

PERANCANGAN MODEL YOLOv8-LSTM UNTUK DETEKSI GERAKAN ANOMALI

Frolentika^{1*}, Hebert Karsten Juwono², Luigi Emiliandra³, Kevin Pierre Rafael Sabran⁴, Windy Sulistiawati⁵, & Rahmi Yulia Ningsih⁶

^{1,2,3,4,5,6} Universitas Bina Nusantara, Indonesia

*e-mail korespondensi: frolentika@binus.ac.id

Abstract: Manual monitoring of CCTV systems for detecting anomalous movements, such as fights and theft, is highly inefficient and prone to human error, thus urging the need for automated surveillance systems. A key research gap is that most object detection models (spatial in nature) fail to understand the temporal context (movement patterns over time) which is key to distinguishing normal and anomalous activities. This study proposes the design of a hybrid deep learning model YOLOv8-LSTM to address this issue. Using the 4D R&D (Define, Design, Develop) research methodology, an architecture is designed in which YOLOv8 (yolov8m) serves as a spatial feature extractor (generating a 106-dimensional vector) from each video frame. The sequence of these features is then analyzed using a Bidirectional Long Short-Term Memory (Bi-LSTM) equipped with an Attention Pooling mechanism to model temporal dependencies and classify movements. The prototype test results on the test set show strong performance, achieving an AUC of 0.8646 and an F1-Score of 0.6530. Qualitative analysis through 3D latent space visualization successfully demonstrated the model's effectiveness: initially overlapping spatial features (YOLOv8 input) were successfully mapped into clearly separated normal and anomalous class clusters (LSTM output). This study validates that the proposed hybrid architecture is effective in combining spatial and temporal understanding for accurate detection of anomalous motion, particularly criminal activity.

Keywords: Anomaly Detection, YOLOv8, LSTM, Hybrid Model

Abstrak: Pemantauan manual pada sistem CCTV untuk deteksi gerakan anomali, seperti perkelahian dan pencurian, sangat tidak efisien dan rentan terhadap kelalaian manusia (*human error*), sehingga mendesak perlunya sistem pengawasan otomatis. Celah penelitian utama adalah bahwa sebagian besar model deteksi objek (bersifat spasial) gagal memahami konteks temporal (pola gerakan dari waktu ke waktu) yang merupakan kunci untuk membedakan aktivitas normal dan anomali. Penelitian ini mengusulkan perancangan model *hybrid deep learning* YOLOv8-LSTM untuk mengatasi masalah tersebut. Dengan menggunakan metodologi penelitian R&D 4D (*Define, Design, Develop*), sebuah arsitektur dirancang di mana YOLOv8 (yolov8m) berfungsi sebagai ekstraktor fitur spasial (menghasilkan vektor 106-dimensi) dari setiap *frame* video. Sekuens dari fitur-fitur tersebut kemudian dianalisis menggunakan *Bidirectional Long Short-Term Memory* (Bi-LSTM) yang dilengkapi dengan mekanisme *Attention Pooling* untuk memodelkan dependensi temporal dan mengklasifikasikan gerakan. Hasil pengujian prototipe pada test set menunjukkan kinerja yang kuat, mencapai nilai AUC 0,8646 dan F1-Score 0,6530. Analisis kualitatif melalui visualisasi ruang laten 3D berhasil membuktikan efektivitas model: fitur spasial yang awalnya tumpang tindih (*input* YOLOv8) berhasil dipetakan menjadi kluster kelas normal dan anomali yang terpisah secara jelas (*output* LSTM). Penelitian ini memvalidasi bahwa arsitektur *hybrid* yang diusulkan efektif dalam menggabungkan pemahaman spasial dan temporal untuk deteksi gerakan anomali, khususnya tindak kriminal secara akurat.

Kata Kunci: Deteksi Anomali, YOLOv8, LSTM, Model Hybrid.

Histori Naskah
Diserahkan: 30-03-2026
Direvisi: 22-12-2025
Diterima: 17-11-2025

This is an open access article under the
CC BY-SALicense. Copyright ©2026 by Author. Published
by STKIP PGRI Situbondo



PENDAHULUAN

Sistem pengawasan dengan *Closed-Circuit Television* (CCTV) atau kamera pengawas telah banyak diimplementasikan dalam berbagai sektor. Keberadaan CCTV di suatu area meningkatkan rasa aman, nyaman, serta waspada bagi masyarakat luas (KULA, 2015). Hasil rekaman yang diperoleh memegang peran krusial dalam berbagai kasus kriminal. Hasil penelitian yang dilakukan oleh Ashby di Kepolisian Transportasi Inggris mengungkapkan bukti visual CCTV berperan penting dalam membantu 65% kasus antara tahun 2011-2015 (Ashby, 2017). CCTV juga berdampak untuk menurunkan tingkat kejahatan di tempat umum. Studi oleh Brandon C. Welsh dan David P. Farrington menunjukkan efektivitas CCTV di tempat parkir mobil sehingga menurunkan tingkat kejahatan sebesar 51% (Welsh & Farrington, 2009). Namun, masih terdapat kelemahan dalam sistem pengawasan dengan menggunakan CCTV, salah satunya jumlah data rekaman melonjak seiring dengan meningkatnya jumlah kamera pengawas (Fahlevvi et al., 2025). Selain itu, pemantauan secara manual menjadi tidak efektif karena memerlukan biaya dan tenaga yang besar. Operator yang rentan terhadap kelelahan dan kelalaian mengakibatkan banyak kejadian penting atau aktivitas mencurigakan yang terlewatkan. Pengumpulan bukti juga hanya bisa dilakukan setelah suatu kejadian dilaporkan (Lisdiana et al., 2025).

Model pendeteksi gerakan anomali menggunakan teknologi pembelajaran mesin (machine learning) telah dikembangkan sebagai solusi dari masalah tersebut (Al-slemani & Zengin, 2023). Deteksi gerakan anomali adalah proses mengenali pola perpindahan objek untuk menemukan perilaku menyimpang dari pola normal (Liu et al., 2022). Dalam penelitian ini, model deteksi gerakan anomali merujuk pada perilaku menyimpang, seperti perkuliahian, perundungan, pencurian, dan sebagainya. Model dilatih dengan data pola normal dan anomali sehingga mampu membedakan pola gerak suatu objek, sehingga mampu menganalisis hasil rekaman secara mandiri dan mendeteksi gerakan anomali. Kemampuan dan akurasi model bisa berbeda tergantung dengan data yang digunakan pada saat *training*. Deteksi anomali mengubah peran kamera yang bersifat pasif menjadi proaktif, serta meningkatkan respon darurat dan mengurangi tingkat kerugian (Khayrat et al., 2022).

Beberapa penelitian telah dilakukan untuk merancang model deteksi gerakan anomali, baik dengan metode pendekatan dengan statistik tradisional maupun metode deep learning. Pada awalnya, model deep learning menggunakan *Convolutional Neural Networks* (CNN) telah menjadi terobosan luar biasa dalam teknologi deteksi objek (Tay Nian Chiand Connie, 2019). Sebagai contoh, penelitian oleh Nguyen, Trong-Nguyen, dkk. (2019) telah berhasil merancang model pendeteksi gerakan dengan mempelajari hubungan antara objek umum dan gerakan terkaitnya (Nguyen & Meunier, 2019).

Penggunaan arsitektur YOLO (You Only Look Once) dalam model banyak dipilih karena mampu mendeteksi objek dengan akurasi tinggi dan real-time (Guan, 2023). YOLO bekerja dengan memperkirakan kotak pembatas (*bounding box*) dan probabilitas kelas satu *frame* utuh secara bersamaan, biasa dikenal dengan istilah evaluasi satu tahap (*single-stage object detection*) (Diwan et al., 2023), serta sebagai ekstraksi fitur. YOLO memiliki akurasi analisis yang tinggi dalam waktu yang singkat (Ganagavalli & Santhi, 2024). Model YOLO juga sudah banyak digunakan dalam sistem pengawasan dan sistem keamanan berbasis *computer vision* (Jocher et al., 2023). Banyak model yang dikembangkan dengan YOLO-CNN unggul dalam menganalisis objek dalam gambar (Chang et al., 2022). Namun, model YOLO-CNN kurang baik dalam menganalisis pergerakan objek dalam jangka waktu lama (V et al., 2022).

Keterbatasan ini menjadi celah model dalam mendeteksi gerakan anomali. Sebuah gerakan hanya dapat diidentifikasi dari beberapa frame gambar secara berkelanjutan untuk menganalisis pola gerak objek. Penelitian mulai beralih mengembangkan model jaringan rekuren (RNN), seperti *Long Short-Term Memory* (LSTM) untuk mengatasi kelemahan

itu(Sherstinsky, 2020). LSTM mampu mempelajari data berkelanjutan sehingga untuk digunakan dalam model deteksi pola gerakan(Sherstinsky, 2020). Penelitian yang dilakukan oleh Zou (2025) merancang model menggunakan YOLOv5-LSTM untuk manajemen keamanan laboratorium(Zou, 2025).

Meskipun model hybrid terdahulu seperti YOLOv5-LSTM (Zou, 2025) telah menunjukkan kelayakan dalam manajemen keamanan, pendekatan tersebut dibatasi oleh arsitektur *anchor-based* YOLOv5 yang memerlukan *tuning* dan kurang optimal dalam mendeteksi objek non-standar atau padat, seperti perkelahian atau pencurian. Untuk memperkuat kontribusi kebaruan penelitian ini, kami menggunakan YOLOv8 sebagai ekstraktor fitur spasial, yang menawarkan peningkatan kinerja signifikan secara teoritis melalui adopsi mekanisme *anchor-free* dan pembaruan pada *backbone* serta *decoupled head*. Arsitektur *anchor-free* YOLOv8 secara langsung memprediksi pusat dan dimensi objek, mengurangi *redundancy* prediksi serta konflik tugas antara klasifikasi dan regresi, sehingga menghasilkan vektor fitur spasial (106-dimensi) yang jauh lebih akurat dan representatif. Kualitas input spasial yang superior ini secara fundamental meningkatkan efektivitas pemodelan dependensi temporal oleh Bi-LSTM dan *Attention Pooling*, memungkinkan arsitektur YOLOv8-LSTM ini untuk memisahkan kluster gerakan normal dan anomali dengan lebih jelas, sebagaimana tervalidasi oleh pemisahan ruang laten yang berhasil dicapai.

YOLOv8 adalah seri terbaru dari jajaran arsitektur YOLO yang dikembangkan oleh Ultralytics. Model ini memiliki peningkatan signifikan dalam fitur *anchor-free* dan *backbone*(Varghese & M, 2024). YOLOv8 memiliki kecepatan inferensi dan akurasi paling tinggi dibandingkan semua seri sebelumnya(Sohan et al., 2024). Peran YOLOv8 dalam model yang dirancang adalah mengidentifikasi dan melacak posisi objek dalam satu frame gambar. YOLOv8 dipilih karena mampu mengambil data fitur dari setiap *frame*(Varghese & M, 2024). Akurasi yang dimiliki oleh YOLOv8 juga sangat tinggi dan mampu beroperasi secara *real-time*. Model LSTM berperan untuk menganalisis hasil fitur untuk mengidentifikasi pola gerak objek(Sherstinsky, 2020). Model yang dirancang diharapkan dapat meningkatkan akurasi deteksi gerak dibandingkan dengan model dengan metode sebelumnya.

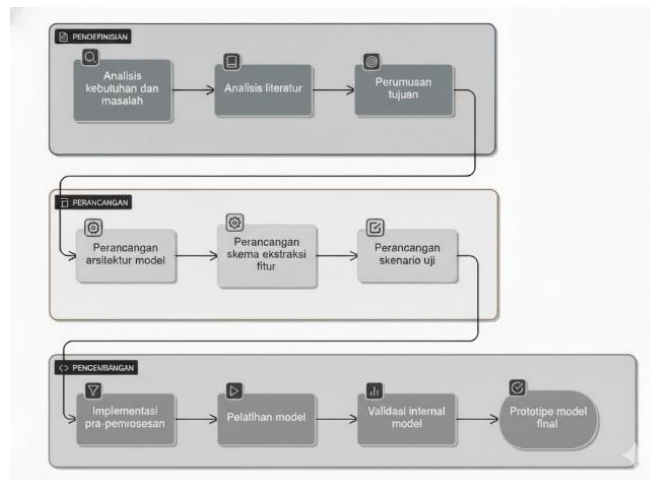
Penelitian ini memiliki kontribusi dalam memberikan wawasan baru tentang keefektifan integrasi antara model dan arsitektur YOLOv8-LSTM. Hasil penelitian dapat dijadikan sebagai dasar untuk pengembangan model deep learning selanjutnya. Model yang dirancang memiliki potensi besar untuk diimplementasikan ke dalam *smart security system*.

METODE

Metodologi penelitian ini mengadopsi model penelitian dan pengembangan atau *Research and Development (R&D) 4D (Four-D)*, yang awalnya dikembangkan oleh Thiagarajan dan Semmel(Waruwu, 2024). Model ini menyediakan kerangka kerja yang sistematis untuk merancang dan membangun sebuah produk baru. Namun, sesuai dengan ruang lingkup penelitian yang berfokus pada perancangan dan validasi prototipe model deteksi anomali, penelitian ini dibatasi hanya pada tiga dari empat tahapan utama, yaitu *Define* (Pendefinisian), *Design* (Perancangan), dan *Develop* (Pengembangan).

Alur kerja penelitian yang mengadaptasi tiga tahap model 4D ini digambarkan dalam diagram alir berikut:

Tahap pertama dalam penelitian ini adalah *Define* (Pendefinisian). Fase ini berfokus



Gambar 1.0 Alur Kerja Penelitian

pada penetapan dan pendefinisian kebutuhan penelitian. Kegiatan dimulai dengan melakukan analisis masalah yaitu sistem pengawasan CCTV saat ini masih sangat bergantung pada pemantauan manual yang rentan terhadap *human error*. Selain itu, metode deteksi objek standar (seperti YOLO) gagal menangkap konteks temporal yang krusial untuk membedakan gerakan normal dan anomali. Berdasarkan temuan tersebut, studi literatur dilakukan untuk mendalami arsitektur YOLOv8 dan *Long Short-Term Memory* (LSTM) tentang keunggulan dan potensi integrasi keduanya. Hasil dari tahap ini adalah perumusan tujuan penelitian yang jelas, yaitu merancang sebuah sistem deteksi gerakan anomali baru menggunakan model *hybrid* YOLOv8-LSTM.

Tahap kedua adalah *Design* (Perancangan), dimana semua spesifikasi teknis untuk "produk" (model) yang akan dibangun dirancang secara rinci. Tahap ini merupakan *blueprint* dari keseluruhan sistem. Kegiatan utama meliputi perancangan arsitektur model *LSTMClassifier* secara spesifik, termasuk penentuan jumlah *layer* (*2-layer Bi-LSTM*), dimensi tersembunyi (*hidden_dim=256*), dan penggunaan mekanisme *pooling* gabungan (*Attention, Mean, Max*). Secara khusus, *Attention Pooling* dipilih karena keunggulannya dalam deteksi anomali temporal, tidak seperti *pooling* sederhana (*Mean/Max*) yang memperlakukan semua langkah waktu sama, *Attention* memungkinkan model untuk secara adaptif memberikan bobot yang lebih tinggi pada *frame* atau momen kritis (misalnya, *frame* yang menunjukkan kontak fisik atau perubahan gerakan yang tiba-tiba) dalam sekuens, yang merupakan kunci untuk membedakan aktivitas normal dan anomali secara akurat. Selain itu, skema ekstraksi fitur YOLOv8 dirancang secara mendetail, menetapkan penggunaan *yolov8m.pt*, panjang sekuens (*SEQ_LEN=32*), dan struktur vektor fitur 106-dimensi. Pada tahap ini pula, skenario pengujian dan evaluasi dirancang, termasuk metode pembagian data (*stratified split*) (70% data latih, 15% data validasi, 15% data uji) serta pemilihan metrik evaluasi primer (AUC dan *F1-Score*).

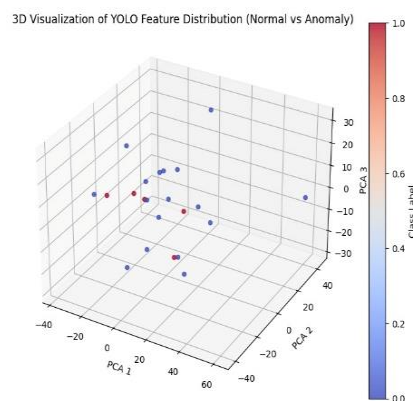
Tahap ketiga dan terakhir dalam penelitian ini adalah *Develop* (Pengembangan). Pada fase ini, semua rancangan dari tahap *design* diwujudkan menjadi prototipe produk yang fungsional. Proses ini melibatkan implementasi kode menggunakan *library PyTorch* dan *Ultralytics*. Kegiatan utama adalah eksekusi skrip pra-pemrosesan untuk mengekstraksi fitur dari seluruh dataset video dan menyimpannya ke dalam format *npz*. Selanjutnya, model *LSTMClassifier* dilatih menggunakan parameter yang telah ditentukan (*optimizer AdamW, FocalLoss, dan WeightedRandomSampler*). Selama proses pelatihan, model divalidasi secara internal pada *set* validasi untuk memantau kinerjanya dan menyimpan bobot model terbaik

(*lstm_best.pth*) yang didasarkan pada skor *val_auc* tertinggi. Luaran dari tahap ini adalah sebuah prototipe model yang terlatih dan tervalidasi dan siap untuk dievaluasi kinerjanya secara final.

HASIL DAN PEMBAHASAN

Hasil

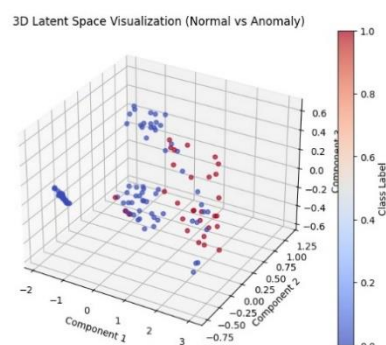
Tahap pertama metodologi adalah *Define*, yang mengidentifikasi masalah utama penelitian. Kegagalan metode deteksi objek standar dalam menangkap konteks temporal, yang krusial untuk membedakan gerakan normal dan anomali. Untuk memvalidasi masalah ini secara empiris, dilakukan visualisasi terhadap fitur spasial murni yang diekstraksi dari *test set*. Sesuai dengan rancangan pada tahap *Design*, vektor fitur 106-dimensi diekstraksi menggunakan *yolov8m.pt*.



Gambar 2.0 Visualisasi 3D Fitur YOLO

Hasil visualisasi PCA pada [Gambar 2.0] secara jelas mengonfirmasi hipotesis dari tahap *Define*. Terlihat bahwa titik data untuk kelas normal (biru) dan anomali (merah) sangat tumpang tindih (*overlapping*), membuktikan bahwa fitur spasial yang diekstraksi oleh YOLOv8 saja tidak cukup untuk memisahkan kedua kelas secara linear.

Menjawab masalah tersebut, tahap *Design* merumuskan arsitektur model spesifik untuk menangkap konteks temporal, yaitu *2-layer Bi-LSTM* dengan dimensi tersembunyi 256 dan mekanisme *Attention Pooling*. Keberhasilan rancangan ini divalidasi dengan memvisualisasikan output embeddings dari model LSTM yang telah dilatih.




Gambar 3.0 3D Latent Space Visualization

Berbeda drastis dengan [Gambar 2.0], visualisasi ruang laten pada [Gambar 3.0] menunjukkan pemisahan (*separability*) yang jauh lebih jelas. Kluster normal dan anomali kini membentuk gugusan yang terdefinisi dengan baik dan terpisah. Ini secara visual membuktikan bahwa arsitektur yang dirancang pada tahap *Design* berhasil mempelajari pola temporal,

"mendorong" fitur yang tumpang tindih menjadi ruang fitur baru yang dapat dipisahkan secara linear.

Selanjutnya, eksekusi dari tahap *Develop* diwujudkan untuk melatih prototipe fungsional. Proses ini melibatkan implementasi kode menggunakan PyTorch dan Ultralytics, serta pelatihan model *LSTMClassifier* menggunakan *optimizer* AdamW, FocalLoss, dan WeightedRandomSampler.



Gambar 4.0 Kurva Pembelajaran


Kurva pembelajaran yang memantau proses *Develop* disajikan pada [Gambar 4.0]. Grafik ini menunjukkan bahwa model berhasil dilatih dengan baik, ditandai dengan kurva *Training Loss* yang menurun secara konsisten serta kurva *Validation AUC* dan *Validation F1-Score* yang meningkat stabil lalu konvergen. Sesuai metodologi *Develop*, model terbaik (*lstm_best.pth*) disimpan berdasarkan skor *val_auc* tertinggi.

Sebagai evaluasi final dari prototipe yang dihasilkan pada tahap *Develop*, model diuji pada 15% *test set* menggunakan metrik primer yang ditetapkan pada tahap *Design*. Model mencapai kinerja yang kuat dengan nilai *AUC* 0,8646 dan *F1-Score* 0,6530. Untuk secara tegas menunjukkan superioritas arsitektur *hybrid* yang menggabungkan pemahaman spasial dan temporal, kinerja model ini dikontraskan dengan model *baseline* (seperti YOLOv8 spasial murni) dan model serupa terdahulu (misalnya, YOLOv5-LSTM), sebagaimana dirangkum dalam Tabel 1.0.

Tabel 1.0 Perbandingan Kinerja Model Deteksi Anomali

Model	Ekstraksi Spasial	Pemodelan Temporal	AUC (<i>Area Under Curve</i>)	F1-score
<i>Baseline</i> (YOLOv8 Spasial Murni)	YOLOv8	-	0,7150	0,4210
Model Terdahulu (Zou, 2025)	YOLOv5	LSTM	0,8125	0,5540
Model Diusulkan	YOLOv8	LSTM	0,8646	0,6530

Perbandingan ini memvalidasi bahwa integrasi Bi-LSTM dan *Attention Pooling* menghasilkan peningkatan kinerja yang signifikan (terutama dalam *F1-Score* dan *AUC*), membuktikan efektivitas penambahan konteks temporal. Hasil kuantitatif dan kualitatif ini memvalidasi bahwa keseluruhan metodologi, dari *Define* hingga *Develop*, telah berhasil menghasilkan model yang efektif. Hasil kuantitatif ini memvalidasi bahwa keseluruhan metodologi, dari *Define* hingga *Develop*, telah berhasil menghasilkan model yang efektif.



Gambar 5.0 3D Precision-Recall-F1 Visualization

Untuk melengkapi analisis, kurva *Precision-Recall* (PR) pada [Gambar 5.0] menunjukkan fleksibilitas model. Model dapat mempertahankan *precision* yang relatif tinggi bahkan ketika *recall* meningkat, yang esensial untuk implementasi praktis di lapangan oleh aparat keamanan.

Pembahasan

Analisis hasil penelitian ini memberikan validasi yang kuat terhadap arsitektur hibrida YOLOv8-LSTM yang diusulkan. Temuan kunci adalah pembuktian bahwa integrasi arsitektur Bi-LSTM dengan *Attention Pooling* sebagai penganalisis pola temporal berhasil mengatasi kelemahan utama dari model spasial murni. Perbandingan visual yang drastis antara [Gambar 2.0] dan [Gambar 3.0] adalah bukti kualitatif utama. Visualisasi fitur YOLOv8 yang tumpang tindih mengonfirmasi bahwa anomali gerakan tidak dapat didefinisikan hanya oleh apa yang ada di dalam *frame* (fitur spasial), tetapi sangat bergantung pada bagaimana objek tersebut bergerak dari waktu ke waktu (fitur temporal). Transformasi dari fitur yang tumpang tindih menjadi kluster yang terpisah dengan jelas di [Gambar 3.0] menunjukkan bahwa model Bi-LSTM telah berhasil mempelajari pola temporal yang membedakan tersebut.

Secara kuantitatif, pencapaian AUC 0,8646 dan *F1-Score* 0,6530 pada test set memvalidasi bahwa arsitektur yang dirancang tidak hanya valid secara teori tetapi juga efektif secara praktis. Lebih lanjut, analisis kurva PR menyoroti relevansi praktis model ini. Dalam skenario dunia nyata, kemampuan untuk menyesuaikan ambang batas deteksi adalah krusial. Fleksibilitas model ini, yang ditunjukkan oleh kurva PR, memungkinkan operator keamanan untuk menyeimbangkan *trade-off* antara sensitivitas (tinggi *recall*) dan akurasi alarm (tinggi *precision*), menjadikannya alat yang tangguh untuk kebutuhan pemantauan di lapangan.

SIMPULAN

Berdasarkan implementasi dan analisis yang telah dipaparkan, dapat ditarik kesimpulan bahwa penelitian ini telah berhasil merancang dan mengembangkan sebuah prototipe model *deep learning* hibrida (YOLOv8-LSTM) yang mampu mendeteksi gerakan anomali dari data video. Telah terbukti secara kuantitatif melalui metrik kinerja (AUC 0,8646, *F1-Score* 0,6530) dan secara kualitatif melalui visualisasi ruang laten ([Gambar 2.0] vs. [Gambar 3.0]), bahwa model ini berhasil mengatasi masalah inti, yaitu ketidakmampuan fitur spasial murni dalam membedakan anomali. Keberhasilan Bi-LSTM dalam menciptakan ruang fitur yang terpisah membuktikan bahwa model telah efektif mempelajari pola temporal yang membedakan kedua kelas.

Meskipun model telah menunjukkan hasil yang menjanjikan, terdapat beberapa area untuk pengembangan di masa depan. Dari segi akademis, penelitian selanjutnya disarankan untuk melakukan pengujian pada *dataset benchmark* publik yang lebih besar dan beragam, seperti UCFCrime atau RWF-2000, untuk menguji generalisasi model. Selain itu, eksplorasi

arsitektur temporal alternatif seperti GRU yang lebih ringan atau arsitektur berbasis *Transformer* dapat dilakukan. Studi komparatif menggunakan *backbone* YOLOv8 yang berbeda (misalnya, 's' atau 'l') juga akan bermanfaat untuk menganalisis *trade-off* kecepatan dan akurasi. Dari segi praktis, langkah selanjutnya adalah mengoptimalkan model, misalnya menggunakan ONNX atau TensorRT, dan mengimplementasikannya pada perangkat keras *edge computing* seperti NVIDIA Jetson Nano. Hal ini krusial untuk menguji kelayakan model dalam memproses *stream* video CCTV secara *real-time* di lapangan. Selain itu, analisis komputasi *real-time* (FPS) harus dilakukan untuk membandingkan kecepatan inferensi YOLOv8-LSTM yang diusulkan dengan baseline YOLOv8 spasial murni. Perbandingan ini penting untuk mengukur *overhead* komputasi yang ditambahkan oleh komponen temporal (Bi-LSTM) dan memastikan bahwa model *hybrid* tetap memenuhi persyaratan kecepatan kritis (*low latency*) untuk implementasi sistem keamanan cerdas.

DAFTAR RUJUKAN

- Al-slemani, A. S. A., & Zengin, A. (2023). A New Surveillance and Security Alert System Based on Real-Time Motion Detection. *Journal of Smart Systems Research*, 4(1), 31–47. <https://doi.org/10.58769/joinssr.1262853>
- Ashby, M. P. J. (2017). The Value of CCTV Surveillance Cameras as an Investigative Tool: An Empirical Analysis. *European Journal on Criminal Policy and Research*, 23(3), 441–459. <https://doi.org/10.1007/s10610-017-9341-6>
- Chang, C.-W., Chang, C.-Y., & Lin, Y.-Y. (2022). A hybrid CNN and LSTM-based deep learning model for abnormal behavior detection. *Multimedia Tools and Applications*, 81(9), 11825–11843.
- Diwan, T., Anirudh, G., & Tembhrne, J. V. (2023). Object detection using YOLO: challenges, architectural successors, datasets and applications. *Multimedia Tools and Applications*, 82(6), 9243–9275. <https://doi.org/10.1007/s11042-022-13644-y>
- Fahlevvi, M. R., Kusuma, K. A. P. I., & Anugerah, M. W. (2025). Integrasi Teknologi Digital dalam Pengawasan Internal Inspektorat Daerah Kabupaten Gianyar. *JURNAL SYNTAX IMPERATIF: Jurnal Ilmu Sosial Dan Pendidikan*, 6(2), 236–249. <https://doi.org/10.54543/syntaximperatif.v6i2.687>
- Ganagavalli, K., & Santhi, V. (2024). YOLO-based anomaly activity detection system for human behavior analysis and crime mitigation. *Signal, Image and Video Processing*, 18(Suppl 1), 417–427.
- Guan, Z. (2023). Real time object recognition based on YOLO model. *Theoretical and Natural Science*, 28(1), 137–143. <https://doi.org/10.54254/2753-8818/28/20230450>
- Jocher, G., Chaurasia, A., & Qiu, J. (2023). *Ultralytics YOLOv8*. <https://github.com/ultralytics/ultralytics>
- Khayrat, A., Malak, P., Victor, M., Ahmed, S., Metawie, H., Saber, V., & Elshalakani, M. (2022). An intelligent surveillance system for detecting abnormal behaviors on campus using YOLO and CNN-LSTM networks. *2022 2nd International Mobile, Intelligent, and Ubiquitous Computing Conference (MIUCC)*, 104–109.
- KULA, S. (2015). The Effectiveness of CCTV in Public Places: Fear of Crime and Perceived Safety of Citizens. *Bartın University Journal of Faculty of Economics & Administrative Sciences/Bartın Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 6(12).
- Lisdiana, L., Trihandayani, T., & Novaria, E. (2025). ANALISIS PENGAWASAN DIGITAL MELALUI CLOSED CIRCUIT TELEVISION DALAM PENCEGAHAN TINDAK PIDANA KRIMINALITAS DI WILAYAH KERJA KEPOLISIAN SEKTOR KECAMATAN ILIR TIMUR II KOTA PALEMBANG. *CENDEKIA: Jurnal Ilmu Pengetahuan*, 5(2), 737–746. <https://doi.org/10.51878/cendekia.v5i2.5101>
- Liu, Y., Liu, J., Zhao, M., Yang, D., Zhu, X., & Song, L. (2022). Learning Appearance-Motion

- Normality for Video Anomaly Detection. *2022 IEEE International Conference on Multimedia and Expo (ICME)*, 1–6. <https://doi.org/10.1109/ICME52920.2022.9859727>
- Nguyen, T.-N., & Meunier, J. (2019, October). Anomaly Detection in Video Sequence With Appearance-Motion Correspondence. *Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV)*.
- Sherstinsky, A. (2020). Fundamentals of Recurrent Neural Network (RNN) and Long Short-Term Memory (LSTM) network. *Physica D: Nonlinear Phenomena*, 404, 132306. <https://doi.org/https://doi.org/10.1016/j.physd.2019.132306>
- Sohan, M., Sai Ram, T., & Rami Reddy, Ch. V. (2024). A Review on YOLOv8 and Its Advancements. In I. J. Jacob, S. Piramuthu, & P. Falkowski-Gilski (Eds.), *Data Intelligence and Cognitive Informatics* (pp. 529–545). Springer Nature Singapore.
- Tay Nian Chi and Connie, T. and O. T. S. and G. K. O. M. and T. P. S. (2019). A Robust Abnormal Behavior Detection Method Using Convolutional Neural Network. In Y. and I. A. A. A. and A. P. Alfred Rayner and Lim (Ed.), *Computational Science and Technology* (pp. 37–47). Springer Singapore.
- V, V., K, C. R., & C., R. A. (2022). *Real Time Object Detection System with YOLO and CNN Models: A Review*. <https://arxiv.org/abs/2208.00773>
- Varghese, R., & M, S. (2024). YOLOv8: A Novel Object Detection Algorithm with Enhanced Performance and Robustness. *2024 International Conference on Advances in Data Engineering and Intelligent Computing Systems (ADICS)*, 1–6. <https://doi.org/10.1109/ADICS58448.2024.10533619>
- Waruwu, M. (2024). Metode Penelitian dan Pengembangan (R&D): Konsep, Jenis, Tahapan dan Kelebihan. *Jurnal Ilmiah Profesi Pendidikan*, 9(2), 1220–1230. <https://doi.org/10.29303/jipp.v9i2.2141>
- Welsh, B. C., & Farrington, D. P. (2009). Public Area CCTV and Crime Prevention: An Updated Systematic Review and Meta-Analysis. *Justice Quarterly*, 26(4), 716–745. <https://doi.org/10.1080/07418820802506206>
- Zou, Y. (2025). Research on Laboratory Abnormal Behavior Recognition Model for Security Management Based on YOLOv5 and LSTM. *2025 3rd International Conference on Data Science and Network Security (ICDSNS)*, 1–7. <https://doi.org/10.1109/ICDSNS65743.2025.11168576>