

Pengembangan Sistem Deteksi Kerumunan Berbasis Edge Computing untuk Mendukung Monitoring Cerdas pada Lingkungan Smart City

Rudy Abmi Ansyari Pane^{1*}, Trio Adiono², Ali Akhmad Ghifari³

¹³Politeknik Negeri Bandung, Bandung, Indonesia

²Institut Teknologi Bandung, Bandung, Indonesia

*Corresponding Author: rudy.abmi@polban.ac.id

Artikel Penelitian

Diterima 30 Desember 2025; Disetujui 26 Februari 2026

Cara sitasi: Pane, R.A.A., Adiono, R., Ghifari, A.A. (2026). Pengembangan Sistem Deteksi Kerumunan Berbasis Edge Computing untuk Mendukung Monitoring Cerdas pada Lingkungan Smart City. *SIGMA-Mu*, 18(2), 01-13.

Abstrak: Perkembangan smart city menuntut sistem monitoring kerumunan yang mampu bekerja secara real-time, namun sistem berbasis cloud masih menghadapi kendala latensi dan kebutuhan bandwidth tinggi. Penelitian ini bertujuan mengembangkan sistem deteksi kerumunan berbasis *edge computing* untuk meningkatkan efisiensi dan responsivitas sistem. Metode yang digunakan adalah pendekatan kuantitatif dengan eksperimen untuk mengukur kinerja sistem berdasarkan parameter latency, frame rate (FPS), serta akurasi menggunakan precision, recall, dan mean Average Precision (mAP). Hasil penelitian menunjukkan bahwa sistem memiliki latency sebesar 40–60 ms per frame dan mampu mencapai 24 FPS, sehingga memenuhi kriteria real-time. Tingkat akurasi yang diperoleh sebesar 91,6% pada data real-time dan 95,8% pada data video. Meskipun demikian, sistem masih memiliki keterbatasan pada kondisi lingkungan yang kompleks seperti *occlusion* dan variasi pencahayaan. Secara keseluruhan, sistem yang dikembangkan efektif untuk mendukung monitoring cerdas pada lingkungan smart city.

Kata kunci: Edge Computing, Deteksi Kerumunan, Real-Time, Smart City, Deep Learning

Abstract: The development of smart cities requires real-time crowd monitoring systems; however, cloud-based approaches still face challenges such as high latency and bandwidth demands. This study aims to develop an edge computing-based crowd detection system to improve system efficiency and responsiveness. A quantitative experimental approach was employed to evaluate system performance based on latency, frame rate (FPS), and accuracy metrics, including precision, recall, and mean Average Precision (mAP). The results show that the system achieves a latency of 40–60 ms per frame and operates at 24 FPS, meeting real-time processing requirements. The system achieves an accuracy of 91.6% on real-time data and 95.8% on video data. However, limitations remain under complex environmental conditions such as occlusion and lighting variations. Overall, the proposed system is effective for supporting intelligent monitoring in smart city environments.

Keywords: Edge Computing, Crowd Detection, Real-Time, Smart City, Deep Learning

1. Pendahuluan

Perkembangan teknologi informasi dan komunikasi dalam beberapa dekade terakhir telah mendorong lahirnya konsep *smart city* sebagai solusi untuk meningkatkan kualitas hidup masyarakat urban melalui pemanfaatan teknologi digital. *Smart city* mengintegrasikan berbagai sistem seperti transportasi, keamanan, lingkungan, dan pelayanan publik berbasis data secara real-time. Salah satu komponen utama dalam *smart city* adalah sistem pengawasan berbasis video (CCTV) yang digunakan untuk memonitor aktivitas masyarakat dan mendukung pengambilan keputusan secara cepat dan akurat (Sun et al., 2026).

Seiring dengan meningkatnya jumlah perangkat IoT dan kamera pengawas di berbagai kota besar, volume data video yang dihasilkan juga meningkat secara eksponensial. Hal ini menimbulkan tantangan baru dalam pengolahan data, khususnya dalam mendeteksi kerumunan secara real-time. Sistem konvensional berbasis *cloud computing* seringkali mengalami kendala berupa latensi tinggi dan kebutuhan bandwidth yang besar, sehingga tidak efisien untuk aplikasi real-time (Kozłowski & Badurowicz, 2025). Sebagai alternatif, *edge computing* hadir sebagai paradigma baru yang memungkinkan pemrosesan data dilakukan di dekat sumber data (*edge device*), sehingga mampu mengurangi latensi dan beban jaringan secara signifikan. Pendekatan ini sangat relevan untuk aplikasi berbasis video seperti deteksi kerumunan, di mana kecepatan respon menjadi faktor kritis (Wang et al., 2022).

Dalam konteks pengelolaan kerumunan, deteksi jumlah dan kepadatan manusia menjadi aspek penting untuk menjamin keamanan publik, khususnya pada area dengan mobilitas tinggi seperti transportasi umum, pusat perbelanjaan, dan event berskala besar. Penelitian terbaru menunjukkan bahwa sistem deteksi kerumunan berbasis deep learning mampu memberikan akurasi tinggi, namun masih menghadapi tantangan dalam implementasi pada perangkat dengan sumber daya terbatas (Khan et al., 2025). Lebih lanjut, integrasi antara teknologi kecerdasan buatan (AI), *edge computing*, dan Internet of Things (IoT) membuka peluang besar dalam pengembangan sistem monitoring cerdas yang adaptif dan responsif. Dalam hal ini, sistem deteksi kerumunan tidak hanya berfungsi sebagai alat pemantauan, tetapi juga sebagai bagian dari sistem pengambilan keputusan otomatis dalam ekosistem *smart city* (Manduva, 2024). Namun demikian, implementasi sistem deteksi kerumunan berbasis *edge computing* masih menghadapi berbagai tantangan, seperti keterbatasan sumber daya perangkat, kebutuhan model yang ringan namun akurat, serta integrasi sistem yang kompleks. Oleh karena itu, diperlukan pendekatan yang mampu mengoptimalkan kinerja sistem dengan mempertimbangkan efisiensi komputasi dan akurasi deteksi secara simultan.

Dalam implementasi sistem monitoring berbasis video pada lingkungan *smart city*, salah satu permasalahan utama yang dihadapi adalah keterbatasan arsitektur *cloud computing* dalam mendukung pemrosesan data secara real-time. Peningkatan jumlah perangkat kamera pengawas menghasilkan volume data yang sangat besar, sehingga membutuhkan bandwidth tinggi untuk transmisi ke server pusat. Selain itu, proses pengiriman data ke cloud juga menimbulkan latensi yang berdampak pada keterlambatan analisis dan respons sistem. Menurut Shi et al. (2016), arsitektur *edge computing* dikembangkan untuk mengatasi permasalahan tersebut dengan memindahkan proses komputasi lebih dekat ke sumber data, sehingga mampu mengurangi latensi dan meningkatkan efisiensi jaringan (Shi et al., 2016).

Meskipun demikian, implementasi *edge computing* tidak terlepas dari keterbatasan, terutama terkait kapasitas komputasi perangkat *edge* yang relatif terbatas dibandingkan dengan *cloud*. Kondisi ini menjadi tantangan dalam mengimplementasikan model *deep learning* yang kompleks untuk deteksi kerumunan secara real-time. Beberapa studi menunjukkan bahwa penelitian dalam bidang deteksi kerumunan masih cenderung menitikberatkan pada pengembangan dan peningkatan performa model deteksi, seperti optimasi akurasi dan efisiensi inferensi, tanpa diimbangi dengan pengembangan sistem terintegrasi yang mempertimbangkan aspek implementasi pada perangkat *edge* secara nyata (Zhu et al., 2018) (Dansereau et al., 2019). Oleh karena itu, terdapat kesenjangan antara kebutuhan sistem monitoring modern yang menuntut integrasi, efisiensi, dan respons real-time, dengan pendekatan penelitian yang masih dominan berfokus pada aspek model secara parsial.

Berbagai penelitian telah mengkaji deteksi kerumunan berbasis kecerdasan buatan dengan pendekatan yang beragam, terutama pada aspek peningkatan akurasi model. Li et al. (2018) mengusulkan metode *CSRNet* berbasis convolutional neural network (CNN) untuk crowd counting yang mampu meningkatkan akurasi estimasi kepadatan melalui pemanfaatan *dilated convolution* (Li et al., 2018a). Selanjutnya, Liu. (2018) mengembangkan pendekatan berbasis *scale-aware network* yang mampu menangani variasi skala objek dalam citra kerumunan secara lebih efektif (Niklaus & Liu, 2018). Di sisi lain, Solanki et al. (2018) memperkenalkan metode multi-source representation untuk meningkatkan akurasi crowd counting dengan menggabungkan berbagai fitur visual (Bhanu Solanki & Tan, 2018). Kesamaan dari penelitian-penelitian tersebut terletak pada fokusnya terhadap peningkatan performa model deteksi, khususnya dalam hal akurasi dan kemampuan generalisasi terhadap kondisi kerumunan yang kompleks. Namun, penelitian tersebut umumnya masih berorientasi pada pengembangan algoritma tanpa mempertimbangkan implementasi sistem secara langsung pada perangkat dengan keterbatasan sumber daya seperti *edge device*.

Penelitian ini menawarkan kebaruan dalam bentuk pendekatan sistem yang tidak hanya berfokus pada pengembangan model deteksi kerumunan, tetapi pada integrasi menyeluruh antara komputasi, pemrosesan data, dan implementasi di lapangan. Berbeda dengan penelitian terdahulu yang umumnya menitikberatkan pada peningkatan performa algoritma secara individual, penelitian ini mengusulkan sistem deteksi kerumunan berbasis *edge computing* yang dirancang untuk dapat diimplementasikan secara langsung dalam ekosistem *smart city*. Pendekatan ini memungkinkan pemrosesan data dilakukan secara lokal pada perangkat *edge*, sehingga mampu mengurangi latensi, meningkatkan respons sistem, serta mengoptimalkan penggunaan bandwidth jaringan.

Selain itu, kebaruan penelitian ini juga terletak pada upaya optimalisasi keseimbangan antara akurasi deteksi dan efisiensi komputasi. Sistem yang dikembangkan tidak hanya ditujukan untuk mencapai tingkat akurasi tinggi, tetapi juga mempertimbangkan keterbatasan sumber daya pada perangkat *edge*, sehingga tetap mampu berjalan secara stabil dalam kondisi nyata. Penelitian ini juga melakukan *reframing* terhadap fungsi sistem deteksi kerumunan, dari yang sebelumnya hanya berfungsi sebagai alat deteksi objek, menjadi bagian integral dari sistem monitoring cerdas yang mendukung pengambilan keputusan berbasis data. Dengan demikian, pendekatan yang diusulkan lebih aplikatif dan relevan dengan kebutuhan nyata dalam pengelolaan kota cerdas, dibandingkan dengan pendekatan berbasis simulasi atau eksperimen laboratorium semata.

Tujuan utama dari penelitian ini adalah untuk mengembangkan suatu sistem deteksi kerumunan berbasis *edge computing* yang mampu beroperasi secara real-time dalam lingkungan yang dinamis. Sistem yang dikembangkan diharapkan mampu memproses data video secara langsung pada perangkat edge tanpa ketergantungan penuh pada cloud, sehingga dapat meningkatkan kecepatan respons dan efisiensi sistem secara keseluruhan. Selain itu, penelitian ini juga bertujuan untuk menghasilkan solusi yang dapat diimplementasikan secara praktis pada berbagai skenario monitoring, khususnya dalam konteks *smart city*.

Lebih lanjut, penelitian ini bertujuan untuk menganalisis kinerja sistem yang dikembangkan dari berbagai aspek, termasuk akurasi deteksi, kecepatan pemrosesan (frame rate), serta efisiensi penggunaan sumber daya komputasi. Selain itu, penelitian ini juga mengkaji bagaimana sistem tersebut dapat berkontribusi dalam mendukung monitoring cerdas berbasis kecerdasan buatan yang adaptif dan responsif terhadap kondisi lingkungan. Dengan demikian, penelitian ini diharapkan dapat memberikan kontribusi tidak hanya pada aspek teknis pengembangan sistem, tetapi juga pada penguatan konsep dan implementasi sistem pengawasan cerdas yang lebih efisien, terintegrasi, dan berkelanjutan.

2. Metode Penelitian

Penelitian ini menggunakan pendekatan **kuantitatif dengan metode eksperimen**, karena bertujuan untuk menguji kinerja sistem deteksi kerumunan berbasis *edge computing* secara terukur dan objektif. Pendekatan kuantitatif digunakan karena penelitian ini melibatkan pengukuran variabel numerik seperti akurasi, kecepatan pemrosesan, dan efisiensi komputasi, yang dianalisis menggunakan teknik statistik deskriptif (Creswell & Plano Clark, 2018). Metode eksperimen dipilih karena memungkinkan peneliti untuk mengontrol variabel tertentu dan menguji hubungan sebab-akibat antara sistem yang dikembangkan dengan hasil yang diperoleh (Sugiyono, 2018). Dengan demikian, pendekatan ini sesuai untuk mengevaluasi performa sistem dalam kondisi yang terkontrol maupun semi-real-time.

Penelitian ini dilakukan pada lingkungan simulasi *smart city* dengan menggunakan data video yang berasal dari kamera pengawas (*CCTV*) maupun dataset publik yang merepresentasikan kondisi kerumunan. Objek penelitian adalah sistem deteksi kerumunan berbasis *edge computing* yang dikembangkan, sedangkan subjek penelitian berupa data visual (video atau citra) yang mengandung objek manusia dalam berbagai tingkat kepadatan. Teknik pengumpulan data dilakukan melalui observasi, dokumentasi, dan eksperimen sistem. Observasi digunakan untuk mengamati hasil deteksi secara langsung, dokumentasi digunakan untuk merekam hasil output sistem, sedangkan eksperimen dilakukan untuk menguji sistem pada berbagai skenario. Teknik-teknik ini merupakan metode umum dalam penelitian kuantitatif eksperimental untuk memperoleh data yang valid dan reliabel (Arikunto, 2021).

Instrumen penelitian yang digunakan meliputi perangkat keras *edge computing*, perangkat lunak deteksi berbasis *deep learning*, serta lembar pengamatan untuk mencatat hasil pengujian. Penyusunan instrumen dilakukan berdasarkan indikator kinerja sistem seperti akurasi dan kecepatan pemrosesan. Validitas instrumen dijaga melalui pengujian berulang (*repeated testing*) dan perbandingan dengan data aktual (*ground truth*), sehingga hasil pengukuran dapat dipercaya.

Validitas dalam penelitian kuantitatif dapat ditingkatkan melalui konsistensi pengukuran dan penggunaan data pembandingan yang jelas.

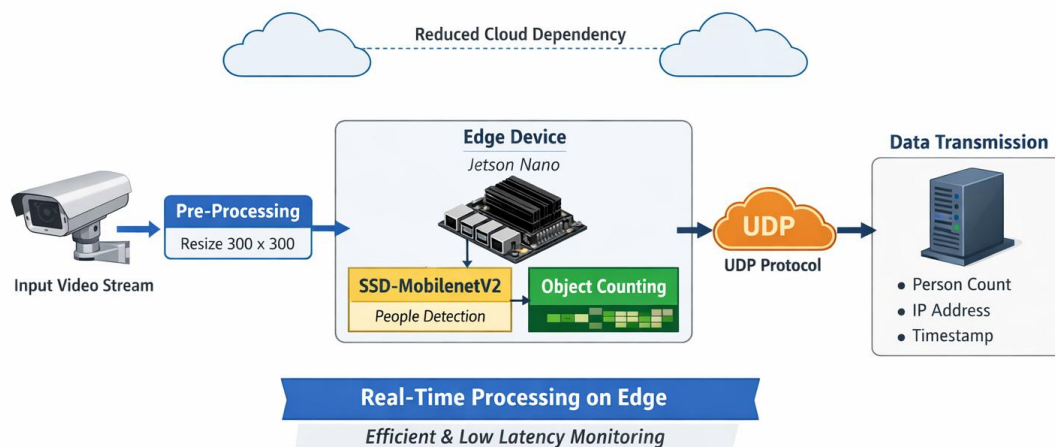
Analisis data dalam penelitian ini menggunakan analisis deskriptif kuantitatif, yaitu dengan mengolah data numerik untuk menggambarkan kinerja sistem berdasarkan parameter tertentu seperti *precision*, *recall*, *mean Average Precision (mAP)*, *frame per second (FPS)*, dan latensi. Data yang diperoleh direduksi, disajikan dalam bentuk tabel atau grafik, kemudian ditarik kesimpulan berdasarkan pola yang muncul. Proses ini mengacu pada teknik analisis data kuantitatif yang menekankan pada penyajian data secara sistematis dan interpretasi berbasis angka. Dengan demikian, hasil penelitian dapat memberikan gambaran objektif mengenai efektivitas sistem yang dikembangkan serta memungkinkan untuk direplikasi oleh peneliti lain.

3. Hasil dan Pembahasan

3.1. Arsitektur Sistem Berbasis Edge Computing

Sesuai dengan metode penelitian yang menggunakan pendekatan eksperimen berbasis sistem, arsitektur yang dikembangkan mengimplementasikan pemrosesan data langsung pada perangkat *edge*. Alur dimulai dari input video (CCTV), dilanjutkan dengan pre-processing (resize 300×300), kemudian diproses menggunakan model SSD-MobileNetV2 untuk mendeteksi objek manusia. Hasil deteksi dihitung (object counting) dan dikirim ke server melalui protokol UDP.

Hasil ini secara langsung menjawab permasalahan pada pendahuluan terkait ketergantungan pada cloud. Dengan memindahkan komputasi ke edge, sistem mampu mengurangi kebutuhan bandwidth dan mendukung pemrosesan data secara real-time, sesuai dengan tujuan penelitian untuk membangun sistem monitoring cerdas berbasis edge computing.



Gambar 1. Arsitektur Sistem Deteksi Kerumunan Berbasis Edge Computing

3.2. Hasil Pengujian Latency (Waktu Pemrosesan)

Berdasarkan hasil eksperimen yang dilakukan sesuai metode pengujian kinerja sistem, diperoleh waktu pemrosesan sebesar: **40 – 60 ms per frame**. Nilai ini diperoleh dari hasil pengukuran waktu komputasi pada setiap tahapan proses inferensi, yang meliputi *pre-processing*, *inference model*, dan *post-processing*.

```
[TRT] -----
[TRT] Timing Report networks/SSD-Mobilenet-v2/ssd_mobilenet_v2_coco.uff
[TRT] -----
[TRT] Pre-Process   CPU    0.11636ms  CUDA   1.00292ms
[TRT] Network       CPU   53.82339ms  CUDA  50.62474ms
[TRT] Post-Process  CPU    0.06802ms  CUDA   0.06833ms
[TRT] Visualize     CPU    0.32417ms  CUDA   0.89604ms
[TRT] Total         CPU   54.33194ms  CUDA  52.59203ms
[TRT] -----

[TRT] -----
[TRT] Timing Report networks/SSD-Mobilenet-v2/ssd_mobilenet_v2_coco.uff
[TRT] -----
[TRT] Pre-Process   CPU    0.08167ms  CUDA   1.06453ms
[TRT] Network       CPU   50.19358ms  CUDA  46.83015ms
[TRT] Post-Process  CPU    0.06563ms  CUDA   0.06500ms
[TRT] Visualize     CPU    0.32204ms  CUDA   0.86141ms
[TRT] Total         CPU   50.66291ms  CUDA  48.82109ms
[TRT] -----

[TRT] -----
[TRT] Timing Report networks/SSD-Mobilenet-v2/ssd_mobilenet_v2_coco.uff
[TRT] -----
[TRT] Pre-Process   CPU    3.36518ms  CUDA   1.89307ms
[TRT] Network       CPU   44.87414ms  CUDA  43.80062ms
[TRT] Post-Process  CPU    0.08026ms  CUDA   0.07042ms
[TRT] Visualize     CPU    0.38595ms  CUDA   0.88755ms
[TRT] Total         CPU   48.70552ms  CUDA  46.65166ms
[TRT] -----

[TRT] -----
[TRT] Timing Report networks/SSD-Mobilenet-v2/ssd_mobilenet_v2_coco.uff
[TRT] detected 4 objects in image
[TRT] terbaca 0 FPS
[TRT] <detectNet.Detection object>
[TRT]   -- ClassID: 1
[TRT]   -- Confidence: 0.59972
[TRT]   -- Left:    237.905
```

Gambar 2. Time used for 1 clock

Secara matematis, waktu pemrosesan total dihitung menggunakan persamaan:

$$T_{total} = T_{pre} + T_{infer} + T_{post} + T_{visual}$$

Berdasarkan salah satu hasil pengujian:

- $T_{pre} = 1.02\text{ms}$

- $T_{infer} = 52.52\text{ms}$
- $T_{post} = 0.60\text{ms}$
- $T_{visual} = 0.89\text{ms}$

sehingga diperoleh:

$$T_{total} = 1.02 + 52.52 + 0.60 + 0.89 = 55.03 \text{ ms}$$

Hasil ini menunjukkan bahwa waktu komputasi sistem berada pada kisaran 40–60 ms, yang menandakan latensi rendah dan memenuhi kriteria *real-time processing*. Nilai ini juga secara langsung menjawab permasalahan pada pendahuluan terkait tingginya latensi pada sistem berbasis cloud. Selain itu, variasi nilai waktu pemrosesan pada beberapa pengujian menunjukkan bahwa sistem memiliki performa yang relatif stabil, sehingga dapat diandalkan untuk implementasi monitoring kerumunan berbasis *edge computing*.

3.3. Hasil Pengujian Frame Rate (FPS)

Hasil pengujian menunjukkan bahwa sistem mampu mencapai: **24 FPS (Frame Per Second)**. Nilai ini menunjukkan bahwa sistem memenuhi kriteria *real-time processing*, sebagaimana yang ditargetkan dalam metode penelitian.

Frame Rate

The number of frames per second that can be executed by the system is 24 frames per second FPS.

```

counter 3
Total Person detected 3
detected 3 objects in image
terbaca 24 FPS
<detectNet.Detection object>
  -- ClassID: 1
  -- Confidence: 0.936401
  -- Left: 103.06
  -- Top: 255.653
  -- Right: 183.592
  -- Bottom: 403.617
  -- Width: 80.5321
  -- Height: 147.964
  -- Area: 11915.8
  -- Center: (143.326, 329.635)
counter 1
<detectNet.Detection object>
  -- ClassID: 64
  -- Confidence: 0.698021
  -- Left: 184.699
  -- Top: 206.095
  -- Right: 283.94
  -- Bottom: 290.257
  -- Width: 99.241
  -- Height: 84.1612
  -- Area: 8352.25
  -- Center: (234.32, 248.176)
<detectNet.Detection object>

```

Fig.7: Frame rate 24FPS

Gambar 3. Tampilan Frame Rate (24 FPS) dan Hasil Deteksi Kerumunan pada Sistem Berbasis Edge Computing

Hasil pengujian menunjukkan bahwa sistem mampu mencapai **24 FPS (Frame Per Second)**, sebagaimana ditampilkan pada Gambar 3. Nilai ini diperoleh dari proses eksekusi sistem yang mampu memproses 24 frame dalam satu detik selama proses deteksi berlangsung secara real-time. Secara matematis, frame rate dapat dihitung berdasarkan hubungan antara jumlah frame yang diproses terhadap waktu komputasi, yaitu:

$$FPS = \frac{1}{T_{frame}}$$

dengan:

- T_{frame} = waktu pemrosesan per frame (detik)

Berdasarkan hasil pengujian pada bagian sebelumnya, diketahui bahwa waktu pemrosesan berada pada kisaran:

$$T_{frame} = 40 - 60 \text{ ms} = 0.04 - 0.06 \text{ detik}$$

Sehingga secara teoritis:

$$FPS = \frac{1}{0.04} = 25 \text{ hingga } \frac{1}{0.06} \approx 16.7$$

Namun, berdasarkan hasil implementasi langsung pada sistem (Gambar 3), diperoleh nilai stabil sebesar **24 FPS**, yang menunjukkan bahwa sistem memiliki performa optimal dan mampu mempertahankan kecepatan pemrosesan secara konsisten. Selain itu, pada Gambar 3 terlihat bahwa sistem mampu:

- mendeteksi **3 objek manusia secara simultan**
- menampilkan informasi bounding box (koordinat, luas area, dan confidence score)
- memberikan output secara real-time tanpa delay signifikan

Hal ini menunjukkan bahwa sistem tidak hanya mampu mencapai nilai FPS secara teoritis, tetapi juga mampu mengimplementasikannya secara nyata pada kondisi operasional. Frame rate di atas 20 FPS menunjukkan bahwa sistem telah memenuhi kriteria *real-time processing*, sehingga mampu melakukan pemantauan kerumunan secara kontinu tanpa jeda signifikan. Jika dikaitkan dengan pendahuluan, capaian ini memperkuat bahwa pendekatan *edge computing* mampu mengatasi keterbatasan sistem berbasis cloud, khususnya dalam hal kecepatan respons dan kontinuitas pemrosesan data video.

3.4. Hasil Pengujian Akurasi Deteksi

Pengujian akurasi dilakukan untuk mengetahui tingkat ketepatan sistem dalam mendeteksi jumlah objek manusia pada citra atau video. Evaluasi dilakukan menggunakan parameter precision, recall, dan mean Average Precision (mAP), yang merupakan metrik umum dalam pengukuran performa model deteksi objek. Pengujian dilakukan pada dua skenario, yaitu data kamera real-time dan data video, untuk melihat konsistensi kinerja sistem dalam kondisi yang berbeda.

3.4.1. Pengujian pada Data Kamera (Real-Time)



Gambar 4. Contoh Data Deteksi Kerumunan pada Kamera Real-Time

Perhitungan akurasi didasarkan pada nilai **True Positive (TP)**, **False Positive (FP)**, dan **False Negative (FN)** yang diperoleh dari hasil deteksi sistem.

Rumus yang digunakan adalah:

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

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

Sebagai contoh, pada salah satu data pengujian:

- TP = 2
- FP = 0
- FN = 1

Maka:

$$Precision = \frac{2}{2 + 0} = 1$$

$$Recall = \frac{2}{2 + 1} = \frac{2}{3}$$

Nilai ini menunjukkan bahwa sistem mampu mendeteksi objek dengan sangat tepat (precision tinggi), namun masih terdapat objek yang tidak terdeteksi (recall < 1).

Selanjutnya, nilai **mAP** dihitung menggunakan rumus:

$$mAP = \frac{1}{N} \sum AP_i$$

Berdasarkan hasil perhitungan dari seluruh data pada tabel, diperoleh:

$$mAP = 0.916$$

Hasil pengujian menunjukkan bahwa sistem memiliki tingkat akurasi sebesar **91,6%** pada data kamera real-time. Nilai precision yang tinggi menunjukkan bahwa sistem jarang melakukan kesalahan deteksi (false positive), sedangkan nilai recall yang bervariasi menunjukkan bahwa masih terdapat objek yang tidak terdeteksi (false negative), terutama pada kondisi objek saling berdekatan (*occlusion*) atau pencahayaan yang kurang optimal.

3.4.2. Pengujian pada Data Video



Gambar 5. Contoh Data Deteksi Kerumunan pada Video

Perhitungan dilakukan dengan metode yang sama. Sebagai contoh:

- TP = 4
- FP = 0
- FN = 3

$$Precision = \frac{4}{4 + 0} = 1$$

$$Recall = \frac{4}{4 + 3} = \frac{4}{7}$$

Berdasarkan keseluruhan data pengujian pada video, diperoleh nilai: $mAP = 0.958$

Hasil pengujian pada data video menunjukkan bahwa sistem memiliki tingkat akurasi yang lebih tinggi, yaitu **95,8%**. Hal ini disebabkan oleh kondisi video yang lebih stabil dibandingkan kamera real-time, seperti pencahayaan yang lebih konsisten dan pergerakan objek yang lebih terprediksi. Dengan demikian, sistem mampu mendeteksi objek dengan lebih optimal.

Hasil akurasi pada data video lebih tinggi dibandingkan data kamera real-time. Perbedaan ini menunjukkan bahwa faktor lingkungan seperti pencahayaan, pergerakan objek, dan tingkat kepadatan kerumunan memiliki pengaruh signifikan terhadap kinerja sistem. Meskipun demikian, kedua hasil tersebut menunjukkan bahwa sistem deteksi kerumunan berbasis *edge computing* yang dikembangkan telah memiliki performa yang baik dan mampu digunakan dalam implementasi monitoring cerdas pada lingkungan *smart city*.

3.5. Analisis Kinerja Sistem Deteksi Kerumunan Berbasis Edge Computing

Hasil pengujian menunjukkan bahwa sistem yang dikembangkan memiliki kinerja yang efisien dalam aspek waktu pemrosesan. Rentang latency sebesar 40–60 ms per frame mengindikasikan bahwa proses inferensi dapat dilakukan secara cepat dan stabil pada perangkat edge. Nilai ini menunjukkan bahwa sistem mampu memenuhi kebutuhan pemrosesan real-time tanpa ketergantungan tinggi terhadap jaringan. Temuan ini sejalan dengan penelitian oleh Teerapittayanon et al. (2017) yang menunjukkan bahwa pemrosesan berbasis edge mampu mengurangi waktu komputasi dan meningkatkan efisiensi sistem pada aplikasi berbasis visi komputer (Teerapittayanon et al., 2017).

Dari sisi kecepatan pemrosesan, capaian **24 FPS** menunjukkan bahwa sistem mampu mempertahankan performa yang stabil dalam kategori *real-time processing*. Nilai ini konsisten dengan waktu pemrosesan per frame yang berada pada kisaran puluhan milidetik. Hal ini menunjukkan bahwa sistem memiliki keseimbangan antara kecepatan dan efisiensi komputasi. Penelitian oleh Li et al. (2018) juga menunjukkan bahwa penggunaan model berbasis CNN yang ringan seperti MobileNet dapat meningkatkan performa deteksi pada perangkat dengan sumber daya terbatas tanpa mengorbankan kecepatan pemrosesan (Li et al., 2018b).

Selanjutnya, hasil pengujian akurasi menunjukkan bahwa sistem mampu mencapai **mAP sebesar 0,916 pada kondisi real-time dan 0,958 pada data video**. Nilai ini menunjukkan bahwa model yang digunakan memiliki kemampuan deteksi yang tinggi terhadap objek manusia. Perbedaan nilai akurasi antara data real-time dan video menunjukkan bahwa faktor lingkungan seperti pencahayaan dan kepadatan objek memengaruhi hasil deteksi. Performa sistem deteksi sangat dipengaruhi oleh kompleksitas visual, termasuk *occlusion* dan variasi skala objek.

Analisis lebih lanjut terhadap nilai precision dan recall menunjukkan bahwa sistem memiliki tingkat kesalahan deteksi yang relatif rendah (*false positive* kecil), namun masih terdapat objek yang tidak terdeteksi pada kondisi tertentu (*false negative*). Kondisi ini umum terjadi pada sistem deteksi kerumunan dengan kepadatan tinggi. Tantangan utama dalam crowd detection adalah keterbatasan model dalam membedakan objek pada kondisi saling tumpang tindih dan kompleks.

Secara keseluruhan, hasil penelitian ini menunjukkan bahwa sistem deteksi kerumunan berbasis *edge computing* mampu mencapai keseimbangan antara kecepatan pemrosesan dan tingkat akurasi. Integrasi antara model deteksi yang efisien dan pemrosesan berbasis edge menjadikan sistem ini efektif untuk diterapkan dalam lingkungan *smart city*. Dengan demikian, temuan penelitian ini memberikan kontribusi dalam pengembangan sistem monitoring cerdas yang tidak hanya cepat, tetapi juga akurat dan adaptif terhadap kondisi nyata di lapangan.

4. Kesimpulan

Penelitian ini berhasil mengembangkan sistem deteksi kerumunan berbasis *edge computing* yang mampu bekerja secara *real-time* dengan kinerja yang efisien dan akurat. Hasil pengujian menunjukkan bahwa sistem memiliki latency rendah pada rentang 40–60 ms per frame dan mampu mencapai kecepatan pemrosesan sebesar 24 FPS, sehingga memenuhi kebutuhan monitoring *real-time*. Selain itu, tingkat akurasi yang diperoleh sebesar 91,6% pada data *real-time* dan 95,8% pada data video menunjukkan bahwa model yang digunakan cukup efektif dalam mendeteksi objek manusia. Implementasi pemrosesan pada perangkat *edge* terbukti mampu mengurangi ketergantungan terhadap *cloud* dan meningkatkan efisiensi sistem. Namun demikian, penelitian ini masih memiliki keterbatasan, terutama pada penurunan performa akurasi dalam kondisi lingkungan yang dinamis seperti pencahayaan yang tidak stabil, *occlusion* antar objek, serta keterbatasan kapasitas komputasi perangkat *edge* dalam menangani skenario kerumunan yang sangat padat. Oleh karena itu, pengembangan lebih lanjut diperlukan, khususnya pada optimalisasi model dan peningkatan *robustness* sistem agar dapat bekerja lebih adaptif pada kondisi nyata yang lebih kompleks dalam implementasi *smart city*.

Referensi

- Arikunto, S. (2021). *Prosedur Penelitian: Suatu Pendekatan Praktik*. Rineka Cipta.
- Bhanu Solanki, P., & Tan, X. (2018). Extended Kalman Filter-Based 3D Active-Alignment Control for LED Communication. *2018 IEEE International Conference on Robotics and Automation (ICRA)*, 4881–4888. <https://doi.org/10.1109/ICRA.2018.8460949>
- Creswell, J. W., & Plano Clark, V. L. (2018). *Designing and Conducting Mixed Methods Research*. Saga Publications.
- Dansereau, D. G., Girod, B., & Wetzstein, G. (2019). LiFF: Light Field Features in Scale and Depth. *2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 8034–8043. <https://doi.org/10.1109/CVPR.2019.00823>
- Khan, M. A., Menouar, H., Hamila, R., & Abu-Dayya, A. (2025). Crowd counting at the edge using weighted knowledge distillation. *Scientific Reports*, *15*(1), 11932. <https://doi.org/10.1038/s41598-025-90750-5>
- Kozłowski, J., & Badurowicz, M. (2025). Analysis of the use of object detection systems in edge computing. *Journal of Computer Sciences Institute*, *37*, 379–390. <https://doi.org/10.35784/jcsi.7815>
- Li, Y., Zhang, X., & Chen, D. (2018a). *CSRNet: Dilated Convolutional Neural Networks for Understanding the Highly Congested Scenes* (Version 4). arXiv. <https://doi.org/10.48550/ARXIV.1802.10062>
- Li, Y., Zhang, X., & Chen, D. (2018b). *CSRNet: Dilated Convolutional Neural Networks for Understanding the Highly Congested Scenes* (Version 4). arXiv. <https://doi.org/10.48550/ARXIV.1802.10062>
- Manduva, V. C. (2024). AI-Powered Real-Time Anomaly Detection in Edge Computing Systems for Smart Cities. *International Journal of Engineering and Computer Science*, *13*(01). <https://doi.org/10.18535/ijecs.v13i01.4819>
- Niklaus, S., & Liu, F. (2018). Context-Aware Synthesis for Video Frame Interpolation. *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 1701–1710. <https://doi.org/10.1109/CVPR.2018.00183>

- Shi, W., Cao, J., Zhang, Q., Li, Y., & Xu, L. (2016). Edge Computing: Vision and Challenges. *IEEE Internet of Things Journal*, 3(5), 637–646. <https://doi.org/10.1109/JIOT.2016.2579198>
- Sugiyono. (2018). *Metode Penelitian Pendidikan (Pendekatan Kuantitatif, Kualitatif, dan R&D)*. Alfabeta.
- Sun, L., Sun, J., Zhang, J., Peng, X., Zhang, F., Zhang, D., Ye, K., & Fan, J. (2026). Edge-Cloud Collaborative Video Analytics System for Crowd Gathering Detection in Metro Stations. *Tsinghua Science and Technology*, 31(3), 1764–1777. <https://doi.org/10.26599/TST.2025.9010082>
- Teerapittayanon, S., McDanel, B., & Kung, H. T. (2017). Distributed Deep Neural Networks Over the Cloud, the Edge and End Devices. *2017 IEEE 37th International Conference on Distributed Computing Systems (ICDCS)*, 328–339. <https://doi.org/10.1109/ICDCS.2017.226>
- Wang, S., Pu, Z., Li, Q., & Wang, Y. (2022). Estimating crowd density with edge intelligence based on lightweight convolutional neural networks. *Expert Systems with Applications*, 206, 117823. <https://doi.org/10.1016/j.eswa.2022.117823>
- Zhu, R., Wang, C., Lin, C.-H., Wang, Z., & Lucey, S. (2018). Object-Centric Photometric Bundle Adjustment with Deep Shape Prior. *2018 IEEE Winter Conference on Applications of Computer Vision (WACV)*, 894–902. <https://doi.org/10.1109/WACV.2018.00103>