



# Analisis Performa Metode KNN, Yolov8, Dan Yolov11 Pada Klasifikasi Konjungtiva Mata Untuk Deteksi Anemia

Yoel Pieter Sumihar<sup>\*</sup>, Febe Maedjaja, Valentino Henry Sas

Fakultas Sains dan Komputer, Program Studi Informatika, Universitas Kristen Immanuel, Yogyakarta, Indonesia

Email: <sup>1,\*</sup>pieter.haro@ukrimuniversity.ac.id, <sup>2</sup>febe@ukrimuniversity.ac.id, <sup>3</sup>valentino.s2042@student.ukrimuniversity.ac.id

Email Penulis Korespondensi: pieter.haro@ukrimuniversity.ac.id

**Abstrak**—Deteksi anemia secara cepat dan non-invasif sangat penting terutama di wilayah dengan keterbatasan fasilitas laboratorium. Konjungtiva mata merupakan indikator visual yang potensial untuk mendeteksi anemia melalui analisis warna dan tekstur. Penelitian ini bertujuan menganalisis dan membandingkan performa tiga metode klasifikasi citra—K-Nearest Neighbors (KNN), YOLOv8, dan YOLOv11—dalam mengidentifikasi kondisi anemia berdasarkan citra konjungtiva. Dataset yang digunakan adalah CP-AnemiC, terdiri dari 710 citra awal yang kemudian diperluas menjadi 3.550 citra melalui augmentasi. KNN menggunakan fitur warna dari ruang CIE LAB, sedangkan YOLOv8 dan YOLOv11 memanfaatkan ekstraksi fitur otomatis berbasis CNN. Evaluasi dilakukan menggunakan metrik akurasi, presisi, recall, dan F1-score. Hasil penelitian menunjukkan bahwa YOLOv8 menghasilkan performa tertinggi dengan akurasi 93,4% dan F1-score 94,5%, diikuti YOLOv11 dengan akurasi 93,0% dan F1-score 94,2%. Sementara itu, KNN hanya mencapai akurasi 85,7%. YOLOv8 menunjukkan deteksi yang cepat dan akurat, sedangkan YOLOv11 memberikan stabilitas pelatihan yang lebih baik. Temuan ini menunjukkan bahwa pendekatan berbasis deep learning, khususnya YOLOv8 dan YOLOv11, memiliki potensi besar untuk digunakan dalam sistem deteksi anemia berbasis citra konjungtiva mata yang efisien, akurat, dan mudah diimplementasikan. Penelitian ini berkontribusi dengan menyajikan analisis komparatif eksplisit antara metode klasik (KNN) dan model deep learning terbaru (YOLOv8 dan YOLOv11) dalam konteks spesifik klasifikasi konjungtiva mata.

**Kata Kunci:** Anemia; Konjungtiva Mata; YOLOv8; YOLOv11; KNN; Klasifikasi Citra

**Abstract**—Rapid and non-invasive anemia detection is crucial, especially in regions with limited laboratory facilities. The conjunctiva of the eye serves as a promising visual indicator for anemia through the analysis of color and texture. This study aims to analyze and compare the performance of three image classification methods K-Nearest Neighbors (KNN), YOLOv8, and YOLOv11 in detecting anemia using conjunctival images. The CP-AnemiC dataset was employed, consisting of 710 original images, later expanded to 3,550 images through augmentation. KNN utilized color features extracted from the CIE LAB color space, while YOLOv8 and YOLOv11 leveraged automatic feature extraction using convolutional neural networks. Evaluation metrics included accuracy, precision, recall, and F1-score. The results indicate that YOLOv8 achieved the best performance with 93.4% accuracy and a 94.5% F1-score, followed by YOLOv11 with 93.0% accuracy and a 94.2% F1-score. In contrast, KNN obtained an accuracy of only 85.7%. YOLOv8 demonstrated fast and accurate detection, while YOLOv11 exhibited more stable training behavior. These findings highlight that deep learning models particularly YOLOv8 and YOLOv11 are highly promising for implementing efficient, accurate, and practical conjunctival image-based anemia detection systems. This research contributes by presenting an explicit comparative analysis between the classical method (KNN) and the latest deep learning models (YOLOv8 and YOLOv11) in the specific context of conjunctival image classification.

**Keywords:** Anemia; Conjunctiva; YOLOv8; YOLOv11; KNN; Image Classification

## 1. PENDAHULUAN

Dalam dekade terakhir, penerapan teknologi kecerdasan buatan (Artificial Intelligence, AI) dalam bidang kesehatan menunjukkan perkembangan yang pesat, khususnya dalam mendukung proses deteksi dini terhadap berbagai kondisi medis. Salah satu penyakit yang menjadi fokus perhatian adalah anemia, yaitu kondisi yang ditandai oleh penurunan jumlah sel darah merah atau kadar hemoglobin dalam darah, yang dapat berdampak serius terhadap kesehatan apabila tidak segera ditangani (Huang et al., 2025). Berbagai algoritma klasifikasi telah dikembangkan untuk diagnosis anemia, termasuk pendekatan multi-class classification yang menunjukkan hasil yang menjanjikan dalam setting klinis (Vohra et al., 2022). Deteksi dini anemia memiliki peran penting dalam pencegahan komplikasi jangka panjang, terutama di wilayah dengan sumber daya medis yang terbatas. Dalam konteks ini, analisis konjungtiva mata menawarkan pendekatan yang inovatif dan non-invasif sebagai indikator potensial untuk mendeteksi anemia (Henry et al., 2024).

Sejumlah penelitian terbaru menunjukkan bahwa konjungtiva mata merupakan indikator visual yang kuat untuk deteksi anemia karena perubahan derajat kemerahan pada jaringan ini berhubungan erat dengan kadar hemoglobin. Appiahene et al. (2023) dan Sehar et al. (2025) mengembangkan metode non-invasif berbasis citra konjungtiva yang diambil menggunakan smartphone, kemudian diproses dengan kombinasi model machine learning dan deep learning sehingga mampu mencapai area under the curve hingga 0,97 untuk klasifikasi anemia. Magdalena et al. (2022) memanfaatkan arsitektur Convolutional Neural Network pada citra palpebral konjungtiva dan menunjukkan bahwa jaringan saraf dalam mampu membedakan kondisi normal dan anemia dengan akurasi sekitar 94%, sehingga mendukung pemanfaatan citra konjungtiva sebagai dasar sistem deteksi otomatis. Studi lain yang dilakukan oleh J. W. Asare et al. (2023) menunjukkan bahwa analisis citra konjungtiva memiliki kinerja yang kompetitif dibandingkan dengan bagian tubuh lain dalam deteksi anemia. Bahkan, Zhao et al. (2024) mengembangkan aplikasi berbasis smartphone yang mampu mengklasifikasikan tingkat keparahan anemia secara real-time menggunakan citra konjungtiva, sehingga memungkinkan deteksi dini di daerah dengan keterbatasan fasilitas kesehatan. Lebih lanjut, penelitian terbaru menunjukkan bahwa teknologi smartphone dapat digunakan untuk screening anemia melalui



pengcitraan konjungtiva dengan bantuan perangkat 3D-printed, memberikan solusi yang cost-effective dan praktis untuk implementasi di lapangan (Arunnagiri et al., 2025).

Perkembangan kecerdasan buatan dalam beberapa tahun terakhir mendorong munculnya berbagai metode deteksi anemia non-invasif berbasis citra yang memanfaatkan area tubuh seperti konjungtiva mata, lip mucosa, telapak tangan, dan ujung jari. Mohamed et al. meninjau secara komprehensif pendekatan-pendekatan ini dan menunjukkan bahwa integrasi teknik deep learning dengan pemrosesan citra memungkinkan sistem skrining anemia yang lebih cepat, murah, dan dapat dioperasikan pada perangkat mobile di lingkungan dengan sumber daya terbatas (Mohamed et al., 2024). Salah satu algoritma klasik yang sering digunakan adalah K-Nearest Neighbors (KNN), yang dikenal karena kesederhanaan dan efektivitasnya dalam melakukan klasifikasi berdasarkan kemiripan fitur. Beberapa studi menunjukkan bahwa metode KNN dapat mencapai akurasi hingga 91,49% dalam klasifikasi citra medis (Huang et al., 2025). Namun, keterbatasan KNN dalam menangani dataset yang besar dan kompleks mendorong peneliti untuk beralih pada model berbasis deep learning yang lebih adaptif dan efisien.

Dalam konteks ini, model You Only Look Once (YOLO) menjadi salah satu pendekatan yang menjanjikan dalam deteksi objek medis (Diwan et al., 2023). YOLO dikenal karena kemampuannya melakukan deteksi secara real-time dengan tingkat akurasi tinggi. Review komprehensif tentang aplikasi YOLO dalam medical imaging menunjukkan bahwa model ini telah terbukti efektif untuk berbagai tugas diagnosis medis, termasuk deteksi kanker laring dan klasifikasi penyakit mata (Nie et al., 2025; Widayani et al., 2024). Versi terbaru seperti YOLOv8 dan YOLOv11 telah menunjukkan peningkatan signifikan dalam kecepatan, stabilitas, dan ketepatan deteksi dibandingkan versi sebelumnya (Li et al., 2025; Rizzieri et al., 2024, 2025). Beberapa penelitian di bidang medis juga membuktikan bahwa model YOLO mampu mendeteksi lesi, kelainan kulit, dan struktur anatomis lain dengan hasil yang sangat baik (Er et al., 2025). Hal ini mengindikasikan potensi besar untuk diterapkan pada analisis konjungtiva mata sebagai indikator anemia.

Meskipun berbagai penelitian telah membahas deteksi anemia berbasis citra konjungtiva, kebanyakan masih berfokus pada pendekatan tradisional atau menggunakan model tunggal, seperti algoritma machine learning konvensional (misalnya KNN, SVM, atau Random Forest) tanpa membandingkannya secara langsung dengan model deep learning terkini. Selain itu, belum banyak studi yang secara eksplisit melakukan analisis komparatif antara metode berbasis pembelajaran klasik dan model deteksi modern seperti YOLOv8 dan YOLOv11 dalam konteks spesifik klasifikasi konjungtiva mata. Kesenjangan penelitian (research gap) ini membuka peluang untuk mengevaluasi sejauh mana model YOLO generasi terbaru mampu memberikan peningkatan performa dan efisiensi dibandingkan metode tradisional dalam mendeteksi anemia secara visual.

Meskipun berbagai penelitian telah membahas deteksi anemia berbasis citra konjungtiva, kebanyakan masih berfokus pada pendekatan tradisional atau menggunakan model tunggal, seperti algoritma machine learning konvensional (misalnya KNN, SVM, atau Random Forest). Selain itu, belum banyak studi yang secara eksplisit melakukan analisis komparatif antara metode berbasis pembelajaran klasik dan model deteksi modern seperti YOLOv8 dan YOLOv11 dalam konteks spesifik klasifikasi konjungtiva mata. Kesenjangan penelitian (research gap) ini membuka peluang untuk mengevaluasi sejauh mana model YOLO generasi terbaru mampu memberikan peningkatan performa dan efisiensi dibandingkan metode tradisional dalam mendeteksi anemia secara visual.

Berdasarkan analisis kesenjangan penelitian yang telah diidentifikasi, penelitian ini diarahkan untuk mengevaluasi dan membandingkan performa tiga metode utama dalam klasifikasi citra konjungtiva mata untuk deteksi anemia, yaitu K-Nearest Neighbors (KNN), YOLOv8, dan YOLOv11. Kajian ini tidak hanya menilai kemampuan masing-masing metode dalam menghasilkan prediksi yang akurat, tetapi juga menyoroti aspek efektivitas dan efisiensinya ketika diterapkan pada data citra medis. Melalui perbandingan yang komprehensif, penelitian ini bertujuan untuk mengidentifikasi model yang paling optimal sehingga dapat diimplementasikan dalam sistem deteksi anemia berbasis Artificial Intelligence (AI) yang lebih andal, cepat, dan layak digunakan dalam lingkungan klinis maupun aplikasi kesehatan digital.

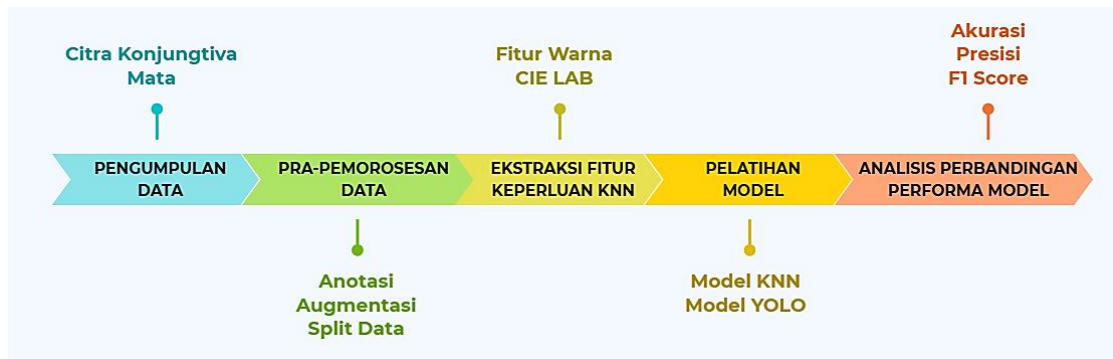
Melalui perbandingan ini, penelitian ini diharapkan dapat memberikan kontribusi nyata dalam pengembangan sistem deteksi anemia berbasis AI yang cepat, akurat, dan mudah diimplementasikan. Selain itu, hasil penelitian ini juga diharapkan dapat memperkuat landasan ilmiah bagi penerapan teknologi non-invasif dalam praktik klinis, terutama di daerah dengan keterbatasan fasilitas laboratorium.

## 2. METODOLOGI PENELITIAN

Penelitian ini merupakan penelitian kuantitatif eksperimental yang bertujuan untuk menganalisis dan membandingkan performa tiga metode klasifikasi citra, yaitu K-Nearest Neighbors (KNN), YOLOv8, dan YOLOv11, dalam mengklasifikasikan citra konjungtiva mata untuk deteksi anemia. Pendekatan ini dilakukan dengan menerapkan supervised learning berbasis machine learning dan deep learning untuk mengidentifikasi citra ke dalam dua kategori utama, yaitu anemia dan non-anemia.

Penelitian ini tidak menguji hipotesis statistik secara eksplisit, tetapi berfokus pada analisis komparatif performa model. Adapun kerangka pemikiran penelitian didasarkan pada asumsi bahwa model berbasis deep learning seperti YOLOv8 dan YOLOv11 akan memberikan hasil yang lebih baik dibandingkan metode tradisional seperti KNN, karena kemampuan ekstraksi fitur otomatis dan struktur arsitektur konvolusional yang lebih kompleks. Proses metodologi

penelitian dibagi menjadi beberapa tahapan, mulai dari pengumpulan data hingga evaluasi dan perbandingan performa kedua model klasifikasi. Metode dapat dilihat pada Gambar 1.



**Gambar 1.** Alur proses metode penelitian

## 2.1 Pengumpulan Data

Data yang digunakan dalam penelitian ini diambil dari CP-AnemiC (A Conjunctival Pallor) Dataset, yang disusun oleh (Asare et al., 2023). Dataset ini terdiri dari citra konjungtiva mata yang dikategorikan ke dalam dua kelas: anemia dan non-anemia. Citra-citra ini berasal dari berbagai individu dengan kondisi yang berbeda, dan dataset ini disediakan secara terbuka di Mendeley Data untuk tujuan penelitian. Dataset ini menjadi bahan utama yang akan digunakan untuk melatih dan menguji model klasifikasi dalam penelitian ini.

## 2.2 Pra-pemrosesan Data

Tahap pra-pemrosesan dilaksanakan untuk mempersiapkan data agar optimal saat proses pelatihan, dimulai dengan pengelompokan awal dataset menjadi dua kelas utama, yaitu anemia dan non-anemia. Selanjutnya, dilakukan augmentasi citra melalui teknik rotasi, flipping horizontal maupun vertikal, serta penyesuaian intensitas cahaya guna memperkaya variasi dan jumlah data. Dataset kemudian didistribusikan dalam dua skema pembagian berbeda, di mana metode KNN menggunakan rasio 75% data pelatihan dan 25% data pengujian, sedangkan model YOLOv8 dan YOLOv11 menggunakan proporsi 70% pelatihan, 15% validasi, dan 15% pengujian. Rangkaian langkah ini bertujuan krusial untuk mencegah terjadinya overfitting sekaligus memastikan model memiliki kemampuan generalisasi yang baik terhadap data baru.

## 2.3 Ekstraksi Fitur

Pada tahap ini, fitur yang relevan diekstraksi dari citra untuk digunakan dalam pelatihan model. Untuk KNN, fitur yang digunakan berasal dari analisis warna citra, khususnya dalam ruang warna CIE LAB. CIE LAB adalah model warna yang dirancang untuk lebih dekat dengan persepsi visual manusia, dan sering digunakan dalam analisis citra medis. Dari setiap citra, nilai rata-rata (mean) dan deviasi standar (standard deviation) dari setiap komponen warna dalam CIE LAB dihitung dan digunakan sebagai fitur untuk klasifikasi.

YOLO tidak memerlukan ekstraksi fitur secara manual. Sebagai model deteksi objek berbasis deep learning, YOLO secara otomatis mengekstraksi fitur selama proses pelatihan. YOLO mengandalkan Convolutional Neural Network (CNN) untuk mempelajari fitur-fitur penting dalam citra dan mendeteksi objek yang ada dalam citra, tanpa memerlukan intervensi manual dalam proses ekstraksi fitur.

## 2.4 Pelatihan Model

Setelah fitur diekstraksi dan data dipersiapkan, tahap selanjutnya adalah pelatihan model klasifikasi. Dalam penelitian ini, dua pendekatan digunakan: KNN dan YOLO. Untuk KNN, model dibangun menggunakan algoritma K-Nearest Neighbors yang diimplementasikan dengan library scikit-learn di Python. Parameter dasar seperti nilai k ditentukan dan dioptimalkan untuk memastikan kinerja yang baik pada data pelatihan.

YOLO, model dilatih menggunakan library Ultralytics dengan implementasi YOLOv8 dan YOLOv11. YOLO adalah model deteksi objek yang sangat efisien dan dapat melakukan deteksi dalam satu kali pemrosesan citra, menjadikannya sangat cepat dan efisien.

## 2.5 Evaluasi dan Perbandingan Model

Evaluasi kinerja untuk setiap model yang dikembangkan dilakukan secara komprehensif dengan menerapkan serangkaian metrik standar, yang mencakup Akurasi (Accuracy), Presisi (Precision), Recall (Sensitivity), dan F1-Score, guna memberikan gambaran yang menyeluruh serta mendalam mengenai kemampuan masing-masing model dalam mendeteksi citra konjungtiva yang merepresentasikan indikasi anemia. Data hasil evaluasi tersebut selanjutnya menjadi landasan utama dalam melakukan analisis perbandingan tingkat efektivitas antara metode K-Nearest Neighbor (KNN), YOLOv8, dan YOLOv11, sekaligus berfungsi sebagai parameter penentu untuk menetapkan model mana yang memiliki performa paling optimal dan andal untuk diterapkan.

### 3. HASIL DAN PEMBAHASAN

Penelitian ini menggunakan dataset CP-AnemiC (A Conjunctival Pallor) yang dikembangkan oleh (J. Asare et al., 2023) dan berasal dari Ghana. Dataset ini terdiri atas 710 citra konjungtiva mata, dengan 424 citra kategori anemia dan 286 citra kategori non-anemia. Untuk memperluas variasi data serta mencegah overfitting, dilakukan augmentasi citra menggunakan teknik flipping dan rotasi sebesar  $30^\circ$ ,  $-30^\circ$ , serta  $180^\circ$ . Setelah proses augmentasi, jumlah dataset meningkat menjadi 3.550 citra (2.120 citra anemia dan 1.430 citra non-anemia).

#### 3.1 Hasil

Model yang diuji terdiri dari K-Nearest Neighbors (KNN), YOLOv8, dan YOLOv11, dengan pembagian data berbeda untuk masing-masing algoritma. KNN menggunakan skema 75% data pelatihan dan 25% data pengujian, sedangkan YOLOv8 dan YOLOv11 menggunakan 70% pelatihan, 15% validasi, dan 15% pengujian.


Hasil pengujian menunjukkan perbedaan performa yang cukup signifikan antar ketiga model. Model YOLOv8 menunjukkan performa terbaik dengan akurasi sebesar 93,4%, presisi 95,0%, recall 94,1%, dan F1-score 94,5%. Model YOLOv11 memiliki performa yang sangat mendekati dengan akurasi 93,0%, presisi 94,7%, recall 93,8%, dan F1-score 94,2%. Adapun metode KNN mencatat hasil yang lebih rendah, yaitu akurasi 85,7%, presisi 87,8%, recall 89,9%, dan F1-score 88,9%.

**Tabel 1.** Perbandingan Performa Model KNN, YOLOv8, dan YOLOv11.

Metrik	YOLOv8	YOLOv11	KNN
Akurasi	93.4%	93.0%	85.7%
Presisi	95.0%	94.7%	87.8%
Recall	94.1%	93.8%	89.9%
F1-Score	94.5%	94.2%	88.9%


Perbandingan nilai metrik tersebut menunjukkan bahwa model YOLO memiliki keunggulan yang jelas dibandingkan dengan metode KNN. Selain hasil kuantitatif, analisis juga dilakukan terhadap grafik hasil pelatihan dan visualisasi deteksi untuk memahami perilaku model selama proses pembelajaran dan pengujian.

Gambar 2 memperlihatkan grafik training curve YOLOv8, yang menunjukkan perubahan nilai loss selama 200 epoch. Terlihat bahwa training loss menurun secara signifikan di awal pelatihan, namun validation loss mengalami fluktuasi pada beberapa epoch terakhir. Pola ini mengindikasikan kemungkinan terjadinya overfitting, di mana model mulai terlalu menyesuaikan diri terhadap data pelatihan.




**Gambar 2.** Performa Yolo v8 Saat Training

Sebaliknya, Gambar 3 menampilkan training curve YOLOv11 yang menunjukkan penurunan loss yang lebih stabil, baik pada data pelatihan maupun validasi. Tren ini menunjukkan bahwa YOLOv11 memiliki kestabilan pelatihan yang lebih baik dan kemampuan generalisasi yang lebih tinggi terhadap data uji. Hal ini sejalan dengan hasil metrik yang menunjukkan performa YOLOv11 yang hampir setara dengan YOLOv8 meskipun dengan fluktuasi yang lebih kecil.

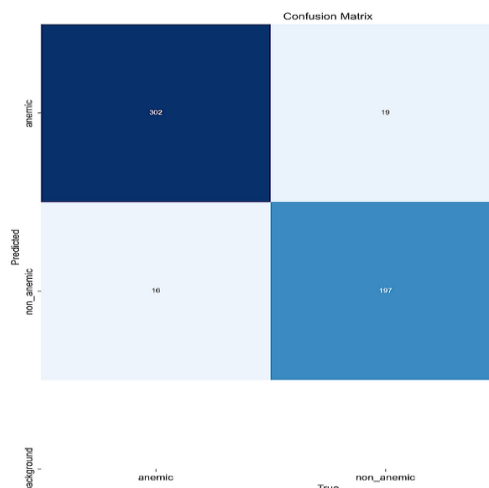


**Gambar 3.** Performa Yolo v11 Saat Training

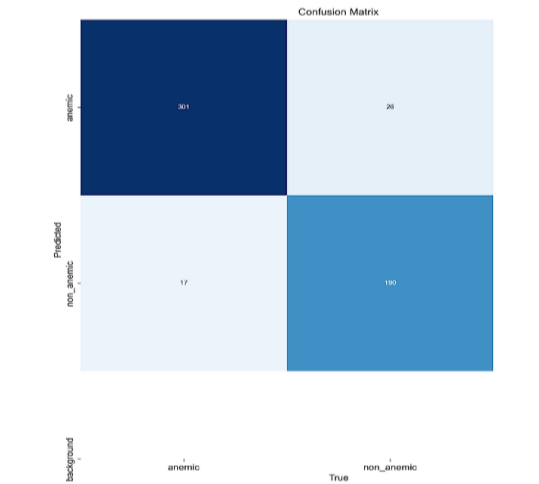
Gambar 4, Gambar 5 dan Gambar 6 menunjukkan confusion matrix hasil pengujian KNN, YOLOv8 dan YOLOv11. Dari ketiga gambar tersebut, terlihat bahwa mayoritas citra terklasifikasi dengan benar pada kategori yang sesuai, dengan sedikit kesalahan klasifikasi pada citra anemia ringan yang memiliki tingkat warna konjungtiva mendekati normal. Kesalahan ini menunjukkan bahwa meskipun model memiliki akurasi tinggi, perbedaan warna yang halus pada area konjungtiva masih menjadi tantangan dalam klasifikasi otomatis.



**Gambar 4.** Confusion Matrix KNN



**Gambar 5.** Confusion Matrix Yolo v8



**Gambar 6.** Confusion Matrix Yolo v11

### 3.2 Pembahasan

Berdasarkan hasil penelitian, performa model YOLOv8 dan YOLOv11 menunjukkan peningkatan yang signifikan dibandingkan metode KNN. Hal ini disebabkan oleh perbedaan mendasar dalam mekanisme ekstraksi fitur. KNN hanya bergantung pada fitur warna yang diekstraksi secara manual (mean dan standar deviasi dalam ruang warna CIE LAB), sehingga informasi spasial dan tekstural dari citra tidak dapat sepenuhnya dimanfaatkan. Akibatnya, kemampuan model untuk membedakan pola kompleks pada citra konjungtiva menjadi terbatas, terutama pada variasi pencahayaan dan kondisi permukaan kulit yang beragam.

Sebaliknya, model YOLO menggunakan pendekatan deep learning berbasis Convolutional Neural Network (CNN) yang memungkinkan ekstraksi fitur otomatis secara hierarkis dari citra. Pendekatan ini menjadikan YOLO lebih adaptif terhadap variasi citra dan lebih mampu mengenali pola non-linear yang relevan untuk identifikasi anemia. Versi terbaru, YOLOv8, memiliki keunggulan dalam efisiensi arsitektur serta pengoptimalan feature extraction yang menghasilkan kecepatan deteksi tinggi tanpa mengorbankan akurasi. Sedangkan YOLOv11 menawarkan arsitektur backbone yang lebih stabil dan mekanisme regularisasi yang lebih baik, yang berdampak pada penurunan validation loss yang konsisten selama pelatihan.

Meskipun YOLOv8 memiliki akurasi dan F1-score tertinggi, grafik pelatihannya menunjukkan fluktuasi yang cukup besar, menandakan kemungkinan overfitting terhadap data pelatihan. Sementara itu, YOLOv11, dengan stabilitas kurva pelatihan yang lebih baik, memberikan hasil yang lebih seimbang antara performa pelatihan dan generalisasi pada data baru. Oleh karena itu, YOLOv11 lebih direkomendasikan untuk implementasi sistem nyata yang memerlukan konsistensi dan ketahanan terhadap variasi data.

Sementara itu, KNN, meskipun menunjukkan hasil yang cukup baik dengan akurasi di atas 85%, masih memiliki keterbatasan signifikan dalam mempelajari fitur kompleks dari citra medis. Hal ini memperkuat kesimpulan bahwa metode berbasis deep learning jauh lebih unggul untuk tugas klasifikasi visual yang kompleks seperti analisis konjungtiva mata.

Secara keseluruhan, penelitian ini menunjukkan bahwa YOLOv8 dan YOLOv11 berpotensi besar diterapkan dalam sistem deteksi anemia non-invasif berbasis citra konjungtiva mata. Dengan akurasi di atas 93%, kedua model mampu memberikan hasil diagnosis yang cepat, efisien, dan konsisten. Penerapan model ini dapat membantu proses skrining awal anemia terutama di daerah dengan keterbatasan fasilitas laboratorium, serta menjadi langkah awal menuju sistem diagnosis medis otomatis berbasis visi komputer yang lebih akurat dan inklusif.

## 4. KESIMPULAN

Penelitian ini telah berhasil menganalisis dan membandingkan performa tiga metode klasifikasi citra, yaitu K-Nearest Neighbors (KNN), YOLOv8, dan YOLOv11, dalam mendeteksi kondisi anemia berdasarkan citra konjungtiva mata. Berdasarkan hasil pengujian, model YOLOv8 menunjukkan performa terbaik dengan nilai akurasi sebesar 93,4%, presisi 95,0%, recall 94,1%, dan F1-score 94,5%, diikuti oleh YOLOv11 dengan akurasi 93,0% dan F1-score 94,2%. Kedua model berbasis deep learning ini mampu mengenali pola warna dan tekstur pada area konjungtiva secara lebih akurat dibandingkan metode konvensional. Sementara itu, metode KNN memperoleh akurasi sebesar 85,7%, menunjukkan bahwa pendekatan berbasis fitur manual masih relevan untuk klasifikasi sederhana, namun belum mampu mengimbangi kemampuan representasi fitur otomatis dari model deep learning. Hasil penelitian ini menegaskan bahwa model YOLO, baik versi v8 maupun v11, memiliki keunggulan signifikan dalam hal akurasi, efisiensi deteksi, serta kemampuan generalisasi terhadap variasi citra. YOLOv8 unggul dalam kecepatan dan ketepatan deteksi, sedangkan YOLOv11 menunjukkan stabilitas pelatihan yang lebih baik dan tren validation loss yang lebih konsisten, sehingga lebih robust terhadap data baru. Dengan demikian, pendekatan berbasis YOLO dapat dianggap sebagai solusi potensial



untuk sistem deteksi anemia non-invasif berbasis citra konjungtiva mata, yang cepat, akurat, dan praktis untuk diimplementasikan dalam sistem kesehatan digital. Selain itu, hasil penelitian ini juga memperlihatkan bahwa teknologi computer vision berbasis AI dapat berperan penting dalam meningkatkan efektivitas diagnosis awal penyakit di daerah dengan keterbatasan fasilitas laboratorium.

## REFERENCES

- Appiahene, P., Arthur, E. J., Korankye, S., Afrifa, S., Asare, J. W., & Donkoh, E. T. (2023). Detection of anemia using conjunctiva images: A smartphone application approach. *Medicine in Novel Technology and Devices*, 18, 100237. <https://doi.org/10.1016/j.medntd.2023.100237>
- Arunnagiri, A. M., Sasikala, M., Ramadass, N., & Ramya, G. (2025). Smartphone-Based Anemia Screening via Conjunctival Imaging With 3d-Printed Spacer: A Cost-Effective Geospatial Health Solution. *Current Medical Imaging Formerly Current Medical Imaging Reviews*, 21(1). <https://doi.org/10.2174/0115734056389602250826081355>
- Asare, J., APPIAHENE, P., & DONKOH, E. (2023, March 2). *CP-AnemiC (A Conjunctival Pallor) Dataset from Ghana*. Mendeley. <https://data.mendeley.com/datasets/m53vz6b7fx/1>
- Asare, J. W., Appiahene, P., Donkoh, E. T., & Dimauro, G. (2023). Iron Deficiency Anemia Detection Using Machine Learning Models: A Comparative Study of Fingernails, Palm and Conjunctiva of the Eye Images. *Engineering Reports*, 5. <https://doi.org/10.1002/eng2.12667>
- Diwan, T., Anirudh, G., & Tembhurne, J. V. (2023). Object detection using YOLO: challenges, architectural successors, datasets and applications. *Multimedia Tools and Applications*, 82(6), 9243–9275. <https://doi.org/10.1007/s11042-022-13644-y>
- Er, H., Tören, M., Asan, B., Kaba, E., & Beyazal, M. (2025). Deep Learning-Based Differentiation of Vertebral Body Lesions on Magnetic Resonance Imaging. *Diagnostics*, 15(15), 1862. <https://doi.org/10.3390/diagnostics15151862>
- Henry, V. S., Sumihar, Y. P., & Maedjaja, F. (2024). Automated Anaemia Detection From Conjunctiva Images : A Machine Learning Approach For Android Application. *JUPI (Jurnal Ilmiah Penelitian Dan Pembelajaran Informatika)*, 9(2), 798–805. <https://doi.org/10.29100/jupi.v9i2.5218>
- Huang, H.-H., Cheng, P.-Y., & Tsai, C.-Y. (2025). Exploring artificial intelligence in functional urology: A comprehensive review. *Urological Science*, 36(1), 2–10. <https://doi.org/10.1097/us9.0000000000000057>
- Li, T., Gharaibeh, N. M., Jia, S., Qinaer, Z., Aihemaiti, S., HaNaTe, A., & Wu, G. (2025). YOLOv8 algorithm-aided detection of patellar instability or dislocation on knee joint MRI images. *Acta Radiologica*, 66(3), 264–268. <https://doi.org/10.1177/02841851241300617>
- Magdalena, R., Saidah, S., Da`wan, I., Ubaidah, S., Fuadah, Y. N., Herman, N., & Ibrahim, N. (2022). Convolutional Neural Network For Anemia Detection Based On Conjunctiva Palpebral Images. *Jurnal Teknik Informatika (JUTIF)*, 3(2), 349–354. <https://doi.org/10.20884/1.jutif.2022.3.2.197>
- Mohamed, M., Salama, R., Ahmed, M., & Aboul-Yazeed, R. S. (2024). AI-Powered Noninvasive Anemia Detection: A Review of Image-Based Techniques. *Advanced Sciences and Technology Journal*, 1(2), 1–30. <https://doi.org/10.21608/astj.2024.340224.1009>
- Nie, X., Zhang, X., Wang, D., Liu, Y., Xing, L., & Liu, W. (2025). Laryngeal cancer diagnosis based on improved YOLOv8 algorithm. *Machine Learning: Science and Technology*, 6(1), 015011. <https://doi.org/10.1088/2632-2153/ada2d9>
- Rizzieri, N., Dall'Asta, L., & Ozoliņš, M. (2024). Diabetic Retinopathy Features Segmentation without Coding Experience with Computer Vision Models YOLOv8 and YOLOv9. *Vision*, 8(3), 48. <https://doi.org/10.3390/vision8030048>
- Rizzieri, N., Dall'Asta, L., & Ozoliņš, M. (2025). An Automated Diagnosis of Myopia from an Optic Disc Image Using YOLOv11: A Feasible Approach for Non-Expert ECPs in Computer Vision. *Life*, 15(10), 1495. <https://doi.org/10.3390/life15101495>
- Sehar, N., Krishnamoorthi, N., & Vinoth Kumar, C. (2025). Deep Learning Model-Based Detection of Anemia from Conjunctiva Images. *Healthcare Informatics Research*, 31(1), 57–65. <https://doi.org/10.4258/hir.2025.31.1.57>
- Vohra, R., Hussain, A., Dudyala, A. K., Pahareeya, J., & Khan, W. (2022). Multi-class classification algorithms for the diagnosis of anemia in an outpatient clinical setting. *PLOS ONE*, 17(7), 1–11. <https://doi.org/10.1371/journal.pone.0269685>
- Widayani, A., Putra, A. M., Maghriebi, A. R., Adi, D. Z. C., & Ridho, Moh. H. F. (2024). Review of Application YOLOv8 in Medical Imaging. *Indonesian Applied Physics Letters*, 5(1), 23–33. <https://doi.org/10.20473/iapl.v5i1.57001>
- Zhao, L., Vidwans, A., Bearnot, C. J., Rayner, J., Lin, T., Baird, J., Suner, S., & Jay, G. D. (2024). Prediction of anemia in real-time using a smartphone camera processing conjunctival images. *PLOS ONE*, 19(5). <https://doi.org/10.1371/journal.pone.0302883>