DETEKSI ACNE VULGARIS MENGGUNAKAN YOU ONLY LOOK ONCE VERSI 11 (YOLOv11)

Skripsi

Oleh

NABILA SYAIDA RAMDANI NPM. 2157031009



JURUSAN MATEMATIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG
2025

ABSTRACT

ACNE VULGARIS (AV) DETECTION USING YOU ONLY LOOK ONCE VERSION 11 (YOLOv11)

By

Nabila Syaida Ramdani

Acne Vulgaris (AV) is a chronic inflammatory skin disorder that commonly affects adolescents and young adults. Early detection of AV types is crucial to prevent both physical and psychological complications. This study aims to develop an imagebased AV detection system using the You Only Look Once version 11 (YOLOv11) architecture, known for its high efficiency in real-time object detection. The dataset used was sourced from Roboflow and consists of five AV classes: whitehead, blackhead, papule, pustule, and nodule. Manual annotation using bounding boxes was performed before training the model for 100 epochs. Evaluation results show that the YOLOv11 model can detect AV with a mean Average Precision (mAP) @0.5 of 0.469. The best performance was achieved in the pustule class with a mAP@0.5 of 0.688, while the whitehead class had the lowest detection accuracy. This study demonstrates the significant potential of YOLOv11 for automatic and real-time AV classification and highlights its applicability as a self-monitoring and educational tool in non-medical contexts. Further improvements can be achieved through advanced data augmentation techniques and enhanced model architectures to enhance detection performance.

Keywords: Acne Vulgaris, YOLOv11, object detection, deep learning, acne classification, computer vision.

ABSTRAK

DETEKSI ACNE VULGARIS (AV) MENGGUNAKAN YOU ONLY LOOK ONCE VERSI 11 (YOLOv11)

Oleh

Nabila Syaida Ramdani

Acne Vulgaris (AV) merupakan kelainan inflamasi kronis pada kulit yang umum terjadi, terutama di kalangan remaja dan dewasa muda. Deteksi dini terhadap jenisjenis AV menjadi penting untuk mencegah dampak fisik maupun psikologis yang lebih parah. Penelitian ini bertujuan untuk mengembangkan sistem deteksi AV berbasis citra menggunakan arsitektur You Only Look Once versi 11 (YOLOv11), yang dikenal memiliki kemampuan deteksi objek *real-time* dengan efisiensi tinggi. Dataset yang digunakan bersumber dari Roboflow dan mencakup lima kelas AV, yaitu whitehead, blackhead, papule, pustule, dan nodule. Proses anotasi dilakukan secara manual menggunakan bounding box, kemudian model dilatih selama 100 epoch. Hasil evaluasi menunjukkan bahwa model YOLOv11 mampu mendeteksi AV dengan nilai rata-rata mean Average Precision (mAP) @0.5 sebesar 0,469. Deteksi terbaik diperoleh pada kelas pustule dengan mAP@0.5 sebesar 0,688, sedangkan kelas whitehead menunjukkan performa terendah. Penelitian ini menunjukkan bahwa YOLOv11 memiliki potensi signifikan dalam membantu klasifikasi AV secara otomatis dan real-time, serta dapat dimanfaatkan sebagai alat edukasi mandiri dalam bidang non-medis. Pengembangan lebih lanjut melalui teknik augmentasi data dan peningkatan arsitektur model direkomendasikan untuk meningkatkan akurasi deteksi.

Kata kunci: Acne Vulgaris, YOLOv11, deteksi objek, deep learning, klasifikasi jerawat, visi komputer.

DETEKSI ACNE VULGARIS MENGGUNAKAN YOU ONLY LOOK ONCE VERSI 11 (YOLOv11)

Oleh

NABILA SYAIDA RAMDANI

Skripsi

Sebagai Salah Satu Syarat untuk Mencapai Gelar SARJANA MATEMATIKA

Pada

Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung



JURUSAN MATEMATIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG
2025

Judul Skripsi : Deteksi Acne Vulgaris (AV) Menggunakan You Only Look Once Versi 11 (YOLOv11)

: Nabila Syaida Ramdani Nama Mahasiswa

Nomor Pokok Mahasiswa : 2157031009

Jurusan : Matematika

: Matematika dan Ilmu Pengetahuan Alam **Fakultas**

MENYETUJU

1. Komisi Pembimbing

Ir. Warsono, M.S., Ph.D.

NIP. 196302161987031003

Lumbanraja, M.Si., Ph.D.

NIP. 198301102008121002

2. Ketua Jurusan Matematika

Dr. Aang Nuryaman.

NIP.197403162005011001

MENGESAHKAN

1. Tim penguji

Ketua : Ir. Warsono, M.S. Ph.D.

Sekretaris : Favorisen R. Lumbanraja, Ph.D.

Penguji
Bukan Pembimbing: Dr. Dian Kurniasari, S.Si, M.Sc.

Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam

Dr. Eng. Heri Satria, S.Si., M.Si.

NIP 197110012005011002

Tanggal Lulus Ujian Skripsi: 19 Juni 2025

PERNYATAAN SKRIPSI MAHASISWA

Yang bertanda tangan di bawah ini:

Nama : Nabila Syaida Ramdani

Nomor Pokok Mahasiswa : 2157031009

Jurusan : Matematika

Judul Skripsi : Deteksi Acne Vulgaris (AV) Menggunakan

You Only Look Once Versi 11(YOLOv11)

Dengan ini menyatakan bahwa skripsi ini adalah hasil pekerjaan saya sendiri. Apabila kemudian hari terbukti bahwa skripsi ini merupakan hasil salinan atau dibuat oleh orang lain, maka saya bersedia menerima sanksi sesuai dengan ketentuan akademik yang berlaku.

Bandar Lampung, 25 Juni 2025

Penulis,



Nabila Syaida Ramdani

RIWAYAT HIDUP

Penulis memiliki nama lengkap Nabila Syaida Ramdani, yang lahir pada tanggal 04 November 2002. Penulis merupakan anak pertama dari dua bersaudara dari pasangan Bapak Muhamad Sehan dan Ibu Noviansyah.

Penulis memulai pendidikan di Taman Kanak-kanak (TK) Islam Al-Ikhlas pada tahun 2007-2008, lalu melanjutkan Sekolah Dasar di SDN 01 Cibadak dari tahun 2009-2011 dan berpindah pendidikan di Sekolah Dasar di SDN 02 Kangkung 2011-2015. Melanjutkan ke Sekolah Menengah Pertama (SMP) di SMPN 03 Bandar Lampung pada tahun 2015 dan berpindah pendidikan di Sekolah Menengah Pertama di SMPN 02 Cibadak pada tahun 2015-2018, dan melanjutkan ke jenjang Sekolah Menengah Atas (SMA) di SMAN 1 Cibadak pada tahun 2018-2021. Pada tahun 2021, penulis diterima sebagai mahasiswa Program Studi S1 Jurusan Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Lampung melalui jalur Seleksi Mandiri Universitas Lampung (SIMANILA).

Pada bulan Januari 2024 penulis melaksanakan Kuliah Kerja Praktik (KP) selama 40 hari di Data Science Center (DSC), yang beralamat di Gedung Lab Riset Multidisiplin Pertamina Lantai 6 Ruang 606, Pondok Cina, Kecamatan Beji, Kota Depok, Jawa Barat, 16424, Indonesia. Sebagai salah satu bentuk pengabdian kepada masyarakat, pada bulan Juni 2024 penulis melaksanakan Kuliah Kerja Nyata (KKN) di Desa Karang Anom, Kecamatan Waway Karya, Kabupaten Lampung Timur, Lampung.

KATA INSPIRASI

"If you really want it, they don't matter anymore, it's just you and your dreams,
the rest is just noise."

(The Tiny Wisdom)

"Everyone must choose one of two pains: The pain of discipline or the pain of regret." (Jim Rohn)

"Ambil resikonya atau kita ga akan kemana-mana" $(Anonym \ on \ X)$

"Take care of yourself. Wake up early. Exercise first thing. Drink water. Stop Worrying. Less screen time. Read books. Practice, & god knows we are worth it." (Anonym)

PERSEMBAHAN

Alhamdulillah, puji dan syukur kepada Allah SWT atas nikmat serta hidayahnya sehingga skripsi ini dapat terselesaikan dengan baik dan tepat pada waktunya. Oleh karena itu, dengan rasa syukur dan bahagia saya persembahkan rasa terima kasih saya kepada:

Ayah, Ibu, dan Adik

Terima kasih kepada orang tua tercinta atas segala doa, dukungan, dan pelajaran hidup yang tak ternilai. Ucapan terima kasih yang sama disampaikan kepada adik tersayang atas semangat, perhatian, dan bantuan yang selalu menjadi penguat dalam setiap langkah perjalanan yang penulis hadapi.

Dosen Pembimbing dan Pembahas

Terimakasih kepada dosen pembimbing dan pembahas yang sudah sangat membantu, memberikan bimbingan, motivasi, serta ilmu yang berharga selama proses penyusunan skripsi.

Sahabat-sahabatku

Terimakasih kepada semua orang-orang baik yang telah memberikan pengalaman, semangat, motivasi, serta doa-doanya dan senantiasa memberikan dukungan dalam hal apapun.

Almamater Tercinta Universitas Lampung

SANWACANA

Puji syukur penulis panjatkan atas kehadirat Allah SWT yang telah melimpahkan rahmat dan karunia-Nya kepada penulis sehingga skripsi dengan judul " **Deteksi** *Acne Vulgaris* (AV) Menggunakan *You Only Look Once* Versi 11 (YOLOv11)" dapat terselesaikan dengan baik. Shalawat serta salam semoga senantiasa tercurah limpahkan kepada Nabi Muhammad SAW beserta keluarga, sahabat, dan umatnya.

Pada proses penyusunan skripsi ini, penulis banyak menerima bantuan, arahan, dukungan moral, maupun semangat dari berbagai pihak. Oleh karena itu, dengan segala hormat dan rasa terima kasih yang mendalam, penulis mengucapkan terima kasih kepada:

- 1. Bapak Ir. Warsono, M.S. Ph.D. selaku dosen Pembimbing I yang telah banyak meluangkan waktu untuk memberikan arahan, bimbingan, motivasi, dan dukungan kepada penulis sejak awal hingga skripsi ini terselesaikan.
- 2. Bapak Favorisen Rosyking Lumbanraja, S.Kom., M.Si., Ph.D. selaku dosen Pembimbing II yang senantiasa mmeberikan bimbingan, arahan, serta saran sehingga penulis dapat menyelesaikan skripsi ini.
- 3. Ibu Dr. Dian Kurniasari, S.Si., M.Sc., selaku dosen penguji yang juga membimbing dengan sabar, memberikan masukan, saran, serta mendukung penulis dalam menyelesaikan skripsi ini. Terima kasih atas bimbingan, masukan, serta dukungan yang telah diberikan selama proses penulisan skripsi ini.
- 4. Dr. Aang Nuryaman, S.Si., M.Si. selaku Pembimbing Akademik dan Ketua Jurusan Matematika FMIPA Universitas Lampung.
- 5. Dr. Eng. Heri Satria, S.Si., M.Si. selaku Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.

- 6. Seluruh dosen dan staf Jurusan Matematika FMIPA Universitas Lampung yang telah memberikan ilmu, bantuan, dan pelayanan terbaik selama perkuliahan.
- 7. Orang tua tercinta, Ibu Noviansyah, Aunty Sofia, Ema Enung Hasanah, dan seluruh keluarga. Terima kasih atas kasih sayang, doa, dan dukungan yang tak pernah putus, yang selalu menjadi sumber kekuatan terbaik untuk penulis menyelesaikan studi dan meraih gelar sarjana.
- 8. Adik tersayang, Nazwa Habibi, terima kasih atas segala dukungan, keceriaan, serta perhatian yang selalu memberi semangat bagi penulis.
- 9. Kepada teman-teman tersayang Adin, Dita, Eva, Mei, Maya, Rahma, Sherina, Tasya, dan Vedisya, terima kasih yang sebesar-besarnya kuucapkan kepada kalian yang telah menjadi bagian penting dalam perjalanan perkuliahan. Kalian bukan sekadar teman, tapi rumah yang nyaman untuk kembali, semoga kebersamaan ini tetap terjaga meski perjalanan kita akan terus membawa kita ke arah yang berbeda.
- 10. Teman-teman seperbimbingan, Rhea, Anastasia, Adin, Anggy, Andi, Ariz, Dita, Dina, Fathan, Erwin, Maya, Mey, Lusi, Sherina, dan Yulina, terima kasih atas kebersaman, diskusi, dan semangat yang saling menguatkan selama proses menyelesaikan skripsi.
- 11. Teman-teman SMA Lulu Hapsah, Sheril Naila Yasmin, dan Nur Intan, yang selalu menjadi tempat berbagi suka dan duka, tempat curhat, dan sumber semangat bagi penulis.

Penulis menyadari masih banyak kekurangan dalam penulisan skripsi ini. Oleh karena itu, penulis mengharapkan masukan serta saran untuk dijadikan pelajaran kedepannya.

Bandar Lampung, 25 Juni 2025

Nabila Syaida Ramdani

DAFTAR ISI

	aman
DAFTAR GAMBAR	
DAFTAR TABEL	xvii
I. PENDAHULUAN	2
1.1 Latar Belakang dan Masalah	2
1.2 Rumusan Masalah	4
1.3 Tujuan Penelitian	4
1.4 Manfaat Penelitian	5
II. TINJAUAN PUSTAKA	7
2.1 Penelitian Terkait	7
2.2 Acne Vulgaris (AV)	10
2.3 Citra Digital	12
2.3.1 Pengolahan Citra Digital	13
2.4 Machine Learning (ML)	15
2.5 Deep Learning (DL)	16
2.6 Object Detection	18
2.7 You Only Look Once (YOLO)	21
2.8 Perkembangan YOLO	25
2.8.1 Lapisan Konvolusi	29
2.9 Evaluasi Model	32
2.10. Antarmuka Website Berbasis Streamlit	35
III. METODOLOGI PENELITIAN	6
3.1 Tempat dan Waktu Penelitian	6

3.2 Data dan Alat	38
3.3 Alur Kerja Penelitian	40
IV. HASIL DAN PEMBAHASAN	35
4.1 Input Data	35
4.2. Pra-Pemrosesan dan Anotasi <i>Dataset</i>	35
4.2.1 Anotasi menggunakan <i>Roboflow</i>	44
4.2.2 Pembagian dataset dan preprocessing	45
4.3 Training Model YOLOv11	45
4.3.1 Install dan import library	45
4.3.2 Training dataset yang telah dianotasi	46
4.3.3 Visualisasi dan Penyimpanan Model	49
4.3.4 Benchmarking Hasil Penelitian	61
4.4 Implementasi Deteksi dan Klasifikasi Kondisi Kulit	63
4.4.1 Deteksi Acne Vulgaris pada Gambar Baru	63
4.4.2 Perhitungan Jumlah dan klasifikasi kondisi kulit	64
4.4.3 Implementasi Antarmuka Website	67
V. KESIMPULAN	68
5.1 Kesimpulan	68
5.2 Saran	69
DAFTAR PUSTAKA	70

DAFTAR GAMBAR

Gambar 1. Koordinat citra digital (Basuki dkk., 2022)	Halaman 12
2. Supervised dan Unsupervised Learning (Poola, 2017)	
3. (a) Alur kerja <i>Computer Vision</i> Tradisional. (b) Alur kerja <i>Deep Learn</i>	ing (Wang
dkk., 2018)	17
4. Region CNN (Moin, 2023)	19
5. Fast R-CNN (Moin, 2023)	20
6. Faster R-CNN (Moin, 2023)	20
7. S×S <i>grid</i> pada YOLO (Aggarwal, 2020)	22
8. Pusat deteksi grid (Redmon dkk., 2016).	22
9. Bounding Box tertinggi berwarna lebih gelap (Redmon dkk., 2016)	23
10. Dua bounding boxes setiap cell (Astrid, 2022).	23
11. Box coordinates (DeepBean, 2023).	24
12. Overlap (atas), union (bawah) (Padilla, 2020)	24
13. YOLO arsitektur (Redmon dkk., 2018).	25
14. Perkembangan YOLO (Nikhileswara, 2024).	26
15. Perbandingan C2F dan C3K2 Blocks (Nikhileswara, 2024)	27
16. Spatial Pyramid Pooling Fast (SPFF) (Nikhileswara, 2024)	28
17. C2-Position Sensitive Attention (C2PSA) block (Nikhileswara, 2024).	28
18. Gambar Arstitektur YOLOv11 (Zijian dkk., 2024)	29
19. Predicted bounding box (merah), ground truth (hijau) (Rosebrock, 20	016)33
20. Alur Pengerjaan Penelitian.	41
21. Anotasi manual pada <i>Roboflow</i>	44

22. Hasil anotasi pada Roboflow	44
23. Output Kode Program 1.	46
24. Output dari folder runs.	47
25. Visualisasi hasil pelatihan model (a) val_batch0_ <i>pred</i> . (b) val_batch2_pred	49
26. Confusion Matrix hasil evaluasi model YOLOv11	50
27. Recall-Confidence Curve pada model YOLOv11	55
28. Hubungan antara <i>Precision</i> dan <i>Recall</i> pada deteksi AV.	56
29. Precision-Confidence-Curve.	57
30. Grafik F-1 Score berdasarkan Confidence Score.	59
31. Hasil pelatihan dan validasi model YOLOv11: Grafik Loss, <i>Precision, Recall</i> ,	dan
mAP per <i>Epoch</i> .	60
32. Deteksi AV pada Gambar wajah baru oleh model YOLOv11	64
33. Visualisasi deteksi jenis AV dan penentuan status kulit oleh model pada berbaş	gai
tingkat keparahan (a) Normal, (b) Severe, (c) Severe.	66
34. Mode dekstop (a) Tampilan awal (b). Tampilan Hasil	68
35. Tampilan pada mode mobile	69

DAFTAR TABEL

Tabel	Halaman
1. Penelitian Terkait	
2. Karakteristik Acne Vulgaris.	11
3. Perbandingan kecepatan model	21
4. Jumlah Anotasi Kategori AV	35
5. Perbandingan Hasil Penelitian	61

DAFTAR KODE PROGRAM

Kode Program	Halaman
1. Install dan Import Library	46
2. Training dataset	
3. Counting	

I. PENDAHULUAN

1.1 Latar Belakang dan Masalah

Acne Vulgaris (AV) atau jerawat adalah kelainan inflamasi kulit kronis yang terjadi pada unit pilosebaceous. Kondisi ini umumnya bermanifestasi sebagai papula, pustula, atau nodul, terutama di wajah, tetapi juga dapat menyerang area lain seperti lengan atas, badan, dan punggung. Meskipun bersifat ideopatik, beberapa faktor dapat memicu timbulnya AV, termasuk peningkatan produksi sebum, hiperkeratinisasi folikel rambut, kolonisasi bakteri *Propionibacterium acnes (P. acnes)*, dan proses inflamasi. Faktor risiko lain yang berkontribusi meliputi pola makan, penggunaan kosmetik, dan stres psikologis (Sutaria dkk., 2023).

Insiden tertinggi AV ditemukan pada remaja laki-laki berusia 16-19 tahun dan remaja perempuan berusia 14-17 tahun. Berdasarkan Studi *Global Burden of Disease* (GBD), sekitar 85% orang dewasa muda berusia 12-25 tahun mengalami AV. Penelitian di Jerman menunjukkan bahwa 64% individu berusia 20-29 tahun dan 43% individu berusia 30-39 tahun juga mengalami AV. Selain itu, penelitian di India menyatakan bahwa AV menyerang lebih dari 80% populasi dunia pada beberapa tahap kehidupan, dan sekitar 85% remaja di negara maju.

Prevalensi AV di kawasan Asia Tenggara berkisar antara 40-80%. Di Indonesia, penelitian di Lampung menunjukkan bahwa perempuan lebih banyak menderita AV dibandingkan laki-laki, dengan presentase masing-masing sebesar 69,7% dan 30,3%. Usia muda dengan rentang 16-25 tahun lebih banyak mengalami AV, yaitu sebesar

53,2%, dan prevalensi AV lebih tinggi pada pengguna kosmetik yaitu sebesar 59,1% (Sibero dkk., 2020).

Dampak AV tidak hanya terbatas pada fisik, tetapi juga psikologis. Gangguan seperti depresi dan kecemasan sering dialami oleh penderita, yang dapat menurunkan kualitas hidup, terutama pada remaja. Selain itu, AV juga dikaitkan dengan kejadian hiperpigmentasi pasca-inflamasi (post-inflammatory hyperpigmentation/PIH) dan jaringan parut di masa dewasa, yang dapat mempengaruhi kualitas hidup di kemudian hari (Wetarini, 2020).

Salah satu faktor pemicu utama AV adalah stres. Stres memicu respons di otak melalui aktivasi sumbu hipotalamus-hipofisis-adrenal (HPA), yang mempengaruhi fungsi kelenjar *sebaceous*. Kelenjar *sebaceous* memiliki reseptor terhadap hormon pelepas kortikotropin (CRH), sehingga peningkatan kadar CRH saat stres dapat merangsang produksi sebum berlebih yang menyumbat saluran kelenjar *pilosebaceous* (Jusuf dkk., 2021). Penanganan AV secara efektif dan tepat waktu diperlukan untuk mempercepat penyembuhan kulit, mencegah munculnya AV baru, menghindari terbentuknya jaringan parut permanen, serta mengurangi beban psikososial penderita (Wiraputranto dkk., 2024).

Berbagai metode telah diterapkan dalam bidang medis untuk mengidentifikasi jenis AV. Salah satunya adalah inspeksi visual atau palpasi, yaitu pemeriksaan dengan perabaan tangan. Namun, metode ini memiliki kelemahan, seperti risiko iritasi dan ketidakpastian kebersihan tangan. Alternatif lain adalah penggunaan *skin analyzer portable* atau 3D *skin analyzer*, tetapi alat ini memiliki harga yang cukup mahal dan tidak tersedia di semua klinik kecantikan (Hasanah dkk., 2022).

Salah satu teknologi yang menjanjikan untuk deteksi AV adalah arsitektur jaringan saraf tiruan *You Only Look Once* (YOLO). Versi terbaru, YOLOv11, meningkatkan efisiensi dan akurasi deteksi objek dengan memanfaatkan sistem *grid* dan kotak pembatas (*bounding box*), memungkinkan deteksi dan klasifikasi objek secara simultan

dalam satu citra. Teknologi ini dapat membantu individu mengenali jenis AV yang dialami dan menentukan tindakan pencegahan yang sesuai untuk menghindari perburukan kondisi kulit.

Berbagai penelitian sebelumnya telah mengeksplorasi berbagai metode untuk klasifikasi AV. Misalnya, Yunita dkk. (2022) membandingkan metode *Gray Level Cooccurance Matrix* (GLCM) dan *K-Nearest Neighbor* (KNN), dengan akurasi tertinggi sebesar 94,5% pada nilai K=3. Penelitian lain oleh Kristin dkk. (2022) menggunakan algoritma *Viola Jones* untuk mengidentifikasi penyebab AV berdasarkan lokasi pada wajah, dengan tingkat akurasi sebesar 78,50%. Selain itu, penelitian yang menggunakan YOLOv5 menunjukkan bahwa pengoptimal *Stochastic Gradient Descent* (SGD) memberikan hasil terbaik dengan nilai F1 tertinggi dibandingkan pengoptimal lainnya.

Penelitian ini bertujuan untuk meningkatkan kinerja klasifikasi AV dengan memanfaatkan perkembangan terbaru dalam arsitektur YOLOv11. Versi terbaru ini menawarkan kemampuan untuk menangkap detail visual yang lebih halus dengan struktur yang lebih efisien. Peningkatan pada bagian backbone dan neck, serta penambahan elemen seperti blok C3k2, Spatial Pyramid Pooling-Fast (SPPF), dan Convolutional block with Parallel Spatial Attention (C2PSA), memberikan keunggulan dalam ekstraksi fitur dan pemrosesan data. Selain itu penelitian ini juga mencakup implementasi deploy sistem deteksi AV berbasis YOLOv11 ke dalam aplikasi berbasis web atau perangkat lunak. Implementasi ini bertujuan untuk mempermudah pengguna dalam mengakses teknologi deteksi AV secara real-time, sehingga dapat sebagai alat bantu edukasi dan pemantauan mandiri. Berdasarkan uraian latar belakang ini, penelitian ini berjudul "Deteksi Acne Vulgaris (AV) Menggunakan You Only Look Once Versi 11 (YOLOv11)".

1.2 Rumusan Masalah

Rumusan masalah dari penelitian ini adalah sebagai berikut:

- 1. Penggunaan arsitektur YOLOv11 diperlukan untuk mendeteksi AV pada wajah manusia secara *real-time* melalui citra digital.
- 2. Peningkatan akurasi dalam mendeteksi objek kecil seperti AV menjadi tantangan utama yang perlu diselesaikan dengan model YOLO versi terbaru.
- 3. Evaluasi kinerja model YOLOv11 perlu dilakukan untuk mengetahui nilai ratarata *Intersection over Union* (IoU), *presision*, dan *recall* dalam mengidentifikasi lima jenis AV.

1.3 Tujuan Penelitian

Penelitian ini bertujuan untuk mengimplementasikan dan mengevaluasi kinerja YOLOv11 dalam identifikasi gambar wajah manusia untuk mendeteksi AV dengan:

- 1. Memahami secara mendalam arsitektur YOLOv11 serta mekanisme kerja deteksi objek *real-time*, termasuk sistem *grid, bounding box,* dan *confidence score* dalam konteks identifikasi AV.
- 2. Merancang dan mengimplementasikan model YOLOv11 yang efisien dan akurat untuk mendeteksi lima jenis AV, yaitu *whitehead, blackhead, papule, pustule,* dan *nodule,* dengan mempertimbangkan struktur jaringan, ukuran *anchor box,* dan parameter pelatihan yang optimal.
- 3. Mengevaluasi kinerja model YOLOv11 dalam tugas klasifikasi AV berdasarkan metrik evaluasi seperti nilai rata-rata *Intersection over Union* (IoU), *presision*, dan *recall* guna menilai efektivitas model dalam mendeteksi objek berukuran kecil pada wajah manusia.

1.4 Manfaat Penelitian

- 1. Memberikan kontribusi dalam pengembangan sistem identifikasi AV secara otomatis berbasis *deep learning* menggunakan YOLOv11, khususnya pada objek kecil dalam citra.
- 2. Menjadi referensi bagi layanan kesehatan atau klinik kecantikan dalam mengadopsi teknologi deteksi AV berbasis citra dengan metode deteksi objek *real time*.
- 3. Memberikan acuan bagi peneliti selanjutnya yang ingin menerapkan metode YOLOv11 dalam berbagai jenis citra yang berbeda atau kasus klasifikasi objek lainnya.

II. TINJAUAN PUSTAKA

2.1 Penelitian Terkait

Beberapa penelitian sebelumnya yang relevan digunakan sebagai dasar untuk memperkuat pemahaman terhadap metode yang diterapkan dalam penelitian ini. Penelitian-penelitian tersebut juga berfungsi sebagai bahan pembanding antara hasil studi terdahulu dan hasil yang diperoleh dalam penelitian ini. Uraian mengenai penelitian terkait disajikan pada Tabel 1.

Tabel 1. Penelitian Terkait

No.	Penelitian	Data	Metode	Hasil
1.	Penelitian Penerapan Algoritma GLCM dan KNN dalam Pengenakan Jenis Jerawat (Yunita dkk., 2022)	Data gambar diambil melalui web https://www.google.com/dan langsung dari penderita jerawat dan jenis jerawat yang diidentifikasi dari ahli sebanyak 180 citra	GLCM dan KNN.	Pendeteksian berhasil dengan model KNN dengan akurasi rata- rata 87,3%.
		gambar.		

No.	Penelitian	Data	Metode	Hasil
2.	Klasifikasi	Sebanyak 107 data citra	Gray Level	Dari 107 Citra
	Penyebab	wajah teman-teman	Co-	gambar model
	Jerawat	peneliti (Sumber:	Occurrence	berhasil
	Berdasarkan	Primer).	Matrix	mendeteksi
	Area Pada		(GLCM).	sebanyak 84 area
	Wajah			wajah yang
	Menggunakan			terdeteksi
	Metode Gray			jerawat, dengan
	Level Co-			tingkat akurasi
	Occurrence			78,50%.
	Matrix			
	(GLCM)			
	(Kristin dkk.,			
	2023).			
3.	Facial Skin	243 gambar berisikan	YOLOv5	Precision 54%,
	Analysis in	jerawat pada area facial		recall 44,6%,
	Malaysians	(Sumber: Pool of		dan mAP50
	using Yolov5:	Multimedia University		42.4%.
	A Deep	(MMU)).		
	Learning			
	Perspective			
	(Y.H. Gan			
	dkk., 2024).			

Berikut adalah ringkasan penelitian terdahulu yang disajikan pada Tabel 1 sebagai berikut:

a. Penelitian Pertama (Yunita dkk., 2022)

Penelitian ini menggunakan metode algoritma *K-Nearest Neighbors* (KNN) untuk mengidentifikasi jenis jerawat dan algoritma *Gray Level Co-occurrence Matrix* (GLCM) untuk mengektraksi pola dari citra. Tahap pertama dalam penelitian ini adalah pengumpulan data. Data citra jerawat yang diperoleh melalui situs web https://www.google.com/ dan secara langsung dari penderita jerawat, dengan total sebanyak 180 gambar. Kumpulan data terdiri dari enam jenis jerawat yaitu papula, pustula, nodul, kistik, *blackhead*, dan *whitehead*.

Tahap *preprocessing* mencakup beberapa proses, yaitu *cropping, resize,* dan *compression*. Setelah itu, segmentasi dilakukan untuk mengubah tipe citra jerawat menjadi citra *grayscale*. Algoritma GLCM adalah metode statistik orde kedua yang menghitung probabilitas hubungan spasial antara dua piksel dengan jarak (*d*) dan sudut (θ) tertentu. Proses kerja GLCM melibatkan penentuan sifat-sifat fungsional dari matriks antar piksel. Beberapa parameter yang digunakan untuk mendapatkan fitur GLCM dalam penelitian ini adalah *contrast, correlation, energy,* dan *homogeneity*. Algoritma KNN adalah algoritma klasifikasi yang menggunakan jarak terdekat dengan suatu objek atau fitur sebagai dasar pengambilan keputusan. Pengujian dilakukan dengan membagi data menjadi 60% data latih dan 40% data uji. Hasil pengujian menunjukkan akurasi sebesar 94,5% pada nilai ketetanggan (*neighbour*) 3. Ketika nilai ketetanggan lebih dari 3, akurasi menurun, tetapi penurunan tersebut tidak terlalu signifikan.

b. Penelitian Kedua (Kristin dkk., 2023)

Penelitian ini dilakukan untuk mencari penyebab jerawat berdasarkan letak pada wajah berbasis *image processing*. Algoritma *Viola Jones*, yang diperkenalkan oleh Paul Viola dan Michael Jones pada tahun 2001, merupakan algoritma yang paling baik untuk melakukan deteksi objek wajah dan tubuh bagian atas. Langkah pertama yang dilakukan pada penelitian ini adalah meng-*input* citra wajah berjerawat berdasarkan letaknya, seperti jerawat di dahi, jerawat di hidung, jerawat di pipi, jerawat di dagu, dan jerawat antar alis. Tahap *preprocessing* data dilakukan melalui konversi RGB menjadi *grayscale*, setelah itu, proses *cropping* diterapkan untuk memfokuskan pada area yang relevan dari citra.

Ekstraksi ciri dilakukan untuk mengambil informasi pokok dari suatu citra menggunakan metode GLCM. Metode ini menganalisis hubungan antara dua piksel tetangga berdasarkan intensitas keabuan, jarak, dan sudut tertentu. Fitur yang digunakan untuk memperoleh ciri tekstur dari suatu objek meliputi kontras, korelasi, energi, dan homogenitas, yang kemudian diklasifikasikan ke dalam bentuk pohon keputusan. Hasil penelitian menunjukkan bahwa dari 107 area pada wajah yang

berjerawat, sebanyak 84 area berhasil terdeteksi. Tingkat akurasi metode GLCM pada sistem yang dirancang mencapai 78,50%.

c. Penelitian Ketiga (Y.H. Gan dkk., 2024)

Penelitian ini berfokus pada analisis kulit wajah orang Malaysia, dengan *dataset* diperoleh dari mahasiswa dan komunitas Universitas Multimedia (MMU), sebanyak 243 gambar. Persiapan data dilakukan menggunakan *LabelImg*, sebuah alat untuk melabeli gambar secara grafis. Alat ini digunakan untuk menggambar kotak pembatas di sekitar fitur kulit wajah, seperti jerawat, pori-pori membesar, atau warna kulit tidak merata. *Dataset* tersebut diberi label dengan sembilan nama kelas, yaitu *acne, uneven skin, fine lines, blackheads, uneven skin tones, enlarged pores, shines, redness*, dan *pigment*.

Hasil terbaik diperoleh dengan menggunakan 100 *epoch*, menghasilkan presisi sekitar 54%, *recall* 44,6%, dan mAP50 sebesar 42,4%. Hasil ini lebih baik dibandingkan dengan menggunakan 50, 80, dan 120 *epoch*. Pada penelitian ini, ukuran batch (*batch size*) juga diatur sebesar 16. Selain proses pelabelan, penelitian ini juga menampilkan berbagai karakteristik kulit berdasarkan jenisnya. Sebagai contoh, kulit kering cenderung tidak memiliki jerawat, tetapi dapat menunjukkan tanda-tanda seperti kulit tidak rata, komedo, warna kulit tidak merata, dan pori-pori membesar. Sebaliknya, kulit berminyak akan memiliki peluang lebih besar untuk mengembangkan jerawat, kulit tidak rata, komedo, warna kulit tidak merata, dan pori-pori membesar. Kulit normal tidak memiliki masalah kulit, sedangkan kulit sensitif lebih rentan terhadap iritasi dan kemerahan.

Sistem yang dirancang telah menentukan berbagai kondisi sebagai garis dasar untuk setiap jenis kulit. Kulit dianggap kering jika jerawat berjumlah tiga atau kurang, sedangkan jika jumlah jerawat berjumlah empat atau lebih, maka dikategorikan sebagai kulit berminyak. Kulit dianggap normal jika tidak ada jerawat yang terdeteksi, dan kulit disebut sensitif jika terdapat kemerahan pada wajah. Hasil dari model YOLOv5 yang dilatih dengan *hyperparameter* yang berbeda menunjukkan bahwa penggunaan *epoch* dan ukuran *batch* yang lebih tinggi dapat menghasilkan

kinerja yang lebih baik dalam mendeteksi kondisi kulit. Mesikpun menambahkan lebih banyak *epoch* dapat memperpanjang waktu pelatihan, kinerja deteksi meningkat karena jaringan saraf memiliki lebih banyak kesempatan untuk mempelajari pola data tanpa *overfitting*. Semakin tinggi *epoch*, semakin besar peluang model untuk memperbaiki bias dan bobotnya, sehingga meningkatkan akurasi deteksi.

2.2 Acne Vulgaris (AV)

Acne Vulgaris adalah salah satu penyakit kulit kronis yang umum terjadi, yang berkaitan dengan penyumbatan dan/atau peradangan pada folikel rambut dan kelenjar minyak yang menyertainya (Rosiani dkk., 2021). Penyakit ini memiliki patogenesis yang kompleks, melibatkan beberapa faktor seperti hiperkeratinisasi folikular, kolonisasi bakteri *Cutibacterium acnes*, produksi sebum berlebih, dan reaksi inflamasi tubuh. Insiden tertinggi terjadi pada remaja laki-laki berusia 16-19 tahun dan perempuan berusia 14-17 tahun. Berdasarkan studi *Global Burden of Disease* (GBD), AV memengaruhi sekiar 85% orang dewasa muda berusia 12-25 tahun.

Acne Vulgaris dapat diklasifikasikan menjadi beberapa jenis lesi inflamasi, yaitu comedones (komedo terbuka dan tertutup), papules (papula), pustules (pustula) dan nodules (nodul). Klasifikasi ini didasarkan pada perbedaan karakteristik klinis setiap lesi, seperti tingkat peradangan, ukuran, dan kedalaman AV (Maulida & Topik, 2024). Setiap jenis lesi memiliki manifestasi klinis yang berbeda. Komedo, yang merupakan lesi non-inflamasi terdiri dari whitehead dan blackhead. Whitehead muncul sebagai benjolan kecil berwarna putih di permukaan kulit akibat penyumbatan pori-pori di bagian bawah kulit, sedangkan blackhead terjadi ketika bagian atas whitehead terkena udara, menyebabkan sebum teroksidasi dan berubah warna menjadi hitam. Lesi inflamasi seperti papule dan pustule muncul ketika whitehead terinfeksi oleh bakteri. Papule ditandai dengan benjolan kecil berwarna merah yang meradang, sedangkan

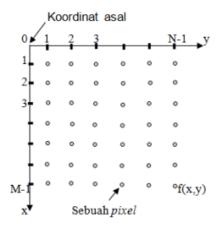
pustule adalah benjolan berisi nanah dengan titik putih kekuningan. Selain itu nodul adalah benjolan keras, merah, dan nyeri yang dapat berlangsung beberapa minggu hingga bulan. Klasifikasi ini membantu tenaga medis dalam menentukan pendekatan pengobatan yang tepat sesuai dengan jenis dan tingkat keparahan AV (Maulida & Topik, 2024). Karakteristik dari lima kategori lesi AV utama ditampilkan pada Tabel 2.

Tabel 2. Karakteristik Acne Vulgaris.

Lesi Acne Vulgaris	Contoh Citra	Ukuran	Warna
Blackhead		Kecil	Hitam atau coklat
Whitehead		Diameter < 5 mm	Putih
Papules		Diameter < 5 mm	Pink atau merah terang, sangat meradang, banyak, dan biasanya lebih menonjol
Pustules		Diameter < 5 mm	Nanah di bagian ujungnya, peradangan merah di sekitarnya
Nodules		Diameter > 5 mm	Pink atau merah dan berukuran besar

2.3 Citra Digital

Citra digital adalah gambar dua dimensi yang dihasilkan dari citra analog yang kontinu melalui proses *sampling*. Proses ini membagi gambar analog menjadi N baris dan M kolom sehingga membentuk citra diskrit. Citra digital merupakan representasi yang dapat diolah oleh komputer, di mana data yang disimpan hanya berupa angka-angka yang menunjukkan intensitas pada masing-masing piksel, seperti yang ditunjukkan pada Gambar 1. Citra digital dapat diproses dan dimanipulasi menggunakan perangkat lunak komputer karena berbentuk data numerik (Nadzir dkk., 2019).



Gambar 1. Koordinat citra digital (Basuki dkk., 2022).

Sebuah citra digital dapat diwakili oleh sebuah matriks yang terdiri dari M kolom dan N baris, di mana perpotongan antara kolom dan baris tersebut membentuk piksel (picture element) yang merupakan elemen terkecil dari sebuah citra. Setiap piksel memiliki dua parameter utama, yaitu koordinat dan intensitas atau warna. Nilai yang terdapat pada koordinat (x, y) dinyatakan sebagai f(x, y) yang menunjukkan besar intensitas atau warna dari piksel pada titik tersebut. Perhitungan manual yang dilakukan untuk memperoleh hasil pengolahan citra berdasarkan Persamaan (1).

$$f(x,y) = \begin{bmatrix} f_{(1,1)} & f_{(1,2)} & \cdots & f_{(1,N)} \\ f_{(2,1)} & f_{(2,2)} & \cdots & f_{(2,N)} \\ \vdots & \vdots & \ddots & \vdots \\ f_{(M,1)} & f_{(M,2)} & \cdots & f_{(M,N)} \end{bmatrix}$$
(1)

Berdasarkan Persamaan 1, secara matematis, citra digital dapat dinyatakan sebagai intensitas $f_{(x,y)}$, di mana nilai x (baris) dan y (kolom) merupakan koordinat posisi, dan $f_{(x,y)}$ adalah nilai fungsi pada setiap titik (x,y) yang menunjukkan besar intensitas yang diterima oleh citra, baik dalam bentuk tingkat keabuan maupun warna dari piksel pada titik tersebut. Besar intensitas ini tergantung pada cahaya yang dipantulkan oleh objek. Dengan demikian, $f_{(x,y)}$ sebanding dengan energi yang dipancarkan oleh sumber cahaya (Nadzir dkk., 2019).

2.3.1 Pengolahan Citra Digital

Pengolahan citra digital adalah ilmu yang mempelajari berbagai teknik untuk meningkatkan kualitas gambar, seperti meningkatkan kontras, mengubah warna, dan melakukan restorasi citra. Selain itu pengolahan citra juga mencakup transformasi gambar seperti translasi, rotasi transformasi skala, dan geometrik. Proses ini juga melibatkan pemilihan fitur citra (*feature images*) yang optimal untuk tujuan analisis, penyimpanan data dengan reduksi dan kompresi, transmisi data, serta pengolahan data secara efisien (Nadzir dkk., 2019). Pengolahan citra digital digunakan sebagai bagian dari teknologi pengindraan mesin otomatis, yang kini berkembang pesat dengan dukungan teknologi komputer. Perkembangan ini memungkinkan pengolahan citra digital dilakukan secara *real-time*, menyimpan citra dengan kapasitas memori yang lebih kecil tanpa mengurangi kualitas, serta mengirimkan citra dengan cepat ke tempat yang berjarak jauh.

Salah satu jenis citra digital adalah citra warna *Red*, *Green*, dan *Blue* (RGB), yang merupakan skema warna yang terdiri dari tiga warna utama : merah (*red*), hijau (*green*),

dan biru (*blue*). Warna-warna ini dapat dikombinasikan dengan berbagai cara untuk menghasilkan beragam warna lainnya. Salah satu contoh proses pengolahan citra adalah mengubah citra RGB menjadi *grayscale*. Proses ini dilakukan dengan menghitung rata-rata nilai intensitas RGB dari setiap piksel penyusun citra tersebut (Fitri dan Abdul, 2017). Ilustrasi nilai citra berwarna dijabarkan pada Persamaan (2, 3, 4, dan 5).

$$I_{red}(m,n,1) = \begin{bmatrix} r_{11} & r_{12} & \cdots & r_{1n} \\ r_{21} & r_{22} & \cdots & r_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ r_{m1} & r_{m2} & \cdots & r_{mn} \end{bmatrix}$$
 (2)

$$I_{green}(m, n, 1) = \begin{bmatrix} g_{11} & g_{12} & \cdots & g_{1n} \\ g_{21} & g_{22} & \cdots & g_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ g_{31} & g_{mn} & \cdots & g_{mn} \end{bmatrix}$$
(3)

$$I_{blue}(m,n,1) = \begin{bmatrix} b_{11} & b_{12} & \cdots & b_{1n} \\ b_{21} & b_{22} & \cdots & b_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ b_{m1} & b_{m2} & \dots & b_{3n} \end{bmatrix}$$
(4)

$$f_g(x,y) = \frac{f_l^R(x,y) + f_l^g(x,y) + f_l^b(x,y)}{3}$$
 (5)

Dengan:

 $f_q(x, y)$ = nilai citra grayscale

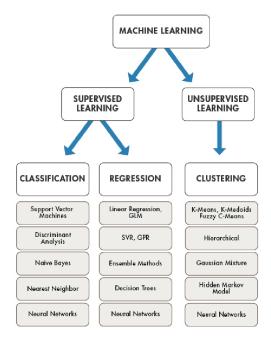
 $f_l^R(x,y)$ = nilai elemen citra warna merah

 $f_l^g(x, y)$ = nilai elemen citra warna hijau

 $f_l^b(x,y)$ = nilai elemen citra warna biru

2.4 Machine Learning (ML)

Machine Learning merupakan pendekatan dalam Artificial Intelligence (AI) yang digunakan untuk menggantikan atau menirukan perilaku manusia dalam menyelesaikan masalah atau melakukan otomatisasi. Sesuai dengan namanya, ML mencoba menirukan bagimana manusia atau makhluk cerdas belajar dan menggeneralisasi. Setidaknya, ML memiliki dua aplikasi utama yaitu klasifikasi dan prediksi. Ciri khas dari ML adalah adanya proses pelatihan atau pembelajaran (training). Oleh karena itu, ML membutuhkan data yang disebut sebagai data training untuk dipelajari. Klasifikasi adalah metode dalam ML yang digunakan untuk memilah atau mengklasifikasikan objek berdasarkan ciri tertentu, sebagaimana manusia membedakan benda satu dengan yang lain (Ahmad, 2017). Terdapat beberapa teknik pada ML yang dapat digunakan, sebagaimana ditunjukkan pada Gambar 2, sebagai berikut:



Gambar 2. Supervised dan Unsupervised Learning (Poola, 2017).

Pembelajaran ML, memiliki dua teknik utama, yaitu *supervised learning* dan *unsupervised learning*, yang dijelaskan sebagai berikut:

1. Pembelajaran terawasi (Supervised Learning)

Supervised learning merupakan teknik melatih mesin menggunakan data yang telah diberi label (Brownlee, 2017). Data label atau target berperan sebagai "supervisor" atau "guru" yang mengawasi proses pembelajaran mencapai tingkat akurasi atau prediksi tertentu. Beberapa data sudah ditandai dengan jawaban yang benar, sehingga mesin belajar membuat model yang menghasilkan prediksi yang benar atau mendekati saat diberikan data baru. Misalnya, untuk memprediksi harga rumah, variabel input seperti luas rumah dan jumlah kamar digunakan, sementara harga rumah berfungsi sebagai label output. Data ini memungkinkan mesin membuat model yang memprediksi harga rumah (Kristiawan & Andreas, 2021). Algoritma yang termasuk supervised learning adalah regresi dan klasifikasi.

2. Pembelajaran Tanpa Pengawasan (*Unsupervised Learning*)

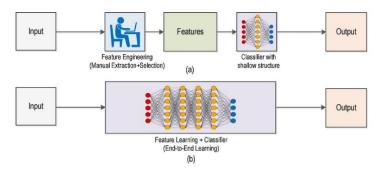
Unsupervised learning merupakan teknik pembelajaran mesin di mana mesin tidak memerlukan data berlabel. Mesin bekerja secara mandiri untuk menemukan pola atau informasi tersembunyi dalam data yang tidak memiliki label. Sebagai contoh, untuk mengelompokkan rumah berdasarkan jumlah kamar dan luas rumah, data rumah dengan variabel jumlah kamar dan luas rumah diberikan. Mesin akan membuat model yang mengelompokkan rumah menjadi beberapa kelompok berdasarkan kedua variabel tersebut. Ketika data baru diberikan, mesin dapat menentukan kelompok mana yang sesuai untuk data tersebut. Algoritma yang termasuk dalam unsupervised learning adalah clustering, association, dan dimensionality reduction (Poola, 2017).

2.5 Deep Learning (DL)

Teknik ML tradisional memiliki keterbatasan dalam memproses data alami yang masih berbentuk mentah. Selama beberapa dekade, para peneliti membangun sistem pengenalan pola atau ML membutuhkan *feature extractor*. *Feature extractor* berfungsi

mengubah data mentah, seperti nilai piksel gambar menjadi representasi *internal* atau vektor fitur yang sesuai, representasi ini kemudian digunakan oleh *subsistem* pembelajaran, biasanya berupa klasifikator, untuk mendeteksi atau mengklasifikasikan pola pada *input*.

Metode DL merupakan pendekatan *representation learning* yang menggunakan beberapa tingkat representasi. Representasi ini diperoleh melalui komposisi modulmodul sederhana namun *non-linear*. Setiap modul mengubah representasi pada satu tingkat, dimulai dari *input* mentah, menjadi representasi pada tingkat yang lebih tinggi dan lebih abstrak, seperti yang ditunjukkan pada Gambar 3. Melalui komposisi transformasi yang cukup banyak, fungsi yang sangat kompleks dapat dipelajari.



Gambar 3. (a) Alur kerja *Computer Vision* Tradisional. (b) Alur kerja *Deep Learning* (Wang dkk., 2018).

Pada tugas klasifikasi, lapisan representasi yang lebih tinggi memperkuat aspek-aspek *input* yang relevan untuk diskriminasi dan menekan variasi yang tidak penting. Sebagai contoh, gambar berbentuk *array* nilai piksel akan diproses pada lapisan pertama untuk mendeteksi keberadaan atau ketiadaan tepi pada orientasi dan lokasi tertentu (Zhao dkk., 2024). Lapisan kedua mendeteksi motif melalui pengenalan susunan tepi tertentu tanpa memperhatikan variasi kecil pada posisi tepi. Lapisan ketiga merangkai motif menjadi kombinasi yang lebih besar sesuai bagian-bagian objek yang dikenal. Lapisan-lapisan berikutnya mendeteksi objek sebagai kombinasi dari bagian-bagian tersebut.

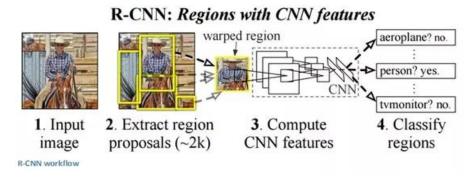
Metode DL telah membuat kemajuan besar dalam menyelesaikan berbagai permasalahan yang sebelumnya sulit diatasi oleh komunitas kecerdasan buatan. Teknologi ini sangat unggul dalam menemukan struktur kompleks dalam data berdimensi tinggi, sehingga memungkinkan penerapannya pada berbagai bidang, termasuk ilmu pengetahuan, bisnis, dan pemerintahan. Selain mencapai prestasi luar biasa dalam penganalan gambar, penganalan suara, dan pemahaman bahasa alami, DL juga telah menunjukkan kemampuannya dalam berbagai aplikasi seperti klasifikasi topik, analisis sentimen, menjawab pertanyaan, dan penerjemahan bahasa. Teknologi ini terus berkembang dan memberikan kontribusi signifikan dalam meningkatkan akurasi dan efisiensi dalam berbagai bidang.

2.6 Object Detection

Object detection adalah teknologi di bidang komputer yang berkaitan dengan computer vision dan image preprocessing yang dapat mendeteksi suatu benda ataupun manusia dalam gambar maupun video. Tujuan dari object detection adalah untuk meniru kecerdasan manusia dalam sebuah komputer. Object detection menentukan keberadaan suatu objek dan ruang lingkup serta lokasi pada sebuah gambar, dimana satu kelas mewakili objek dan kelas lain mewakiliki kelas non objek. Deteksi objek dapat dibagi kembali menjadi hard detection dan soft detection. Hard detection bisa mendeteksi adanya objek beserta lokasi pada objek, sedangkan soft detection hanya mendeteksi adanya objek saja (Wang, J. dkk., 2021).

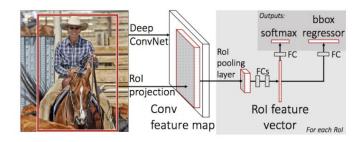
Pada awalnya, metode *object detection* dilakukan secara manual, di mana manusia memberikan masukan langsung kepada sistem mengenai objek yang perlu dideteksi (Borah, 2020). Seiring dengan perkembangan teknologi, pendekatan tradisional ini digantikan oleh metode berbasis *machine learning* dan *deep learning*, yang memungkinkan sistem untuk belajar secara otomatis dari data yang diberikan. Salah satu kemajuan penting dalam perkembangan *object detection* adalah diperkenalkannya

model *Region-based Convolutional Neural Network* (R-CNN) oleh Ross Girschick pada tahun 2014. Model ini menggunakan pendekatan dua tahap (*two-stage*), yaitu menghasilkan proposal wilayah (*region proposals*), dan melakukan klasifikasi pada wilayah tersebut, alur kerja R-CNN disajikan pada Gambar 4. Meskipun memiliki tingkat akurasi yang tinggi, R-CNN memiliki kelemahan dalam hal efisiensi karena membutuhkan waktu komputasi yang lama (Borah, 2020). Para peneliti mengembangkan model *Fast* R-CNN, alur kerja *Fast* R-CNN disajikan pada Gambar 5. Model ini meningkatkan efisiensi dengan memproses gambar *input* melalui CNN sebagai *feature extractor* untuk menghasilkan *convolutional feature map*. Melalui *feature map*, area proposal diidentifikasi tanpa perlu memasukkan 2000 proposal wilayah secara terpisah ke dalam CNN. Namun, *Fast* R-CNN masih menghadapi tantangan dalam hal kecepatan, terutama untuk kumpulan data besar.

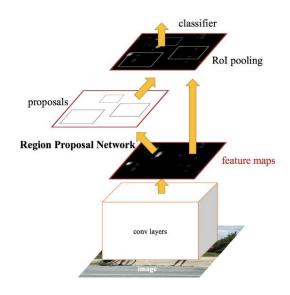


Gambar 4. Region CNN (Moin, 2023).

Selanjutnya, Faster R-CNN dikembangkan untuk meningkatkan kecepatan deteksi objek. Model ini memperkenalkan Region Proposal Network (RPN), yang bertindak sebagai mekanisme perhatian (attention mechanism) untuk menghasilkan wilayah proposal secara lebih efisien. Model Faster R-CNN merupakan model terpadu yang terdiri dari dua modul utama, yaitu RPN dan Fast R-CNN. Meskipun lebih cepat dibandingkan pendahulunya, Faster R-CNN hanya menghasilkan kotak pembatas (bounding boxes) dan tidak mendukung segmentasi semantik, yang ditampilkan pada Gambar 6.



Gambar 5. Fast R-CNN (Moin, 2023).



Gambar 6. Faster R-CNN (Moin, 2023).

Model YOLO (*You Only Look Once*) menawarkan pendekatan yang berbeda dibandingkan model berbasis *region* seperti R-CNN, *Fast* R-CNN, dan *Faster* R-CNN. Sebuah jaringan saraf konvolusi tunggal (*single* CNN) memprediksi kotak pembatas (*bounding boxes*) dan probabilitas kelas untuk kotak-kotak tersebut secara langsung dalam satu evaluasi. Pendekatan ini memungkinkan YOLO untuk mendeteksi objek secara *real-time* dengan kecepatan tinggi, mencapai hingga 45 *frame* per detik pada model dasar (Wang dkk., 2021). Perbandingan kecepatan antara model R-CNN, *Faste* R-CNN, *Faster* R-CNN, dan YOLO, disajikan pada Tabel 3 sebagai berikut:

Tabel 3. Perbandingan kecepatan model.

Model	Pascal2009maP	Kecepatan	
R-CNN	66,0	0.05 FPS	20s/gambar
Fast R-CNN	70,0	0.5 FPS	2s/gambar
Faster R-CNN	73,2	7 FPS	140ms/gambar
YOLO	63,4	45 FPS	22ms/gambar

2.7 You Only Look Once (YOLO)

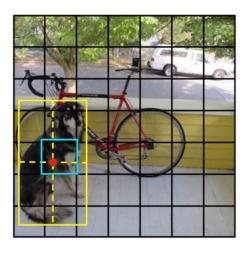
Pada tahun 2016, sebuah jaringan saraf diperkenalkan oleh Joseph Redmon, Santosh Divvala, Ross Girshick, dan Ali Farhadi. Jaringan ini mampu memproses 45 gambar per detik sekaligus menjalankan deteksi secara *real-time*. Metode ini dinamakan *You Only Look Once* (YOLO) karena kecepatan dan metode penggunaannya yang unik (Shan dkk., 2018). Metode ini sepenuhnya meninggalkan pendekatan deteksi dua tahap "*region candidate+regression*". Gambar yang akan diukur diubah ukurannya menjadi seragam, kemudian dibagi menjadi beberapa *grid*. Kategori target diprediksi berdasarkan *grid* tempat pusat target berada, dan hasil deteksi dihasilkan pada lapisan konvolusi terakhir.

Konsep dari metode ini mengubah deteksi target menjadi regresi. Seluruh gambar digunakan sebagai *input* jaringan, dan melalui satu jaringan saraf, lokasi *bounding box* serta kategorinya dapat diperoleh. Gambar *input* disesuaikan menjadi ukuran seragam 448×448 piksel. Setelah itu, gambar dibagi menjadi *grid* berukuran $S \times S$, seperti yang ditunjukkan pada Gambar 7.



Gambar 7. S×S grid pada YOLO (Aggarwal, 2020).

Jika pusat objek deteksi jatuh ke dalam sebuah *grid*, *grid* tersebut bertanggung jawab untuk mendeteksi objek tersebut, seperti yang ditunjukkan pada Gambar 8. Setiap *grid* memberikan skor pada kotak pembatasnya untuk memprediksi kemungkinan keberadaan objek deteksi. Nilai prediksi sebesar 0, menunjukkan bahwa tidak ada objek deteksi dalam sel *grid*. Setiap *grid* dalam metode ini dapat menghasilkan beberapa kotak pembatas, tetapi hanya kotak dengan skor tertinggi, yang dianggap sebagai objek paling mungkin yang akan dipilih untuk prediksi (Zhang dkk., 2019). Ilustrasi mengenai hal ini ditampilkan pada Gambar 8 dan 9.

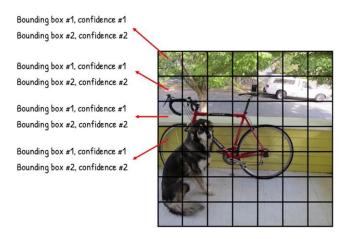


Gambar 8. Pusat deteksi grid (Redmon dkk., 2016).

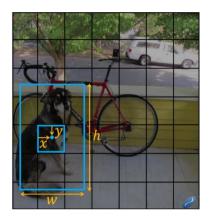


Gambar 9. Bounding Box tertinggi berwarna lebih gelap (Redmon dkk., 2016).

Setiap *grid* akan memprediksi B *bounding boxes* dan *confidence score* untuk setiap kotak. Arsitektur ini mengatur model untuk memprediksi dua *bounding boxes*, seperti yang ditunjukkan pada Gambar 10. Skor klasifikasi berada dalam rentang 0 hinga 1, dengan 0 sebagai tingkat *confidence score* terendah dan 1 sebagai yang tertinggi. Setiap *grid* terdiri dari lima parameter: x, y, *width, height*, dan *confidence score*, seperti yang ditampilkan pada Gambar 11.

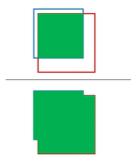


Gambar 10. Dua bounding boxes setiap cell (Astrid, 2022).



Gambar 11. Box coordinates (DeepBean, 2023).

Koordinat (x,y) merepresentasikan lokasi pusat dari *bounding box* yang diprediksi. *Width* dan *height* merupakan pecahan relatif terhadap ukuran keseluruhan gambar. *Confidence* merepresentasikan nilai *Intersection over Union* (IoU) antara *bounding box* yang diprediksi dan *bounding box* sebenarnya, yang disebut *ground truth box*. Rasio ini adalah perbandingan antara area perpotongan *bounding box* yang diprediksi dan *ground truth box* terhadap area gabungan (*union*) dari kedua *bounding box* tersebut (Aggarwal, 2020). Ilustrasi mengenai hal ini disajikan pada Gambar 12.

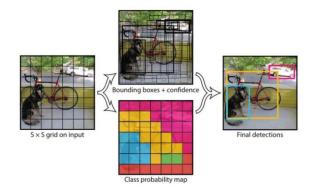


Gambar 12. Overlap (atas), union (bawah) (Padilla dkk., 2020).

Selain menghasilkan bounding boxes dan confidence score, setiap sel grid juga memprediksi kelas objek. Prediksi kelas ini direpresentasikan dalam bentuk vektor one-hot dengan panjang C, yang merupakan jumlah kelas dalam dataset. Namun, penting untuk dicatat bahwa meskipun setiap grid dapat memprediksi sejumlah bounding boxes dan confidence score untuk kotak-kotak tersebut, setiap sel hanya memprediksi satu kelas. Hal Ini menjadi salah satu keterbatasan dari algoritma YOLO.

Jika terdapat beberapa objek dengan kelas berada dalam satu sel *grid*, algoritma akan gagal mengklasifikasikan keduanya dengan benar.

Setiap prediksi dari satu sel *grid* memiliki bentuk $C + B \times 5$, di mana C adalah jumlah kelas dan B adalah jumlah *bounding boxes* yang diprediksi. Nilai B dikalikan dengan B karena mencakup informasi B0, B1, width, height, dan confidence) untuk setiap bounding box. Karena terdapat B1, sel grid dalam setiap gambar, prediksi keseluruhan berbentuk tensor dengan dimensi B2, width, height, dan confidence B3, with the setiap gambar B4, with the setiap gambar B5, dimensi B6, with the setiap gambar B8, with the setiap gambar B9, with the setiap gambar B1, with the



Gambar 13. YOLO arsitektur (Redmon dkk., 2018).

2.8 Perkembangan YOLO

Sejak diperkenalkannya YOLOv1, model tersebut telah mengalami beberapa kali iterasi, yang masing-masing mengalami peningkatan dari segi akurasi, kecepatan, dan efisiensi, seperti yang ditampilkan pada Gambar 14. Penjelasan mengenai berbagai versi YOLO sebagai berikut:



Gambar 14. Perkembangan YOLO (Nikhileswara, 2024).

Model ketiga dari algoritma ini memperkenalkan prediksi multiskala, yang memungkinkan deteksi objek pembatas pada tiga skala yang berbeda. Peningkatan ini secara signifikan meningkatkan kemampuan model dalam mendeteksi objek dengan berbagai ukuran. Penambahan lapisan *Spatial Pyramid Pooling* (SPP) ke jaringan *backbone* juga memperluas bidang reseptif model, sehingga meningkatkan kemampuan ekstraksi fiturnya (Ali Farhadi & Joseph Redmon, 2018).

Model kelima mengembangkan kemampuan dengan mengadopsi modul C3 dalam jaringan *backbone*-nya. Model ini mengurangi kompleksitas komputasi dan meningkatkan kecepatan inferensi. Model ini juga memperkenalkan augmentasi data *mosaic*, khususnya *mosaic4*, yang menggabungkan dan mentransformasi empat gambar secara acak untuk meningkatkan representasi fitur dan pembelajaran model. Optimisasi kotak jangkar adaptif juga ditambahkan, memungkinkan model menangani objek dalam berbagai ukuran dengan lebih baik.

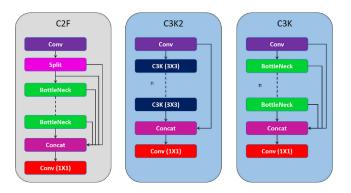
Model kedelapan menyempurnakan arsitektur dengan menggantikan modul C3 dengan modul c2f, yang meningkatkan efisiensi ekstraksi fitur. Model ini juga memperkenalkan mekanisme deteksi tanpa jangkar (anchor-free) untuk meningkatkan deteksi target kecil. Proses augmentasi mosaic dioptimalkan dengan menghindari penggunanya pada sepuluh epoch pelatihan terakhir, sehingga meningkatkan generalisasi model.

Model kesembilan memperkenalkan *Progressive Gradient Integration*, yang mengatasi keterbatasan supervisi pada arsitektur yang kompleks serta membuat

arsitektur menjadi lebih ringan dan praktis. Sebuah arsitektur jaringan baru, yang disebut *Generalized High–Efficiency Layer Aggregation Network* (GELAN) diusulkan. Arsitektur ini mengintegrasikan desain *CrossStage Partial Network* (CSPNet) dan *Efficient Layer Aggregation* (ELAN), menyeimbangkan desain model ringan, kecepatan inferensi, dan akurasi. Koneksi parsial antar tahap digunakan untuk menghubungkan peta fitur di berbagai tahap, memperkaya informasi semantik, dan meningkatkan akurasi deteksi (Wang dkk., 2024).

Model kesepuluh dari algoritma deteksi objek mengadopsi arsitektur *dual-head* dengan *head one-to-many* dan *head one-to-one*. Selama pelatihan, kedua *head* ini digunakan, tetapi untuk inferensi hanya *head one-to-one* yang digunakan, sehingga meningkatkan presisi prediksi. Penambahan modul *Feature Pyramid Attention* (PSA) setelah *Spatial Pyramid Pooling Fast* (SPPF) mendorong pembelajaran fitur global dan lebih meningkatkan kinerja deteksi (Wang dkk., 2024).

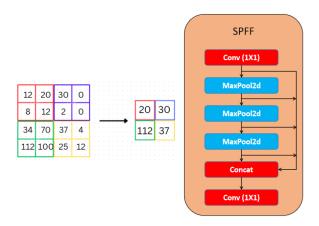
Pada iterasi terbaru, model kesebelas menggantikan modul C2f dengan modul C3K2, yaitu lapisan *bottleneck* CSP yang dirancang khusus dengan dua lapisan konvolusi yang lebih kecil. Perubahan ini meningkatakan kecepatan pemrosesan tanpa mengorbankan kinerja, yang ditampilkan pada Gambar 15.



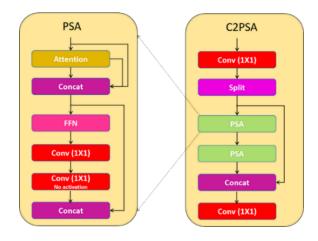
Gambar 15. Perbandingan C2F dan C3K2 Blocks (Nikhileswara, 2024).

Model kesebelas tetap mempertahankan modul *Spatial Pyramid Pooling Fast* dari model kedelapan, sebagaimana ditunjukkan pada Gambar 16. Selain itu, model ini memperkenalkan modul C2PSA yang mampu mengintegrasikan informasi *channel* dan

spasial melalui mekanisme *multi-head attention* untuk ekstraksi fitur yang lebih efisien, seperti yang direpresentasikan pada Gambar 17. Mekanisme kotak jangkar adaptif juga disempurnakan untuk mengoptimalkan konfigurasi di berbagai *dataset*, sehingga meningkatkan akurasi deteksi. Model kesebelas juga memperluas kemampuannya ke tugas-tugas seperti segmentasi *instance*, *image classification*, *pose estimation*, dan *oriented bounding box detection* sehingga dapat menangani berbagai tantangan tugas dalam *computer vision*.



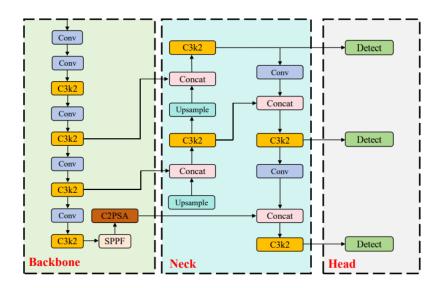
Gambar 16. Spatial Pyramid Pooling Fast (SPPF) (Nikhileswara, 2024).



Gambar 17. C2-Position Sensitive Attention (C2PSA) block (Nikhileswara, 2024).

2.8.1 Lapisan Konvolusi

Model kesebelas mempertahankan struktur yang mirip dengan pendahulunya, seperti yang diilustrasikan pada Gambar 18. Model ini menggunakan lapisan konvolusi awal untuk melakukan *downsampling* pada gambar *input*. Lapisan ini membentuk fondasi proses ekstraksi fitur secara bertahap mengurangi dimensi spasial seiring dengan peningkatan jumlah saluran fitur.



Gambar 18. Arstitektur YOLOv11 (Zijian dkk., 2024).

- 1. *Backbone*, merupakan komponen penting dalam arsitektur YOLO yang bertugas mengekstraksi fitur dari gambar *input* pada berbagai skala. Proses ini melibatkan penumpukan lapisan konvolusi dan blok khusus untuk menghasilkan *feature map* pada berbagai revolusi.
- 2. *Neck*, berfungsi untuk menggabungkan fitur pada berbagai skala dan mentransmisikannya ke *head* untuk diprediksi. Proses ini biasanya melibatkan *upsampling* dan penggabungan *feature map* dari berbagai level, memungkinkan model menangkap informasi multi-skala secara efektif.
- 3. Head, yang juga dikenal sebagai Dense Prediction, bertanggung jawab untuk menghasilkan prediksi akhir dalam hal deteksi dan klasifikasi objek. Komponen ini

memproses *feature map* yang diteruskan dari *neck*, menghasilkan *bounding boxes* dan label kelas untuk objek dalam gambar.

Peningkatan signifikan pada model kesebelas adalah pengenalan blok C3k2, yang menggantikan blok C2f yang digunakan pada versi sebelumnya (Ghosh, 2024). Blok C3k2 merupakan implementasi *Bottleneck Cross Stage Partial* (CSP) yang lebih efisien secara komputasi. Blok ini menggunakan dua konvolusi yang lebih kecil alihalih satu konvolusi besar seperti pada model kedelapan (Fransesco & Solawetz, 2023). Istilah "k2" dalam C3k2 menunjukkan ukuran *kernel* yang lebih kecil, yang berkontribusi pada pemrosesan yang lebih cepat sambil tetap mempertahankan kinerja.

a. SPPF dan C2PSA

Model kesebelas atau YOLOv11 tetap mempertahankan blok SPPF dari versi sebelumnya. Selain itu, model ini memperkenalkan blok baru bernama *Cross Stage Partial* dengan *Spatial Attention* (C2PSA) setelahnya (Ghosh, 2024). Blok C2PSA ini merupakan tambahan penting yang meningkatkan perhatian spasial pada *feature map*. Mekanisme perhatian spasial ini memungkinkan model untuk lebih efektif fokus pada area penting dalam gambar. Melalui penggabungan fitur secara spasial, blok C2PSA memungkinkan YOLOv11 untuk berkonsentrasi pada area yang menjadi perhatian utama, yang berpotensi meningkatkan akurasi deteksi objek dengan ukuran dan posisi yang bervariasi

b. C3K2

Model kesebelas memperkenalkan perubahan signifikan melalui penggantian blok C2f di bagian *neck* dengan blok C3k2. Blok C3k2 dirancang untuk memberikan kecepatan dan efisiensi yang lebih tinggi, sehingga meningkatkan kinerja keseluruhan dalam proses agregasi fitur. Setelah proses *upsampling* dan penggabungan, bagian *neck* pada YOLOv11 mengintegrasikan blok yang telah ditingkatkan, menghasilkan kecepatan pemrosesan yang lebih baik (Ghosh, 2024).

Bagian *head* pada YOLOv11 menggunakan beberapa blok C3k2 untuk memproses dan menyempurnakan *feature map* secara efisien. Blok C3k2 ditempatkan di beberapa jalur dalam *head*, yang berfungsi untuk memproses fitur—multi-skala pada berbagai kedalaman. Blok C3k2 memiliki fleksibilitas yang bergantung pada nilai parameter c3k:

- Jika c3k = False, modul C3k2 berperilaku mirip dengan blok C2f, menggunakan struktur *bottleneck* standar.
- Jika c3k = True, struktur *bottleneck* digantikan oleh modul C3, yang memungkinkan ekstraksi fitur lebih dalam dan kompleks.

Karakteristik utama blok C3k2 adalah pemrosesan yang lebih cepat. Penggunaan dua konvolusi yang lebih kecil mengurangi *overhead* komputasi dibandingkan dengan konvolusi tunggal yang besar, sehingga menghasilkan ekstraksi fitur yang lebih cepat. Selain itu, blok C3k2 merupakan versi yang lebih ringkas dari CSP *bottleneck*, yang membuat arsitektur ini lebih efisien dalam hal jumlah parameter yang dapat dilatih.

c. CBS

Head pada YOLOv11 mencakup beberapa lapisan Convolution-BatchNorm-SiLU (CBS) seteleh blok C3k2. Lapisan ini berfungsi untuk lebih lanjut menyempurnakan feature map melalui beberapa mekanisme. Proses ini mencakup ekstraksi fitur yang relevan untuk deteksi objek yang akurat, stabilisasi dan normalisasi aliran data melalui bath normalization, serta penerapan fungsi aktivasi Sigmoid Linear Unit (SiLU) untuk non-linearitas. Fungsi aktivasi ini meningkatkan kinerja model secara keseluruhan.

Blok CBS menjadi komponen mendasar dalam proses ekstraksi fitur dan deteksi. *Feature map* yang telah disempurnakan oleh blok ini diteruskan ke lapisan berikutnya untuk prediksi *bounding box* dan klasifikasi. Pendekatan ini memastikan bahwa model dapat menangkap informasi penting secara lebih efisien, sehingga meningkatkan akurasi deteksi objek.

d. Lapisan Konvolusi Akhir dan Lapisan Detect

Setiap cabang deteksi dalam YOLOv11 diakhiri dengan satu *set* lapisan Conv2D yang bertugas mengubah fitur menjadi *output* yang diperlukan untuk deteksi objek. *Output* ini mencakup beberapa elemen penting, yaitu:

- Bounding box coordinates untuk melokalisasi objek dalam gambar.
- Objectness scores yang menunjukkan keberadaan objek dalam area tertentu.
- Class scores untuk menentukan jenis objek yang terdeteksi.

Penggunaan Conv2D dalam konteks ini sangat penting karena memungkinkan model untuk memanfaatkan informasi spasial yang telah diekstraksi, sehingga meningkatkan kemampuan deteksi objek dalam berbagai kondisi dan variasi gambar.

2.9 Evaluasi Model

Evaluasi kinerja model dilakukan mengggunakan beberapa metrik evaluasi seperti *Confusion matrix, Intersection over Union* (IoU), *Precision, Recall*, dan *mean Average Precision* (mAP). Metrik -metrik ini membantu menganalisis kemampuan model mengenali serta mendeteksi objek secara akurat.

a) Intersection over Union:

Intersection over Union (IoU) merupakan konsep penting pada deteksi objek yang mengevaluasi akurasi predicted bounding box dibandingkan dengan ground-truth bounding box. Ketika model deteksi objek memprediksi lokasi sebuah objek pada gambar, model menghasilkan predicted bounding box yang mewakili lokasi objek tersebut. Sementara itu, ground truth bounding box menunjukkan lokasi sebenarnya objek pada gambar. Metrik IoU menghitung tingkat tumpang tindih antara predicted bounding box dan ground truth bounding box, Gambar 19 menunjukkan ilustrasi perhitungan IoU. Perhitungan dilakukan dengan membagi luas perpotongan antara predicted bounding box dan ground truth bounding box dengan luas gabungan bounding box tersebut. Rumus perhitungan dapat dilihat pada Persamaan (6):

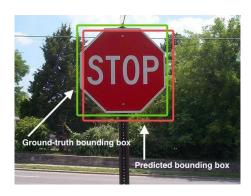
$$IoU = \frac{TP}{TP + FP + FN} \tag{6}$$

Dengan:

TP: True Positives Diprediksi sebagai positif dan benar.

FP: False Positives Diprediksi sebagai positif tetapi salah.

False Negative (FN): Ground truth tidak terprediksi.



Gambar 19. *Predicted bounding box* (merah), *ground truth* (hijau) (Rosebrock, 2016).

b) Confusion Matrix

Kelas tertentu memerlukan empat komponen berikut pada *confusion matrix*:

- 1. *True Positive* (TP): Deteksi yang benar. Deteksi memiliki IoU ≥ ambang batas (*threshold*).
- 2. False Positive (FP): Deteksi yang salah. Deteksi memiliki IoU < ambang batas (threshold).
- 3. False Negative (FN): Ground truth yang tidak terdeteksi.
- 4. *True Negative* (TN): Tidak berlaku. Terdapat banyak kemungkinan *bounding box* seharusnya tidak terdeteksi dalam sebuah gambar.

Apabila terdapat banyak *bounding box* saling tumpang tindih, proses *threshold* dan *Non-Maximum Suppression* (NMS) diterapkan. Pada proses ini, hanya *bounding box* dengan nilai *confidence* tertinggi yang akan dipertahankan. *Bounding box* lainnya dengan nilai IoU > 0,5 dianggap *overlap* dan akan di-*suppress*. Nilai IoU

sebesar 0,5 merupakan ambang batas yang umum digunakan untuk menentukan *overlap*.

c) Precision

Precision merupakan kemampuan model dalam mengidentifikasi objek relevan. Metrik ini menunjukkan presentase prediksi positif yang benar dan dirumuskan pada Persamaan (7).

$$Precision = \frac{TP}{TP + FP} \tag{7}$$

Dengan:

TP: True Positives (Diprediksi sebagai positif dan benar).

FP: False Positives (Diprediksi sebagai positif tetapi salah).

d) Recall

Recall merupakan kemampuan model dalam menemukan kasus relevan (all ground truth bounding boxes). Metrik ini menunjukkan presentase true positive yang terdeteksi di antara semua ground truth yang relevan dan dirumuskan pada Persamaan (8).

$$Recall = \frac{TP}{TP + FN} = \frac{TP}{All\ ground\ truths}$$
 (8)

Dengan:

TP: True Positif (Diprediksi sebagai potisif dan benar).

FN: False Negative (Ground truth tidak terprediksi).

e) mean Average Precision (mAP)

mean Average Precision (mAP) mengevaluasi kinerja keseluruhan model pada semua kategori melalui perhitungan rata-rata Average Precision (AP) setiap kelas (Tan, 2020). Average Precision dirata-ratakan pada semua kategori yang secara tradisional disebut sebagai mAP. Skor mAP dihitung berdasarkan rata-rata nilai AP yang diperoleh, seperti yang ditunjukkan pada Persamaan (9).

$$mAP = \frac{1}{N} \sum_{i=1}^{N} AP_i \tag{9}$$

Keterangan:

 $mAP = mean \ Average \ Precision$, metrik keseluruhan untuk mengevaluasi model pada banyak kelas.

 $\frac{1}{N}$ = Nilai rata-rata dihitung dengan membagi jumlah *Average Precision (AP)* dengan jumlah kelas (N).

2.10. Antarmuka Website Berbasis Streamlit.

Framework Streamlit menyediakan pustaka berbasis python yang memungkinkan pengembang untuk membangun antarmuka pengguna secara interaktif dan cepat (Ranjan & Sahu, 2021). Penggunaan Streamlit mempermudah integrasi antara model deteksi AV dan tampilan antarmuka. Sistem ini mendukung pengembangan aplikasi berbasis web tanpa memerlukan pengetahuan mendalam tentang pengembangan web konvensional (Hernandez & Suarez, 2022).

Antarmuka website menampilkan hasil deteksi model secara visual kepada pengguna. Komponen utama meliputi *form* unggah gambar, hasil identifikasi AV, kotak pembatas, serta rekomendasi perawatan kulit. Semua komponen dirancang agar tersaji secara terstruktur dan mudah diakses. Desain antarmuka mendukung perangkat desktop dan mobile melalui fitur responsif bawaan *framework*. Komponen pada perangkat desktop tersaji secara horizontal, sedangkan pada perangkat mobile tersaji secara vertikal untuk memastikan kenyamanan pengguna.

Penggunaan Streamlit menunjukkan bahwa implementasi model deteksi tidak hanya berhenti pada proses pelatihan, tetapi juga berlanjut ke tahap penyampaian hasil yang ramah bagi pengguna akhir. Sistem ini memberikan kemudahan akses dan pengalaman pengguna yang optimal, sehingga mendukung aplikasi nyata di bidang kesehatan kulit (Santos & Silva, 2021).

III. METODOLOGI PENELITIAN

3.1 Tempat dan Waktu Penelitian

Berikut merupakan tempat dan waktu yang dilakukan dalam mengerjakan penelitian:

a. Tempat Penelitian

Penelitian ini dilaksanakan pada semester genap tahun akademik 2024/2025, bertempat di Laboratorium Fakultas Matematika dan Ilmu Pengetahuan Alam (FMIPA) yang berlokasi di Jl. Prof. Dr. Ir. Sumantri Brojonegoro No. 1, Kota Bandar Lampung, Lampung 35141.

b. Waktu Penelitian

Penelitian dilakukan pada semester genap, tepatnya pada bulan Agustus 2024. Proses pengerjaan terbagi menjadi tiga tahap. Tahap pertama meliputi pengumpulan dan pemahaman studi literatur serta penentuan tema penelitian, yang memerlukan waktu kurang lebih 25 minggu. Tahap kedua mencakup pelabelan dan *preprocessing* data, serta pengerjaan program, yang membutuhkan waktu sekitar 7 minggu. Tahap terakhir merupakan tahap penyusunan hasil pengerjaan dan analisis program dalam draf laporan serta penyampaian hasil penelitian melalui seminar, yang memakan waktu kurang lebih 7 minggu.

3.2 Data dan Alat

a. Data

Penelitian ini menggunakan data sekunder berupa gambar yang diperoleh melalui platform Roboflow, https://app.roboflow.com/nabila-syaidaramdanire1zj/acne_detection_2yb0xp/browse?queryText=&pageSize=50&s tartingIndex=0&browseQuery=true. Dataset terdiri dari 919 gambar yang diklasifikan ke dalam lima kelas, yaitu pustule, whitehead, blackhead, nodules, dan papules.

b. Alat

Peralatan ini didukung oleh perangkat keras dan perangkat lunak sebagai berikut:

a) Perangkat keras (*Hardware*)

Perangkat yang digunakan dalam penelitian ini adalah laptop dengan merk ASUS A416JAO-VIPS324 dengan tipe 64-bit *operating system, x64-based processor*. Spesifikasi *hardware* perangkat tersebut adalah sebagai berikut:

Processor : Intel(R) Core(TM) i3-1005G1 CPU @ 1.20GHz

Memori : SSD 256 GB

RAM : 8 GB

b) Perangkat Lunak (Software)

Perangkat lunak yang digunakan dalam penelitian ini meliputi:

- 1) Windows 11 Home Single Language
 - Sistem operasi terbaru yang dikembangkan oleh Microsoft, mendukung berbagai aplikasi dan perangkat lunak yang digunakan dalam penelitian.
- 2) Visual Studio Code 1.95.3

Editor teks ringan dan handal yang dibuat oleh Microsoft untuk sistem operasi *multiplatform*, artinya tersedia juga untuk versi Linux, Mac, dan Windows. Teks editor ini secara langsung mendukung bahasa pemrograman JavaScript, TypeScript, dan Node.Js, serta bahasa pemrograman lainnya yang dapat dipasang via *marketplace Visual Studio Code* seperti: C++, C#, Python, Go, Java, PHP, dst (Salamah & St, S. 2021).

3) Roboflow

Roboflow merupakan sebuah platform yang tersedia di web dan memiliki banyak fungsi yang berhubungan dengan dataset. Roboflow dapat membagikan dataset sekaligus memproses dataset tersebut (Hayati dkk., 2023).

4) Google Colaboratory 1.0.0

Google *Colab* (singkatan dari *Google Colaboratory*) adalah *platform* berbasis *cloud computing* yang disediakan oleh Google. Memungkinkan pengguna untuk mengeksekusi kode *Python* dalam lingkungan berbasis *cloud* tanpa perlu meng-*install* atau mengatur lingkungan lokal mereka sendiri. Google *Colab* sering digunakan oleh para ilmuwan data, peneliti, dan pengembang untuk melakukan berbagai jenis pekerjaan, termasuk pemrosesan data, pengembang model kecerdasan buatan, analisis data, dan pelatihan model mesin (Andarsyah & Yanuar. 2024).

5) Library *Ultralytics* 8.0.226

Ultralytics merupakan pengembang resmi dari model YOLO versi YOLOv5 hingga YOLOv11. Perusahaan ini menyediakan pustaka berbasis *python* yang mendukung proses pelatihan, validasi, prediksi, serta *deployment* model deteksi objek secara efisien. *Ultralytics* menyediakan Antarmuka Pemrograman Aplikasi (API) yang sederhana dan terintegrasi dengan baik dalam ekosistem Python, seperti PyTorch, NumPy, dan OpenCV, sehingga mempermudah pengguna dalam mengembangkan dan menerapkan model deteksi objek secara praktis (Ultralytics, 2023).

6) Counting (Perhitungan Objek Terdeteksi)

Proses *counting* dalam YOLO dilakukan dengan menghitung jumlah objek yang berhasil dideteksi berdasarkan *bounding box* yang dihasilkan oleh model. Teknik ini banyak digunakan dalam berbagai aplikasi seperti perhitungan jumlah kendaraaan, orang, atau hewan, pada suatu area pantauan (Redmon dkk., 2016).

7) Library TensorFlow 2.17.1

Tensorflow adalah sebuah *library open-source* yang dikembangkan oleh Google untuk membangun dan menjalankan model *machine learning* dan *deep learning*. Tensorflow menggunakan grafik alur data (*data flow graph*) untuk memproses data dan mendukung eksekusi di CPU maupun GPU, sehingga efisien untuk pelatihan model berskala besar (Abadi dkk., 2016).

8) Library OpenCV-Python 4.10.0.84

Pengolahan gambar digital memungkinkan komputer untuk memahami, menganalisis, dan mengambil keputusan berdasarkan data visual. Salah satu alat yang banyak digunakan untuk tujuan ini adalah *Open Source Computer Vision Library* (OpenCV), yang merupakan pustaka sumber terbuka untuk visi komputer dan pengolahan citra (Effendi, 2018).

9) *Library YAML 6.0.2*

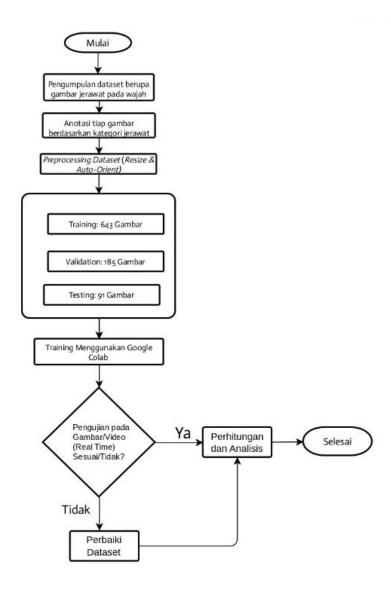
YAML adalah bahasa serialisasi data yang dapat dibaca manusia dan merupakan singkatan dari "YAML Ain't Markup Language" yang sering juga disebut sebagai "Yet Another Markup Language". Bahasa ini ditulis dengan ekstensi file .yml atau .yaml (Bassey, 2023).

10) NVIDIA GPU & CUDA Toolkit

Compute Unified Architecture (CUDA) adalah platform pengembangan dari NVIDIA untuk komputasi paralel menggunakan GPU. Toolkit ini mencakup pustaka akselerasi GPU, kompiler, alat pengembangan, dan runtime CUDA untuk membangun aplikasi yang dipercepat oleh GPU (Burhan, 2024).

3.3 Alur Kerja Penelitian

Penelitian ini merancang sistem *real-time* untuk identifikasi AV dengan menggunakan YOLOv11. Data yang digunakan dalam penelitian ini berupa gambar wajah manusia yang diperoleh dari *web Roboflow*. Proses penelitian ini melibatkan beberapa tahapan yang diilustrasikan pada Gambar 20.



Gambar 20. Alur Pengerjaan Penelitian.

Alur pengerjaan penelitian ini menjelaskan secara sistematis tahapan-tahapan yang dilakukan dalam mengembangkan model deteksi AV menggunakan model YOLOv11. Setiap langkah disusun secara berurutan untuk memastikan proses pengumpulan data, pengolahan data, pengembangan model, hingga evaluasi kinerja dapat berjalan dengan optimal. Penjelasan alur pengerjaan adalah sebagai berikut:

- 1. Melakukan studi literatur yang menyeluruh tentang topik yang akan diteliti, khususnya terkait dengan metode YOLO dan deteksi objek *real-time*.
- 2. Mempersiapkan *dataset* yang berisi gambar wajah yang diambil melalui *Roboflow*. *Dataset* dalam penelitian ini bersifat *public*.
- 3. Melakukan *preprocessing* secara manual dengan fitur *Bounding Box Tool* pada *Roboflow*. Proses ini meliputi *Auto-Orient* dan *Resize* gambar menjadi 640 x 640 piksel. *Dataset* kemudian dibagi menjadi tiga bagian: *training*, *validation*, dan *testing*.
- 4. Mengekstrak file *dataset* atau memanggil *dataset* dalam *Roboflow* dengan menggunakan API KEY.
- 5. Setelah data siap, langkah selanjutnya adalah mengembangkan model YOLOv11. Proses pengembangan model meliputi:
 - a. Membuat dan mengonfigurasi model YOLOv11 untuk mendeteksi dan mengklasifikasikan AV ke dalam beberapa kategori (*whitehead, blackhead, papule, pustule*, dan *nodule*).
 - b. Melakukan pelatihan model dengan menggunakan *hyperparameter* yang tepat seperti jumlah *epoch, learning rate,* dan *batch-size*.
 - c. Melakukan validasi model dengan menggunakan metrik evaluasi seperti IoU, *precision*, *recall*, dan mAP.
- 6. Selanjutnya, menganalisis hasil evaluasi untuk mengetahui kinerja model YOLOv11 dalam mendeteksi AV secara *real-time*.

V. KESIMPULAN

5.1 Kesimpulan

Berdasarkan hasil penelitian dan pengujian yang telah dilakukan terhadap model deteksi AV, menggunakan YOLOv11 dengan lima kelas AV (*blackhead, whitehead, papule, pustule,* dan *nodule*), dapat disimpulkan beberapa hal berikut:

- 1. Model YOLOv11 mampu mendeteksi dan mengklasifikasikan jenis-jenis AV pada wajah manusia dengan kinerja yang cukup baik. Hal ini terlihat dari nilai rata-rata *mean Average Precision* (mAP) pada *threshold* 0,5 sebesar 0,469.
- 2. Selama pelatihan model selama 100 *epoch* nilai *loss* pada data pelatihan dan validasi menunjukkan penurunan yang konsisten. Hal ini menandakan bahwa proses pelatihan berjalan dengan baik.
- 3. Deteksi terbaik diperoleh pada kelas *pustule* dengan mAP@0,5 sebesar 0,688, sementara deteksi terendah terdapat pada kelas *whitehead* dengan mAP@0,5 sebesar 0,212. Perbedaan ini menunjukkan bahwa beberapa jenis AV, seperti *pustule* lebih mudah dikenali oleh model dibandingkan jenis lain yang memiliki karakteristik visual serupa, seperti *whitehead*.
- 4. Pendekatan YOLOv11 memberikan berpotensi besar dalam membantu deteksi awal jenis AV yang dialami seseorang. Sistem ini dapat digunakan sebagai bagian dari dukungan diagnosis non-medis atau sebagai alat sistem edukasi mandiri untuk meningkatkan pemahaman mengenai kesehatan kulilt wajah.

5.2 Saran

Berdasarkan penelitian ini, beberapa saran dapat diberikan untuk pengembangan lebih lanjut:

- 1. Pemilihan data yang tepat sangat disarankan, termasuk dalam proses anotasi. Hindari penggunaan *bounding box* yang terlalu kecil, karena ukuran objek yang sangat kecil sering kali menyulitkan model dalam mengenali fitur penting secara konsisten. Fokus pada area yang cukup jelas dan proporsional secara visual dapat membantu model memahami konteks AV dengan lebih baik, sehingga meningkatkan akurasi prediksi.
- 2. Peningkatan kinerja model dapat dilakukan dengan mengeksplorasi teknik augmentasi data yang lebih beragam, seperti *rotation, scaling*, atau *contrast adjustment*, sehingga variasi data latih menjadi lebih kaya. Selain itu, pengembangan arsitektur model yang lebih kompleks maupun penerapan teknik *transfer learning* juga dapat dipertimbangkan guna memperoleh hasil deteksi yang lebih optimal.
- 3. Integrasi model ke dalam antarmuka berbasis web juga menjadi langkah penting dalam pengembangan ke depan. Salah satu saran adalah menambahkan fitur penggunaan kamera secara langsung di website agar pengguna dapat melakukan deteksi kondisi kulit secara *real-time*.

Penelitian ini diharapkan dapat memberikan kontribusi dalam pengembangan sistem deteksi AV berbasis visi komputer yang akurat dan efisien. Metode YOLOv11 memiliki potensi besar untuk menjadi dasar pengembangan teknologi pendeteksi kondisi kulit wajah. Teknologi ini dapat dimanfaatkan dalam bidang non-medis, khususnya sebagai alat bantu edukasi dan pemantauan mandiri oleh pengguna.

DAFTAR PUSTAKA

- Abadi, M., Barham, P., Chen, J., Chen, Z., Davis, A., Dean, J., & Kudlur, M. 2016. TensorFlow: A system for large-scale machine learning. In *Proceedings of the 12th USENIX Symposium on Operating Systems Design and Implementation (OSDI 16)* (pp. 265–283). USENIX Association.
- Aggarwal, A. 2020. YOLO Explained. *Analytics Vidhya*. https://medium.com/analytics-vidhya/yolo-explained-5b6f4564f31. Diakses pada 10 Desember 2024.
- Ahmad, H. 2017. Mengenal Artificial Intelligence, Machine Learning, Neural Network, dan Deep Learning. 1(1):1-5.
- Ali Farhadi & Joseph Redmon. 2018. Yolov3: An incremental improvement. In Computer vision and pattern recognition. **1804**: 1–6. Springer Berlin/Heidelberg. https://doi.org/10.48550/arXiv.1804.02767.
- Andarsyah, R., & Yanuar, A. 2024. Sentimen Analisis Aplikasi Posaja pada Google Playstore Untuk Peningkatan Pospay SuperApp Menggunakan Support Vector Machine. *Jurnal Teknik Informatika*. **16**(2):1-7.
- Bassey, M. 2023. How to Work with YAML in Python. Earthly.https://earthly.dev/blog/yaml-in-python/. Diakses pada tanggal 18 Oktober 2023.
- Brownlee, J. 2017. Long Short-Term Memory Networks with Python: Develop Sequence Prediction Models with Deep Learning. Machine Learning Mastery. Melbourne.
- Effendi, M. R. 2018. Sistem Deteksi Wajah Jenis Kucing Dengan Image Classification Menggunakan Opency. *Jurnal Teknologi Informatika Dan Komputer*. **4**(1):27–35. https://doi.org/10.37012/jtik.v4i1.283.

- Fitri, M, & Abdul, F. 2017. Sistem Pengenalan Bunga Berbasis Pengolahan Citra Dan Pengklasifikasi Jarak. *Jurnal Ilmu Teknik Elektro Komputer dan Informatika* (*JITEKI*). **3**(2): 124-131. https://doi.org/10.26555/jiteki.v3i2.7470.
- Fransesco, & Solawetz, J. 2024. What is YOLOv8? A Complete Guide.23 Oktober 2024. https://blog.roboflow.com/what-is-yolov8/. Diakses pada 24 November 2024.
- Ghosh, A. 2024. Ultralytics YOLO11: Faster Than You Can Imagine!. *LearnOpenCV*. https://learnopencv.com/yolo11/. Diakses pada 24 November 2024.
- Hasanah, L, & Hasan, M. 2022. Deteksi Lesi Acne Vulgaris pada Citra Jerawat Wajah Menggunakan Metode K-Means Clustering. *Indonesian Journal on Software Engineering* (IJSE). **8**(1): 46-51. DOI:10.31294/ijse.v8i1.12966.
- Hayati, J.N., Singasatria, D., & Muttaqin, R.M. 2023. Object Tracking Menggunakan Algoritma You Only Look Once (YOLO)v8 Untuk Menghitung Kendaraan. *Jurnal Ilmiah Komputer dan Informatika*. **12**(2): 91-99. https://doi.org/10.34010/komputa.v12i2.10654.
- Hernandez, J. A., & Suárez, J. 2022. Developing Interactive Applications for Data Science Using Streamlit and Python. *International Journal of Computer Applications*. **182**(12):1-6.
- Huey, Y., Yin, S., & Han, Y., Hong, Y., & Fong, Q. 2024. Facial Skin Analysis in Malaysians using YOLOv5: A Deep Learning Perspective. *Journal of Informatics and Web Engineering*. **3**(2):1-18. https://doi.org/10.33093/jiwe.2023.3.2.1.
- Jusuf, N. K., Putra, I. B., & Sutrisno, A. R. 2021. Correlation between stress scale and serum substance P level in acne vulgaris. *International Journal of General Medicine*, **14**: 681–686. https://doi.org/10.2147/IJGM.S294509.
- Kristiawan & A., Widjaja. 2021. Perbandingan Algoritma Machine Learning dalam Menilai Sebuah Lokasi Toko Ritel. *JuTISI*. **7**(1):35-46.
- Kristin, K., Ratiandi, R., Kusumawardhani, E., Marpaung, J, & Irmansyah, F. 2022. Klasifikasi Penyebab Jerawat Berdasarkan Area Pada Wajah Menggunakan Metode Gray Level Co-Occurrence Matrix (GLCM). *Journal of Electrical Engineering, Energy, And Information Technology.* **10**(2): 1-15. https://doi.org/10.26418/j3eit.v10i2.57088.
- Maulida, Y., & Topik, M. 2024. Penanganan Acne Vulgaris Terkini. *Jurnal Ilmiah Ilmu Kesehatan dan Kedokteran.* **3**(2): 98-111 https://doi.org/10.55606/termometer.v2i3.4072.

- Moin, M. 2023. Object Detection: A journey from R-CNN to Mask R-CNN and YOLO. *Medium Augmented AI*. https://medium.com/augmented-startups/object-detection-a-journey-from-r-cnn-to-mask-r-cnn-and-yolo-698ba097d490. Diakses pada tanggal 8 Desember 2024.
- Nadzir, Z., Sofyan, H, & Mangaras, Y. 2019. Aplikasi Pengolahan Citra Digital Untuk Identifikasi Umur Pohon. *Telematika*. **16**(2): 97-104. DOI:10.31315/telematika.v16i2.3183.
- Nikhileswara, S. 2024. YOLOv11 Architecture Explained: Next-Level Object Detection with Enhanced Speed and Accuracy. https://medium.com/@nikhil-rao-20/yolov11-explained-next-level-object-detection-with-enhanced-speed-and-accuracy-2dbe2d376f71. Diakses pada 7 Desember 2024.
- Padilla, R., Netto, L. S., & Silva, da. B. 2020. A Survey on Performance Metrics for Object-Detection Algorithms, pp. 237-242. *Conference: 2020 International Conference on Systems, Signals and Image Processing* (IWSSIP). DOI:10.1109/IWSSIP48289.2020.
- Poola, I. 2017. The Best of The Machine Learning Algorithms Used in Artificial Intelligence. *International Journal of Advanced Research in Computer and Communication Engineering.* **6**(10):187-194. DOI:10.17148/IJARCCE.2017.61032.
- Ranjan, P., & Sahu, P. K. 2021. Interactive Data Visualization and Model Deployment Using Streamlit. *International Journal of Scientific & Technology Research*, **10**(4): 176-180.
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You Only Look Once: Unified, Real-Time Object Detection. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 779–788. https://doi.org/10.1109/CVPR.2016.91.
- Rosebrock, A. 2016. Intersection over Union (IoU) for object detection. Pyimagesearch. https://pyimagesearch-com.translate.goog/2016/11/07/intersection-over-union-iou-for-object-detection/? x_tr_sl=en&_x_tr_tl=id&_x_tr_hl=id&_x_tr_pto=imgs. Diakses pada 21 Juni 2025.
- Rosiani, U. D., Batubulan, K. S., & Malia Elisiana. (2021). Identifikasi "Acne Vulgaris" Berdasarkan Fitur Warna Dan Tekstur Menggunakan Klasifikasi JST Backpropagation. *Jurnal Informatika Polinema*, **7**(2): 7–12. https://doi.org/10.33795/jip.v7i2.463.

- Santos, C. L., & Silva, R. A. 2021. Building Data Science Applications with Streamlit: A Case Study. *Journal of Data Science and Analytics*. **5**(1): 45-58.
- Salamah, U. G., & St, S. 2021. Tutorial Visual Studio Code. Media Sains Indonesia.
- Sibero, H., Sirajudin, A, & Anggraini, D. 2020. Prevalensi dan Gambaran Epidemiologi Akne Vulgaris di Provinsi Lampung. *JK Unila*. **3**(3): 1-5. https://doi.org/10.23960/jkunila.v3i2.pp308-312.
- Sutaria, A., Masood, S., & Saleh, H. 2023. Acne Vulgaris. National Library of Medicine, Amerika Serikat.
- Tan, Jie. 2024. Mean Average Precision (mAP) Explained. *Builtin*. https://builtin.com/articles/mean-average-precision. Diakses pada 20 Mei 2025.
- Ultralytics. 2023. YOLOv5 to YOLOv11 Models for Object Detection. GitHub repository. https://github.com/ultralytics. Diakses pada tanggal 15 Mei 2025.
- Wang, A., Chen, H., Liu, L., Chen, K., Lin, Z., Han, J., & Ding, G. 2024. YOLOv10: Real-Time End-to-End Object Detection. arXiv. https://doi.org/10.48550/arXiv.2402.13616.
- Wang, C. Y., Yeh, I. H., & Mark Liao, H. Y. 2024. Yolov9: Learning what you want to learn using programmable gradient information. In *European Conference on Computer Vision* (pp. 1-21). https://doi.org/10.48550/arXiv.2402.13616, Network Application Branch, China Computer Users Association, 2018.
- Wang, J., Song, L., Li, Z., Sun, H., Sun, J., & Zheng, N. 2021. End-to-End Object Detection with Fully Convolutional Network. *IEEE/CVF Conference on Computer Vision and Pattern Recognition* (CVPR 2021). 15844–15853. https://doi.org/10.1109/CVPR46437.2021.01559.
- Wang, K., Fang, T., Su, L., He, Z., Chen, R., & Fei, X. 2024. Comprehensive Performance Evaluation of YOLOv11, YOLOv10, YOLOv9, YOLOv8, and YOLOv5 on Object Detection of Power Equipment. *arXiv* preprint *arXiv*:2411.18871. https://doi.org/10.48550/arXiv.2411.18871.
- Wetarini, K., & Febyan. 2020. Acne Vulgaris in Adults: A Brief Review on Diagnosis and Management. 7(5): 246–253.
- Wiraputranto, C., Sitohang, S., Tathayhita, A., & Ilyas, M. 2023. Effectiveness of Standard Therapy for Acne Vulgaris Based on Clinical Practice Guidelines in Indonesia. *National Library of Medicine*. **17**: 2165-2175. doi: 10.2147/CCID.S469143. eCollection 2024.

- Yunita, F., Yulifitri, A, & Maharani, P. 2022. Penerapan Algoritma GLCM dan KNN dalam Pengenalan Jenis Jerawat. *Jurnal Komtika*. **6**(2): 74-82. https://doi.org/10.31603/komtika.v6i2.8078.
- Zhang L., Wang, J., Ma Yulin., Gao, R., & Wu Dazhong. 2018. Deep learning for smart manufacturing: Methods and applications. *Journal of Manufacturing Systems* **48**: 144-156. https://doi.org/10.1016/j.jmsy.2018.01.003.
- Zhang, Yi., Ji, L., Sun, W., Feng, G., Deneen, V. M., & Cui. G. 2023. A hybrid network integrating convolution and transformer for thymoma segmentation. *Intelligence Medicine*. **3**(3): 164-172. https://doi.org/10.1016/j.imed.2022.06.003.
- Zhao, Y., Guo, M., Chen, X., Sun, J., & Qiu, J. (2024). Attention-Based CNN Fusion Model for Emotion Recognition during Walking Using Discrete Wavelet Transform on EEG and Inertial Signals. Big Data Mining and Analytics, 7(1): 188–204. *Scopus*. https://doi.org/10.26599/BDMA.2023.9020018.