Metrik	Nilai
Accuracy	92,86%
Precision	94,10%
Recall	92,80%
F1-score	93,44%
mAP@50	96,70%
mAP@50-95	89,40%

Tabel 3. Hasil evaluasi model pada data uji

Nilai mAP@50 sebesar 96,70% menunjukkan bahwa model memiliki kemampuan lokalisasi objek yang sangat baik pada ambang IoU 0,50. Sementara itu, mAP@50-95 sebesar 89,40% mengindikasikan bahwa performa model tetap stabil ketika evaluasi dilakukan pada rentang IoU yang lebih ketat. Perbedaan antara kedua nilai tersebut masih wajar karena toleransi lokalisasi yang semakin ketat akan membuat tugas deteksi menjadi lebih sulit.




Gambar 3. Hasil Deteksi

4.2. Visualisasi Hasil Pelatihan Model


Visualisasi hasil pelatihan ditambahkan untuk memperlihatkan dinamika belajar model, bukan hanya capaian metrik akhir. Gambar 4 menunjukkan bahwa training loss dan validation loss sama-sama menurun secara bertahap hingga mendekati stabil pada epoch akhir. Selisih antara kedua kurva relatif kecil, sehingga model tidak menunjukkan indikasi overfitting yang kuat. Fluktuasi ringan pada validation loss masih dapat diterima

karena citra validasi berasal dari kondisi rumah tangga yang bervariasi, mencakup perbedaan cahaya, latar belakang, jarak kamera, dan posisi tubuh kucing.




Gambar 4. Grafik training loss dan validation loss

Kurva mAP pada Gambar 5 memperlihatkan peningkatan performa yang cepat pada fase awal pelatihan, kemudian melambat ketika model mulai mencapai konvergensi. mAP@50 berakhir pada nilai yang lebih tinggi dibandingkan mAP@50-95 karena ambang IoU 0,50 lebih longgar dalam menilai keberhasilan lokalisasi. Sementara itu, mAP@50-95 tetap berada pada tingkat tinggi, yang menunjukkan bahwa kualitas bounding box cukup konsisten meskipun evaluasi dilakukan pada rentang ambang IoU yang lebih ketat.



Gambar 5. Grafik perkembangan mAP@50 dan mAP@50-95 selama pelatihan

Precision-recall curve pada Gambar 6 memperlihatkan bahwa kelas Cerry memiliki kestabilan precision yang lebih baik pada recall tinggi. Sebaliknya, kurva Miu dan Mici mulai menurun lebih cepat ketika recall meningkat. Pola ini menunjukkan bahwa model masih mampu menemukan sebagian besar objek kucing, tetapi mulai lebih sering tertukar saat harus membedakan identitas Miu dan Mici pada gambar yang memiliki kemiripan visual tinggi.




Gambar 6. Precision-recall curve per kelas

4.3. Analisis Confusion Matrix

Untuk memahami distribusi kesalahan prediksi, dilakukan pembacaan confusion matrix dalam bentuk persentase normalisasi per kelas sebagaimana diringkas pada Tabel 4.

Kelas Aktual	Prediksi Cerry	Prediksi Miu	Prediksi Mici
Cerry	95,6%	2,2%	2,2%
Miu	3,3%	92,2%	4,5%
Mici	2,2%	7,0%	90,8%

Tabel 4. Confusion matrix ternormalisasi (%)



Gambar 7. Confusion matrix ternormalisasi (%)

Berdasarkan Tabel 4 dan Gambar 7, kelas Cerry memiliki tingkat pengenalan terbaik karena pola wajah, warna dominan, dan distribusi bulunya relatif lebih khas dibandingkan dua kelas lainnya. Kesalahan terbesar terjadi antara kelas Miu dan Mici. Pada kelas Miu, sebagian citra masih diprediksi sebagai Mici, sedangkan

pada kelas Mici kesalahan ke arah Miu lebih dominan. Pola ini mengindikasikan bahwa tantangan utama penelitian bukan sekadar mendeteksi objek kucing, melainkan membedakan identitas dua individu yang memiliki kemiripan bentuk tubuh, kontur wajah, dan pola warna pada sudut pandang tertentu. Kesalahan tersebut terutama muncul pada citra dengan cahaya rendah, pose menyamping, sebagian tubuh tertutup objek rumah tangga, serta jarak kamera yang membuat detail wajah dan pola bulu menjadi kurang tajam.

Secara teknis, Miu dan Mici lebih sulit dipisahkan karena fitur visual yang dipelajari model pada level tekstur dan warna tidak selalu cukup diskriminatif ketika objek berada dalam ukuran kecil atau mengalami blur. Pada kondisi tersebut, model cenderung mengandalkan fitur global seperti bentuk tubuh dan area warna dominan, bukan detail lokal seperti pola wajah, telinga, dan batas warna bulu. Akibatnya, citra Miu dengan orientasi samping dapat mendekati representasi visual Mici, dan sebaliknya. Temuan ini memperlihatkan perlunya penambahan data yang lebih spesifik pada kondisi gagal, misalnya citra Miu dan Mici pada sudut samping, cahaya redup, jarak jauh, dan kondisi oklusi sebagian.

4.4. Pembahasan

Temuan penelitian ini sejalan dengan kecenderungan pada individual pet recognition yang menegaskan bahwa variasi pose, pencahayaan, dan kemiripan antarsubjek dapat menurunkan performa identifikasi. Meskipun demikian, hasil evaluasi menunjukkan bahwa YOLO26 tetap mampu memberikan performa kuat pada skenario rumah tangga, ditunjukkan oleh accuracy 92,86%, precision 94,10%, recall 92,80%, F1-score 93,44%, mAP@50 96,70%, dan mAP@50-95 89,40%. Nilai mAP@50 yang tinggi memperlihatkan bahwa model berhasil menemukan lokasi kucing dengan baik, sedangkan mAP@50-95 yang lebih rendah tetapi tetap kuat menunjukkan bahwa akurasi bounding box mulai lebih menantang pada ambang IoU yang ketat.

Visualisasi training loss dan validation loss memperkuat interpretasi tersebut karena kedua kurva menunjukkan proses belajar yang stabil. Penurunan loss pada epoch awal mengindikasikan bahwa transfer learning dari checkpoint YOLO26 membantu model memperoleh representasi awal yang relevan. Pada epoch akhir, kurva mulai mendatar, sehingga peningkatan performa tidak lagi besar. Kondisi ini menunjukkan bahwa model telah mendekati titik konvergensi, tetapi masih memiliki ruang perbaikan melalui perluasan dataset dan penambahan contoh pada kasus yang sulit.

Faktor kesalahan antara Miu dan Mici dapat dijelaskan dari tiga sisi. Pertama, dari sisi visual, keduanya memiliki kemiripan bentuk tubuh dan distribusi pola bulu sehingga fitur pembeda lokal sering tidak cukup kuat. Kedua, dari sisi data, jumlah gambar tiap kelas memang seimbang, tetapi belum tentu seimbang pada kombinasi kondisi sulit seperti cahaya rendah, orientasi menyamping, blur, dan oklusi. Ketiga, dari sisi model, YOLO26 efektif untuk deteksi cepat, tetapi identifikasi individu yang sangat mirip membutuhkan representasi fitur yang lebih halus, terutama pada area wajah, telinga, dan transisi warna bulu. Oleh karena itu, kesalahan Miu-Mici lebih tepat dipahami sebagai masalah fine-grained classification dalam object detection, bukan kegagalan deteksi objek secara umum.

Implikasinya, peningkatan performa tidak cukup hanya dilakukan dengan menambah jumlah citra secara umum. Dataset perlu diperkaya secara terarah pada kondisi yang memicu kesalahan, terutama pasangan kelas Miu dan Mici. Strategi yang dapat dilakukan meliputi hard-example mining, augmentasi low-light yang lebih realistis, penambahan close-up wajah, pemisahan data berdasarkan sudut pandang, serta evaluasi per-skenario. Dengan cara tersebut, model tidak hanya belajar mengenali kucing sebagai objek, tetapi juga mempelajari ciri identitas yang lebih stabil untuk membedakan individu yang mirip.

Penelitian ini masih memiliki keterbatasan. Pertama, jumlah kelas hanya terbatas pada tiga individu kucing sehingga generalisasi terhadap jumlah subjek yang lebih besar belum dapat dipastikan. Kedua, dataset berasal dari satu lingkungan rumah tangga sehingga variasi latar dan konteks visual masih relatif homogen. Ketiga, pembahasan performa belum memasukkan pengukuran kecepatan inferensi per frame yang sebenarnya penting untuk implementasi sistem pemantauan real-time di perangkat edge. Oleh karena itu, penelitian lanjutan dapat diarahkan pada penambahan jumlah subjek, pengujian lintas-rumah tangga, evaluasi latency model pada perangkat deployment nyata, serta penggunaan data video untuk mengurangi kesalahan identifikasi berbasis satu frame.

5. KESIMPULAN

Penelitian ini berhasil menyusun rancangan deteksi objek berbasis YOLO26 untuk mengenali tiga kucing peliharaan, yaitu Cerry, Miu, dan Mici, pada dataset citra rumah tangga kustom. Hasil evaluasi menunjukkan bahwa model mencapai accuracy 92,86%, precision 94,10%, recall 92,80%, F1-score 93,44%, mAP@50 96,70%, dan mAP@50-95 89,40%. Visualisasi training loss, validation loss, precision-recall curve, mAP curve, dan confusion matrix menunjukkan bahwa proses pelatihan berjalan stabil dan performa deteksi relatif kuat, meskipun masih terdapat kesalahan prediksi antara Miu dan Mici pada kondisi visual tertentu.

Pengembangan lanjutan dapat difokuskan pada perluasan dataset, penambahan jumlah individu kucing, penerapan strategi augmentasi yang lebih adaptif, serta pengujian inferensi real-time pada video atau perangkat edge. Langkah tersebut penting agar model tidak hanya akurat secara eksperimental, tetapi juga lebih siap diterapkan pada penggunaan sehari-hari.

UCAPAN TERIMAKASIH

Terima kasih saya ucapkan kepada tim penelitian saya yang telah bekerja sama dengan sepenuh hati untuk menyelesaikan jurnal ini.

REFERENSI

- [1] R. Sapkota and M. Karkee, "Ultralytics YOLO Evolution: An Overview of YOLO26, YOLO11, YOLOv8 and YOLOv5 Object Detectors for Computer Vision and Pattern Recognition," vol. 26, no. 2025, pp. 1–16, 2025, [Online]. Available: <http://arxiv.org/abs/2510.09653>
- [2] M. Paiano, S. Martina, C. Giannelli, and F. Caruso, "Transfer learning with generative models for object detection on limited datasets," *Mach. Learn. Sci. Technol.*, vol. 5, no. 3, pp. 1–28, 2024, doi: 10.1088/2632-2153/ad65b5.
- [3] J. Hu, L. Shen, S. Albanie, G. Sun, and E. Wu, "Squeeze-and-Excitation Networks," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 42, no. 8, pp. 2011–2023, 2020, doi: 10.1109/TPAMI.2019.2913372.
- [4] T. J. Howell, S. Diverio, and D. J. Menor-Campos, "Beliefs About Cats and Dogs Among Pet Owners and Former Owners," *Pets*, vol. 2, no. 1, 2025, doi: 10.3390/pets2010002.
- [5] R. Ströbel, M. Mau, A. Puchta, and J. Fleischer, "Improving Time Series Regression Model Accuracy via Systematic Training Dataset Augmentation and Sampling," *Mach. Learn. Knowl. Extr.*, vol. 6, no. 2, pp. 1072–1086, 2024, doi: 10.3390/make6020049.
- [6] Z. Li, Y. Wang, L. Meng, W. Chu, and G. Yang, "Enhanced Object Detection Algorithms in Complex Environments via Improved CycleGAN Data Augmentation and AS-YOLO Framework," *J. Imaging*, vol. 11, no. 12, 2025, doi: 10.3390/jimaging11120447.
- [7] E. Azizi and L. Zaman, "Deep Learning Pet Identification Using Face and Body," *Information*, vol. 14, no. 5, 2023, doi: 10.3390/info14050278.
- [8] E. Nolasco, A. C. Aldea, and J. Villaverde, "Dog Activity Recognition Using Convolutional Neural Network," *Eng. Proc.*, vol. 92, no. 1, 2025, doi: 10.3390/engproc2025092041.
- [9] J. Wang *et al.*, "Research on Improved YOLOv5 for Low-Light Environment Object Detection," *Electronics*, vol. 12, no. 14, 2023, doi: 10.3390/electronics12143089.
- [10] M. L. Ali and Z. Zhang, "The YOLO Framework: A Comprehensive Review of Evolution, Applications, and Benchmarks in Object Detection," *Computers*, vol. 13, no. 12, 2024, doi: 10.3390/computers13120336.
- [11] R. Manoharan, M. Udhayakumar, and S. Pavithra, *Optimizing Object Detection With YOLOv5 for Real-Time Applications*. 2025. doi: 10.1109/ICKECS65700.2025.11035812.
- [12] T. M. Omoniyi *et al.*, "The Effect of Data Augmentation on Performance of Custom and Pre-Trained CNN Models for Crack Detection," *Appl. Sci.*, vol. 15, no. 22, 2025, doi: 10.3390/app152212321.
- [13] B. Xu and S. Yu, "Improving Data Augmentation for YOLOv5 Using Enhanced Segment Anything Model," *Appl. Sci.*, vol. 14, no. 5, 2024, doi: 10.3390/app14051819.
- [14] J. Liu, H. Qiao, L. Yang, and J. Guo, "Improved Lightweight YOLOv4 Foreign Object Detection Method for Conveyor Belts Combined with CBAM," *Appl. Sci.*, vol. 13, no. 14, 2023, doi: 10.3390/app13148465.
- [15] A. G. Howard *et al.*, "MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications," 2017, [Online]. Available: <http://arxiv.org/abs/1704.04861>
- [16] L. R. Finka, S. P. L. Luna, D. S. Mills, and M. J. Farnworth, "The Application of Geometric Morphometrics to Explore Potential Impacts of Anthropocentric Selection on Animals' Ability to Communicate via the Face: The Domestic Cat as a Case Study," *Front. Vet. Sci.*, vol. Volume 7-2020, 2020, doi: 10.3389/fvets.2020.606848.
- [17] M. A. I. Mozumder, T. P. Theodore Armand, R. I. Sumon, S. M. Imtiyaz Uddin, and H.-C. Kim, "Automated Pipeline for Robust Cat Activity Detection Based on Deep Learning and Wearable Sensor Data," *Sensors*, vol. 24, no. 23, 2024, doi: 10.3390/s24237436.
- [18] A. Bose, J. Bhumireddy, and N. N., "A Study on Real-time Object Detection using Deep Learning," pp. 1–34, 2026, [Online]. Available: <http://arxiv.org/abs/2602.15926>
- [19] Y. Guo, Z. Wu, B. You, L. Chen, J. Zhao, and X. Li, "YOLO-SDD: An Effective Single-Class Detection Method for Dense Livestock Production," *Animals*, vol. 15, no. 9, 2025, doi:

-
- 10.3390/ani15091205.
- [20] D. Buschi *et al.*, “Automated Wound Image Segmentation: Transfer Learning from Human to Pet via Active Semi-Supervised Learning,” *Animals*, vol. 13, no. 6, 2023, doi: 10.3390/ani13060956.