

Pengembangan Sistem Monitoring Perawatan Lanjut Usia Menggunakan Webcam Dan Algoritma YOLOv7: Deteksi Lansia

1st Rahmad Hidayad
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia

rahmadhidayad@student.telkomuniversity.ac.id

2nd Casi Setianingsih
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia

setiacasie@telkomuniversity.ac.id

3rd Astri Novianty
Fakultas Teknik Elektro
Universitas Telkom
Bandung, Indonesia

astrinovianty@telkomuniversity.ac.id

Abstrak— Membuat sistem pemantauan perawatan lansia dengan memanfaatkan webcam dan teknologi YOLOv7 sangatlah esensial untuk menyelesaikan isu-isu yang ditemui oleh generasi tua. Tanpa pengawasan yang tepat, lansia berpotensi mengalami masalah kesehatan dan keselamatan, terutama bagi mereka yang berisiko tinggi terkena penyakit demensia. Hambatan fisik dan mental yang umum terjadi pada lansia membuat mereka kesulitan dalam melakukan rutinitas harian secara independen, sehingga solusi kreatif diperlukan untuk pengawasan yang lebih efektif. Solusi yang diajukan dalam kajian ini berfokus pada penciptaan sistem yang mampu membedakan lansia dari non-lansia dalam waktu nyata. Uji coba mengindikasikan bahwa desain sistem memiliki kapabilitas yang cukup baik dalam mengidentifikasi objek serta tingkah laku lansia. Berkat algoritma YOLOv7, sistem sukses dalam mengklasifikasi lansia dengan akurasi hingga 94% dan memonitor tindakan sehari-hari mereka dengan efektivitas yang memuaskan. Dengan kata lain, melalui pengembangan sistem pemantauan ini, kita berkesempatan meningkatkan kualitas perawatan dan kehidupan lansia, sekaligus menyediakan dukungan yang sangat dibutuhkan bagi mereka yang menangani permasalahan perawatan usia lanjut.

Kata kunci— Monitoring, Algoritma YOLOv7, Pendeteksian lansia, realtime

I. PENDAHULUAN

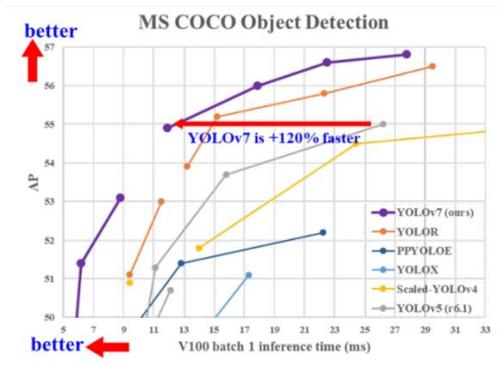
Penduduk lanjut usia (lansia) sebagai mereka yang telah mencapai usia 60 (enam puluh) tahun ke atas. Sejak tahun 1971 hingga 2020, ada peningkatan persentase penduduk lansia di Indonesia dari 4,5 persen menjadi 10,7 persen. Proyeksi menyatakan bahwa angka ini akan bertambah hingga 19,9 persen di tahun 2045. [1]. Hyperkifosis merujuk pada kelengkungan tidak normal di bagian toraks tulang belakang. Pada usia muda, kelengkungan biasanya sekitar 10-20 derajat. Kondisi ini dapat berdampak buruk pada kesehatan, seperti meningkatkan risiko jatuh, patah tulang, kematian, menurunnya kapasitas fisik, dan ketidakseimbangan[2]. Kecelakaan pada lansia yang jatuh adalah penyebab kedua kematian dan dianggap salah satu peristiwa paling berbahaya. 47% lansia tidak dapat berdiri

setelah terjatuh [3]. Pengawasan lansia yang hidup sendiri di rumah tanpa kehadiran orang dewasa yang sehat yang sedang beraktivitas penting untuk mencegah peningkatan risiko. Selain itu, ada mekanisme untuk mengawasi lansia yang dapat mengidentifikasi berbagai keadaan secara langsung [4] dengan menggunakan *WebCam*. Sebuah pendekatan yang menarik adalah menggunakan teknologi kecerdasan buatan, terutama YOLOv7, untuk menghadapi masalah ini. YOLOv7 merupakan salah satu model deteksi objek di bidang Computer Vision yang sangat maju dan efektif. Oleh karena itu, fokus dari penelitian ini adalah mengembangkan sistem pemantauan lansia menggunakan model deteksi objek YOLOv7. Dengan memasukkan teknologi ini ke dalam rutinitas harian lansia, tujuannya adalah untuk meningkatkan standar perawatan serta memberikan bantuan yang lebih baik bagi keluarga dan penjaga. Dengan memanfaatkan YOLOv7, harapannya adalah untuk menghasilkan solusi yang mampu mengurangi potensi kecelakaan dan meningkatkan standar hidup lansia di masyarakat yang terus berkembang.

II. KAJIAN TEORI

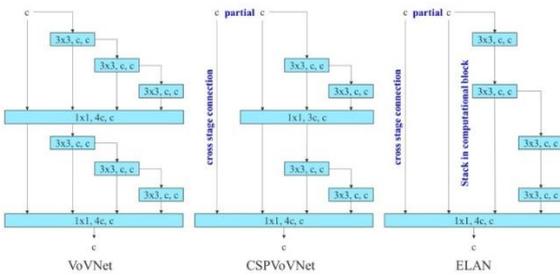
A. Algoritma You Look Only Once (YOLO)

You Only Look Once atau YOLO merupakan salah satu teknik yang diterapkan untuk menentukan jenis dan posisi objek di dalam sebuah gambar secara langsung dengan memanfaatkan jaringan konvolusi. Metode ini mampu memproyeksikan kotak pembatas (bounding boxes) dan probabilitas kelas untuk setiap kotak, yang memungkinkan prediksi objek dengan presisi tinggi. Metode ini adalah buah dari kemajuan teknologi di ranah computer vision, yang memperbolehkan perangkat untuk secara otomatis mendeteksi, mengklasifikasikan, dan mengkalkulasi objek di dalam gambar [5] secara langsung. Pada Tugas Akhir ini menggunakan algoritma YOLOv7 untuk meningkatkan kinerja yang unggul.



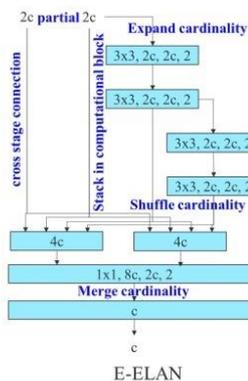
GAMBAR 1 Perbandingan YOLOv7 Dengan Algoritma Lain [5]

Berdasarkan Gambar 1. Dalam hal performa, algoritma YOLOv7 unggul dibandingkan dengan pendahulunya, YOLOv5 (r6.1). Pada durasi sekitar 12 (ms), YOLOv7 mencatatkan nilai AP sekitar 55. Di sisi lain, YOLOv5 (r6.1) memerlukan waktu sekitar 26 (ms) untuk mencapai nilai AP yang sama. Hal ini mengindikasikan bahwa YOLOv7 beroperasi dengan kecepatan 120% lebih tinggi dibandingkan YOLOv5 (r6.1) dalam tes tersebut [5].



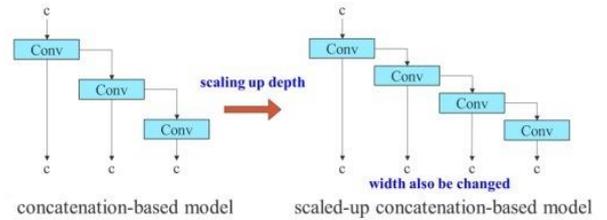
GAMBAR 2 Perbandingan Arsitektur VoVNet, CSPVoVNet, dan ELAN [5]

Paper YOLOv7 memaparkan model-model arsitektur terbaru, seperti VoVNet, CSPVoVNet, dan ELAN. Saat menelaah literatur mengenai desain arsitektur yang efisien, jumlah parameter, kapasitas komputasi, dan densitas komputasi menjadi aspek kunci. YOLOv7 mengedepankan model ELAN berkat kemampuannya dalam menciptakan jaringan efisien dengan cermat mengontrol jalur gradien. Pendekatan ini memfasilitasi jaringan bertingkat untuk belajar dan mengintegrasikan informasi secara lebih terpadu dan efektif [5].



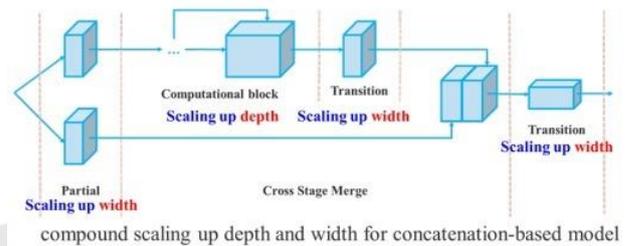
GAMBAR 3 Memperluas Arsitektur ELAN Menjadi E-ELAN [5]

Dalam konteks pengembangan YOLOv7, penulis telah merevisi arsitektur ELAN dan menghasilkan varian yang dikenal sebagai E-ELAN (Extended Efficient Layer Aggregation Networks). Walaupun jalur transmisi gradien ELAN orisinal tetap tidak tersentuh, E-ELAN mengimplementasikan konvolusi grup untuk meningkatkan kardinalitas fiturnya. Selanjutnya, E-ELAN secara acak mengintegrasikan fitur dari grup-grup yang berbeda dan menyinkronkan kardinalitas mereka. Dengan pendekatan ini, ada peningkatan signifikan pada fitur yang ditemukan oleh peta fitur yang beragam, serta optimalisasi dalam penggunaan parameter dan komputasi [5].



GAMBAR 4 Peningkatan Concatenation Model [5]

Konsep penskalaan model memegang peranan krusial dalam pengembangan jaringan saraf tiruan. Melalui proses penskalaan, kemampuan dalam meningkatkan kedalaman, kualitas resolusi gambar, serta lebar model menjadi mungkin. Dalam riset yang dilakukan oleh penulis YOLOv7, terdapat sebuah observasi menarik: saat penskalaan diterapkan dengan kedalaman yang lebih dalam pada model berbasis concatenation, ada peningkatan lebar pada keluaran unit komputasi. Ini berimplikasi pada peningkatan lebar masukan untuk lapisan transmisi yang berikutnya [5].



GAMBAR 5 Peningkatan Komposit Kedalaman Dan Lebar Untuk Model Berbasis Konkatensi [5]

Dengan demikian, penulis dari YOLOv7 memperkenalkan sebuah model yang dikenal dengan compound scaling up depth and width for concatenation-based. Model ini secara khusus meningkatkan kedalaman hanya pada blok komputasi yang esensial untuk penskalaan. Sedangkan, untuk bagian lainnya dari lapisan transmisi, penyesuaian dilakukan dengan meningkatkan skala lebarnya sesuai kebutuhan [5].

B. Lansia

Berdasarkan Undang-Undang No.13 tahun 1998, individu yang telah berumur di atas 60 tahun diklasifikasikan sebagai lansia. Penuaan merupakan proses alami yang akan dialami setiap manusia yang memiliki umur yang panjang. Namun, seberapa cepat atau lambat proses itu berlangsung tergantung pada setiap individu [2].

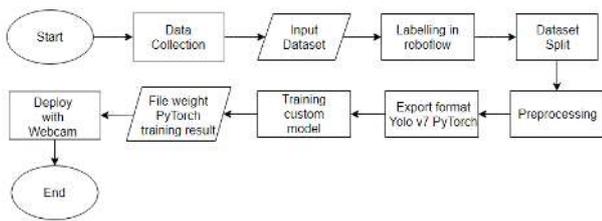
C. Roboflow

Dalam dunia Computer Vision, Roboflow hadir sebagai sebuah platform yang dirancang khusus untuk meningkatkan proses pengumpulan data, pra-pemrosesan, serta metode pelatihan model. Salah satu keunggulan Roboflow adalah ketersediaan set data publik yang bisa langsung dimanfaatkan oleh para pengguna. Selain itu, platform ini juga memberi kesempatan bagi pengguna untuk memasukkan data kustom milik mereka. Sebagai tambahan, Roboflow memiliki kemampuan untuk mendukung beragam format anotasi.

III. METODE

A. Desain Sistem

Pada tugas akhir ini dibuatnya sistem deteksi lansia yang dibuat untuk dapat menganali dua objek, yaitu lansia dan muda.



GAMBAR 6 Alur Pengerjaan Desain Sistem

1.Partisi Data

Dataset gambar/citra yang digunakan akan dilatih untuk menciptakan suatu model yang dapat mengenali objek. Keseluruhan dataset ini berisikan sebanyak 1200 gambar, 600 gambar untuk lansia. Begitu juga untuk dataset muda, terdiri dari 600 gambar.

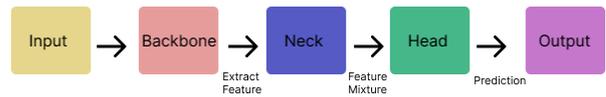
TABEL 1

Keterangan	Jumlah Gambar	Total Keseluruhan Dataset
Lansia	600	1200
Muda	600	

Pada Partisi data dilakukan sejumlah pengujian pembagian, seperti 70% dan 30%, 80% dan 20%, 90% dan 10%. Semua pembagian tersebut hanya terdiri dari dua folder yang berbeda yaitu *Train set* dan *Validation set* yang sudah memiliki label dari masing-masing gambar yang telah di labelling melalui platform roboflow. Pada dataset tersebut dilakukan juga augmentasi dengan menggunakan fitur pada roboflow seperti *brightness* sebesar 10%, *greyscale* sebesar 10%, dan *flip* sebesar 10%.

2. Pelatihan Data

Pada proses pelatihan dataset, sebelumnya telah mendapatkan dataset terpilih untuk dapat menjutkan proses pelatihan dataset ini. Platform yang digunakan untuk pelatihan ini adalah Google Colaboratory dikarenakan proses pelatihan YOLOv7 ini membutuhkan komputasi yang tinggi agar dapat menjalankan proses training, Pada umumnya, YOLOv7 masih mengusung arsitektur layer konvolusional untuk melatih model. Proses pelatihan dataset ini adalah membuat model dengan metode transfer learning pada bobot yang telah disediakan oleh pencipta YOLOv7.



GAMBAR 7 Alur Arsitektur YOLOv7

1. Input

Tahap pertama training dataset adalah menginput gambar sebagai objek untuk dinormalisasikan dan diubah ukurannya menjadi 640x640 sebelum masuk kedalam jaringan.

2. Backbone

Bagian ini adalah proses dimana gambar inputan diekstraksi menjadi fitur-fitur yang akan diolah di bagian "head". Sebelumnya akan dilakukan teknik konvolusi dengan ukuran kernel yang berbeda, penggabungan fitur, dan shortcut connection tujuannya adalah agar backbone mempelajari representasi fitur yang semakin kompleks dan abstrak dari gambar.

3. Neck

Sebuah Kumpulan lapisan jaringan layer yang disatukan untuk di teruskan ke tahap berikutnya untuk diprediksi.

4. Head

Bagian ini bertugas membuat prediksi akhir berdasarkan fitur yang telah diproses oleh backbone dan neck.

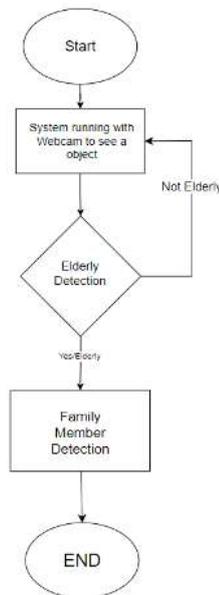
5. Output

Output dari model akan berupa tensor yang berisi semua informasi ini untuk setiap objek yang dideteksi dalam gambar. Tensor adalah struktur data multidimensi yang digunakan secara luas dalam pembelajaran mesin dan deep learning.

3.Evaluasi Model

Hasil dari training tersebut dapat menggunakan matriks evaluasi sebagai cara untuk menghitung model terunggul yang telah training. Hasil evaluasi berdasarkan dari nilai confusion matrix dikarenakan sistem akan mendeteksi ketepatan setiap kelas yang sudah dilakukan pada saat pelatihan data yang menghasilkan file bobot unggul.

4.Implementasi Sistem



GAMBAR 8
Alur Implementasi Sistem

Pada sistem deteksi lansia digunakan file bobot terunggul yang diperoleh dari hasil pelatihan data. File bobot tersebut akan dieksekusi menggunakan laptop atau komputer. Pada laptop atau komputer akan dihubungkan dengan WebCam sebagai penglihatan dari device tersebut.

B. Desain Perangkat

Digunakannya perangkat keras maupun perangkat lunak untuk mendukung dan menghasilkan penelitian yang baik pada setiap percobaannya. Perangkat keras yang digunakan pada penelitian ini adalah laptop dan WebCam, sedangkan perangkat lunaknya menggunakan Google Colaboratory dan roboflow. Laptop dan WebCam digunakan sebagai alat untuk mengeksekusi sistem yang telah dibuat. Google Colaboratory digunakan untuk melatih data, sedangkan roboflow digunakan sebagai alat *preprocessing*.

C. Hyperparameter Tuning

Meneruskan setelah fase pelatihan model, peneliti berinisiatif untuk mengadakan eksperimen dengan menyesuaikan hyperparameter YOLOv7. Berikut rincian hyperparameter yang akan menjadi fokus variasi dalam penelitian ini:

1. Learning Rate

Melakukan pengujian pada learning rate bertujuan untuk mengidentifikasi nilai learning rate yang paling tepat sehingga pelatihan model dapat berjalan efektif dengan hasil akurasi yang optimal. Learning rate berperan sebagai hyperparameter yang menetapkan magnitudo langkah yang dilakukan optimizer dalam upaya menemukan set bobot terbaik selama fase pelatihan.

2. Optimizer

Uji coba pada optimizer ditujukan untuk memastikan model mencapai optimalitas saat pelatihan. Ini memungkinkan model untuk ditrain dengan tujuan mendapatkan kinerja optimal. Optimizer juga berfungsi untuk menekan nilai fungsi kerugian. Ada dua jenis optimizer yang digunakan pada pengujian ini, yaitu

a. SGD (Stochastic Gradient Descent):

Ini merupakan teknik optimasi tradisional yang sering diaplikasikan. SGD menentukan gradien dari fungsi kerugian berdasarkan setiap dataset dan memodifikasi bobot dengan mengurangi hasil perkalian antara gradien dengan tingkat belajar.

b. ADAM (Adaptive Moment Estimation):

metode optimasi fleksibel yang menyatukan ide dari RMSprop dan Momentum. Adam menyesuaikan learning rate untuk tiap parameter berdasarkan perkiraan sebelumnya dari momentum gradien serta perhitungan momen kuadrat.

3. Epoch

Dengan menguji jumlah epoch, tujuannya adalah untuk mengidentifikasi jumlah iterasi yang paling sesuai dalam melatih model agar mencapai akurasi yang tinggi tanpa overfitting. Epoch diartikan sebagai satu perulangan lengkap atas seluruh data pelatihan yang ada.

4. Batch Size

Pengujian terhadap batch size dilaksanakan guna mendapatkan ukuran batch yang optimal yang memungkinkan model dilatih dengan akurasi yang tinggi dan proses yang efisien. Dalam konteks pelatihan, batch size merujuk pada jumlah sampel data yang dijalankan dalam setiap iterasi.

5. Confidence Threshold

Pengujian terhadap confidence threshold dilakukan untuk memonitor bagaimana performa model deteksi objek tergantung pada perubahan nilai threshold yang diterapkan. Dari pengujian ini, kita berharap untuk menemukan nilai threshold yang ideal yang akan memberikan kinerja unggul pada model.

D. Evaluasi Kinerja Model

Evaluasi YOLOv7 fokus pada penilaian dan perhitungan efektivitas model deteksi yang telah dirancang. Ini bertujuan untuk memastikan bahwa model memiliki kemampuan yang baik dalam mendeteksi objek dengan presisi dan kestabilan. Metode evaluasi yang digunakan antara lain Confusion matrix, Precision, Recall, Precision-Recall, F1 Score, dan mAP.

1. Confusion Matrix

Proses evaluasi model YOLOv7 melibatkan tindakan menilai dan mengukur seberapa baik model deteksi yang telah disusun berfungsi. Dalam evaluasi ini, Confusion Matrix digunakan sebagai alat utama; sebuah tabel yang membandingkan output prediksi model dengan data asli atau ground truth. Tabel ini memuat informasi mengenai True Positive (TP), True Negative (TN), False Positive (FP), dan False Negative (FN). Alat ini memberikan gambaran mendalam tentang seberapa akurat model dalam mengidentifikasi data dan menunjukkan kesalahan yang mungkin dilakukan oleh model. Akurasi, yang didefinisikan sebagai proporsi prediksi benar dari seluruh data, termasuk dalam kelas positif dan negatif, dihitung untuk memberikan gambaran umum tentang kinerja model.

$$accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

2. Precision

Precision menunjukkan keakuratan model dalam mengenali kelas positif dari semua prediksi yang dianggap sebagai kelas positif. Perhitungannya didasarkan pada rumus:

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

3. Recall

Recall menilai kapabilitas model dalam mengidentifikasi data kelas positif dari total data yang sejatinya adalah kelas positif. Rumusnya adalah:

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

4. F1- Score

F1 Score adalah nilai rata-rata harmonik antara Precision dan Recall, memberikan keseimbangan antara keduanya, terutama ketika terdapat ketidakseimbangan kelas [6].

$$F1\ Score = 2 \times \frac{(precision \times recall)}{(precision + recall)}$$

IV. HASIL DAN PEMBAHASAN

Selama tahap evaluasi, ditemukan akurasi terbaik dari berbagai penyesuaian hyperparameter. Sementara itu, saat pelaksanaan model, inti pengujian berfokus pada kemampuan sistem untuk mendeteksi objek dari sudut yang berbeda, jarak, dan pencahayaan. Pengujian meliputi pembagian data, pemilihan algoritma pengoptimalan, penyesuaian hyperparameter seperti tingkat pembelajaran, epoch, dan ukuran batch, serta pengaturan ambang kepercayaan. Dalam menentukan model yang terbaik, confusion matrix menjadi acuan utama.

A. Pengujian Partisi Data

Pengujian dilakukan dengan cara membagi dataset menjadi tiga bagian, yaitu 70% data *train* dan 30% data *validation*, 80% data *train* dan 20% data *validation*, 90% data *train* dan 10% data *validation*. Pengujian dilakukan untuk mengetahui akurasi pada setiap partisi data dan yang terunggul akan digunakan pada pengujian selanjutnya. Pada tahap ini *tuning* yang digunakan adalah *learning rate* = 0.01, *optimizer* = SGD, Epoch = 100, Batch Size = 16, Confidence Threshold = 0.25 dan Akurasi terunggul pada partisi data 90% data *train* dan 10% data *validation* sebesar 63%. Hasil perbandingan akurasi pengujian tersebut dapat dilihat pada gambar 9.

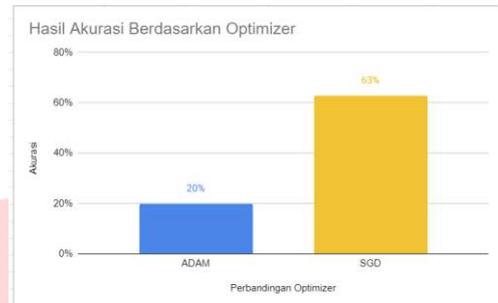


GAMBAR 9
Perbandingan Akurasi Pengujian Partisi Data

B. Pengujian Optimizer

Pengujian ini dilakukan dengan cara mengubah optimizer pada saat melatih dataset yang terdiri dari dua optimizer yaitu SGD dan ADAM. Tujuan dari pengujian pengoptimal adalah untuk mengukur seberapa baik dan akurat model ketika

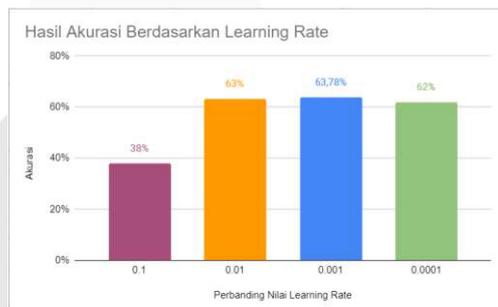
dioperasikan dengan pengoptimal yang beragam. Pengoptimal berfungsi sebagai metode yang diterapkan untuk mengupdate dan meningkatkan bobot serta bias pada model di saat fase pelatihan. Pada tahap ini tuning yang digunakan adalah *learning rate* = 0.01, *optimizer* = SGD dan ADAM, Epoch = 100, Batch Size = 16, Confidence Threshold = 0.25 dan Akurasi terunggul pada penggunaan *optimizer* = SGD sebesar 63%. Hasil perbandingan akurasi pengujian tersebut dapat dilihat pada gambar 10.



GAMBAR 10
Perbandingan Akurasi Pengujian Optimizer

C. Pengujian Learning Rate

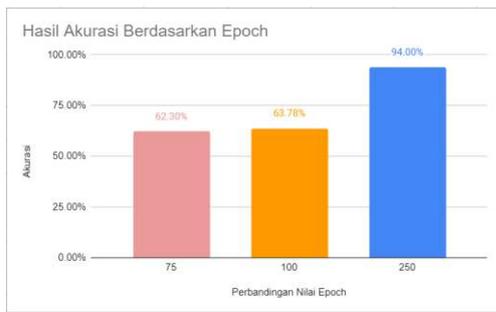
Pengujian ini dilakukan dengan cara mengubah nilai pada *learning rate*. Tujuan dari pengujian ini mendapatkan tingkat pembelajaran terbaik untuk mengoptimalkan pelatihan model dengan efisiensi dan tingkat keakuratan yang tinggi. Tingkat pembelajaran digambarkan sebagai hyperparameter yang menentukan seberapa besar langkah yang ditempuh oleh pengoptimal dalam usaha mencari bobot ideal saat pelatihan. Pada tahap ini tuning yang digunakan adalah *learning rate* = 0.01, 0.001, 0.0001, 0.1, *optimizer* = SGD, Epoch = 100, Batch Size = 16, Confidence Threshold = 0.25 dan Akurasi terunggul pada penggunaan *learning rate* = 0.001 sebesar 63,78%. Hasil perbandingan akurasi pengujian tersebut dapat dilihat pada gambar 11.



GAMBAR 11
Perbandingan Akurasi Pengujian Learning Rate

D. Pengujian Epoch

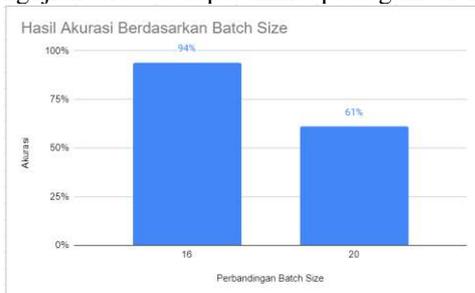
Pengujian dengan cara mengubah nilai pada epoch. Pengujian ini bertujuan untuk Mengurangi peluang model mengalami overfitting. Epoch merupakan putaran lengkap melalui seluruh data latih selama proses pelatihan. Pada tahap ini tuning yang digunakan adalah *learning rate* = 0.01, *optimizer* = SGD, Epoch = 75, 100, 250, Batch Size = 16, Confidence Threshold = 0.25 dan Akurasi terunggul pada penggunaan epoch = 250 sebesar 94%. Hasil perbandingan akurasi pengujian tersebut dapat dilihat pada gambar 12.



GAMBAR 12
Perbandingan Akurasi Pengujian Epoch

E. Pengujian Batch Size

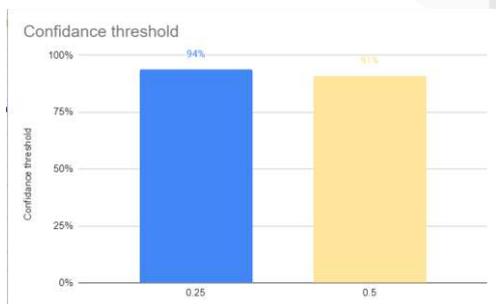
Pengujian dengan cara mengubah nilai pada batch size. Pengujian kapasitas batch dilaksanakan untuk mencari dimensi batch terbaik dengan melatih contoh berdasarkan kapasitas batch yang spesifik. Kapasitas batch merupakan kuantitas data yang dikerjakan setiap putaran pelatihan. Pada tahap ini tuning yang digunakan adalah learning rate = 0.01, optimizer = SGD, Epoch = 250, Batch Size = 16, 20, Confidence Threshold = 0.25 dan Akurasi terunggul pada penggunaan batch size = 16 sebesar 94%. Hasil perbandingan akurasi pengujian tersebut dapat dilihat pada gambar 13.



GAMBAR 13
Perbandingan Akurasi Pengujian Optimizer

F. Pengujian Confidence Threshold

Pengujian ini dilakukan dengan cara mengubah nilai pada confidence threshold. Tujuan dari pengujian ini menahan nilai confidence agar mengetahui kinerja model pada saat pelatihan. Pada tahap ini tuning yang digunakan adalah learning rate = 0.01, optimizer = SGD, Epoch = 250, Batch Size = 16, Confidence Threshold = 0.25, 0.5 dan Akurasi terunggul pada penggunaan Confidence Threshold = 0.25 sebesar 94%. Hasil perbandingan akurasi pengujian tersebut dapat dilihat pada gambar 14.



GAMBAR 14
Perbandingan Akurasi Pengujian Confidence Threshold

Hasil terunggul dari pengujian *Hyperparameter* ini dapat dilihat pada tabel 2.

TABEL 2
Hasil Terunggul Pengujian *Hyperparameter*

Partisi	Optimizer	Learning Rate	Epoch	Batch Size	Confidence Threshold	Akurasi
Data	SGD	0.001	250	16	0.25	94%

G. Hasil Evaluasi Pengujian Model Terunggul

Berdasarkan pengujian *hyperparameter* akurasi model pada confusion matrix, precision, recall, dan f1-score dapat dilihat pada tabel 3.

TABEL 3
Hasil Evaluasi Pengujian Model Terunggul *Hyperparameter*

Akurasi	Precision	Recall	F1-Score
94%	100%	89%	94%

H. Pengujian Menggunakan WebCam

Pada pengujian ini digunakan rumus akurasi seperti berikut:

$$Akurasi = \frac{Total\ terdeteksi}{Total\ percobaan} \times 100$$

Pengujian terbagi menjadi empat, yaitu pengujian jarak, pengujian insitas cahaya, pengujian sudut dan pengujian objek. Pengujian real pada objek didapatkan hasil jarak pada 4 meter dan 6 meter dengan akurasi 100%. Intensitas cahaya didapatkan hasil 24 Lux, 47 Lux, 65 Lux. Sudut didapatkan hasil 0°,10°,20°,30°.Hasil akurasi dapat dilihat pada tabel 4.

TABEL 4
Pengujian Real

Pengujian	Jarak	Intensitas Cahaya	Sudut	Objek Terdeteksi	Akurasi
Jarak	2 meter	65 Lux	0°	0	0%
	4 meter			6	100%
	6 meter			6	100%
	7 meter			0	0%
Intensitas Cahaya	4 meter	0 Lux	0°	0	0%
		24 Lux		6	100%
		47 Lux		6	100%
		65 Lux		6	100%
		450 Lux		3	50%
2500 Lux	0	0%			
Sudut	4 meter	45 Lux	0°	6	100%
			10°	6	100%
			20°	6	100%
			30°	6	100%
			50°	0	0%

V. KESIMPULAN

Hasil dari penelitian penelitian, analisis, dan peninjauan yang telah dijalankan dalam karya Capstone Design berjudul "Pengembangan Sistem Monitoring Perawatan Lanjut Usia Menggunakan WebCam dan Algoritma YOLOv7," kita bisa mengambil kesimpulan pengujian training model didapatkan hasil akurasi sebesar 94% dengan menggunakan partisi data 90:10, Optimizer SGD, Learning Rate 0.001, Epoch 250, Batch Size 16, Confidence Threshold 0.25. Pengujian real pada objek didapatkan hasil jarak pada 4 meter dan 6 meter dengan akurasi 100%. Intensitas cahaya didapatkan hasil 24 Lux, 47 Lux, 65 Lux. Sudut didapatkan hasil 0°,10°,20°,30°. Hasil pengujian menunjukkan bahwa sistem yang dikembangkan memiliki tingkat akurasi yang memadai dalam mendeteksi objek dan perilaku lansia. Algoritma YOLOv7 mampu mengenali lansia dengan tingkat akurasi 94%, serta mendeteksi aktivitas sehari-hari dengan reliabilitas yang baik. Dengan demikian, pengembangan sistem monitoring ini berpotensi meningkatkan perawatan dan kualitas hidup lansia, serta memberikan dukungan yang berharga bagi para pemangku kepentingan dalam menghadapi tantangan perawatan lanjut usia.

REFERENSI

- [1] "data lansia 2021 resmi dari badan pusat statistik".
- [2] P. M. Journal, I. Syah, Y. Febriani, and A. Adenikheir, "HYPERKIFOSIS DAN BODY MASS INDEX LANSIA DI KOTA," no. 2, pp. 38–43, 2022.
- [3] W. W. Hsu, J. M. Guo, C. Y. Chen, and Y. C. Chang, "Fall Detection with the Spatial-Temporal Correlation Encoded by a Sequence-to-Sequence Denoised GAN," *Sensors*, vol. 22, no. 11, Jun. 2022, doi: 10.3390/s22114194.
- [4] H. G. Kim and G. Y. Kim, "Deep Neural Network-Based Indoor Emergency Awareness Using Contextual Information from Sound, Human Activity, and Indoor Position on Mobile Device," *IEEE Trans. Consum. Electron.*, vol. 66, no. 4, pp. 271–278, Nov. 2020, doi: 10.1109/TCE.2020.3015197.
- [5] Ö. Kaya, M. Y. Çodur, and E. Mustafaraj, "Automatic Detection of Pedestrian Crosswalk with Faster R-CNN and YOLOv7," *Buildings*, vol. 13, no. 4, pp. 1–17, 2023, doi: 10.3390/buildings13041070.
- [6] "Analisis Performansi Deteksi Objek Pada Metode Complex YOLOv4 Untuk Autonomous Driving."