

# Pemodelan Deteksi dan Klasifikasi Fraktur Tulang pada Radiografi X-Ray Menggunakan YOLOv8 dan Preprocessing CLAHE

Jose Julian Hidayat<sup>1</sup>, Abdul Halim Anshor<sup>2</sup>, M. Syaibani Anwar<sup>2</sup>

<sup>1,2,3</sup>Teknik Informatika, Fakultas Teknik, Universitas Pelita Bangsa, Bekasi, Indonesia

<sup>1</sup>josejulianhidayat@gmail.com\*, <sup>2</sup>abdulhalimanshor@pelitabangsa.ac.id, <sup>3</sup>syaibani@pelitabangsa.ac.id

## Abstract

*This study aims to develop a model for detecting and classifying bone fractures in digital X-ray radiography images using the You Only Look Once version 8 (YOLOv8) architecture with the application of Contrast Limited Adaptive Histogram Equalization (CLAHE) as a preprocessing method. The CLAHE method is used to improve contrast quality and clarify bone structure details, thereby facilitating the feature extraction process by the detection model. The research dataset comprises 641 X-ray and MRI images divided into ten classes consisting of various types of bone fractures, namely Comminuted, Greenstick, Linear, Oblique, Oblique Displaced, Segmental, Spiral, Transverse, and Transverse Displaced, as well as the Healthy class as a comparison. Model training was conducted for 100 epochs using YOLOv8n with CLAHE-based augmentation to improve the visibility of the fracture area. The best results were obtained from the YOLOv8-CLAHE (balanced) model with a mAP@0.5 of 0.933 to 0.941, precision of 0.939 to 0.965, and recall of 0.877 to 0.901. The Segmental and Comminuted classes showed the highest performance, while classes with limited data such as Greenstick and Linear still had relatively low accuracy. The model's inference speed reached 8.3 milliseconds per image, demonstrating the potential application of this system for real-time fracture detection in clinical settings. The results of this study show that the application of the CLAHE method in the image pre-processing stage can improve the detection and classification performance of YOLOv8, and has the potential to support the development of automated diagnosis systems in the field of orthopedic radiology.*

*Keywords: yolov8, clahe preprocessing, bone fracture detection, digital x-ray radiography, deep learning*

## Abstrak

Penelitian ini bertujuan untuk mengembangkan model deteksi dan klasifikasi fraktur tulang pada citra radiografi X-ray digital menggunakan arsitektur *You Only Look Once versi 8 (YOLOv8)* dengan penerapan *Contrast Limited Adaptive Histogram Equalization (CLAHE)* sebagai metode *preprocessing*. Metode *CLAHE* digunakan untuk meningkatkan kualitas kontras dan memperjelas detail struktur tulang sehingga memudahkan proses ekstraksi fitur oleh model deteksi. Sepuluh kelas (*comminuted, greenstick, linear, oblique, oblique displaced, segmental, spiral, transversal, dan transversal displaced*) termasuk dalam dataset penelitian, bersama dengan satu kelas yang berfungsi sebagai pembanding. Dataset yang digunakan secara keseluruhan terdiri dari 641 gambar, yang terdiri dari gambar *X-ray* dan gambar *MRI*, yang telah melalui proses anotasi dan pembagian data. Pelatihan model dilakukan selama 100 *epoch* menggunakan *YOLOv8n* dengan augmentasi berbasis *CLAHE* untuk memperbaiki visibilitas area fraktur. Hasil terbaik diperoleh dari model *YOLOv8-CLAHE (balanced)* dengan capaian *mAP@0.5* dari 0.933 menjadi 0.941, *precision* 0.939 menjadi sebesar 0.965, dan *recall* sebesar 0.877 jadi 0.901. Kelas *Segmental* dan *Comminuted* menunjukkan performa tertinggi, sedangkan kelas dengan jumlah data terbatas seperti *Greenstick* dan *Linear* masih memiliki akurasi relatif rendah. Kecepatan inferensi model mencapai 8,3 milidetik per citra, menunjukkan potensi penerapan sistem ini untuk deteksi fraktur secara *real-time* pada lingkungan klinis. Hasil penelitian ini menunjukkan bahwa penerapan metode *CLAHE* pada proses pra-pengolahan citra mampu meningkatkan performa deteksi dan klasifikasi *YOLOv8*, serta berpotensi mendukung pengembangan sistem diagnosis otomatis di bidang radiologi ortopedi.

Kata kunci: *YOLOv8, CLAHE preprocessing, deteksi fraktur tulang, radiografi x-ray digital, deep learning*

©This work is licensed under a Creative Commons Attribution -ShareAlike 4.0 International License

## 1. Pendahuluan

Salah satu masalah kesehatan terbesar di dunia adalah fraktur tulang, yang dapat disebabkan oleh trauma, kecelakaan, dan kondisi medis tertentu [1]. Hilangnya kontinuitas tulang, termasuk tulang rawan sendi dan epifisis, baik total maupun parsial, dikenal sebagai fraktur [2]. Fraktur adalah hasil dari trauma fisik yang melebihi kekuatan tulang. Ini dapat terjadi karena berbagai alasan, mulai dari trauma langsung, seperti kecelakaan lalu lintas, cedera saat berolahraga, hingga trauma tidak langsung, yang sering terjadi pada pasien lanjut usia dengan *osteoporosis* [3]. Fraktur tulang dapat dibedakan berdasarkan arah patahan, bentuk garis fraktur, serta penyebabnya. Setiap jenis memiliki

karakteristik tersendiri yang penting untuk dikenali dalam proses diagnosis radiologis [4]. Sebuah laporan dari *World Health Organization* menyatakan bahwa jumlah kasus patah tulang di seluruh dunia terus meningkat. Jumlah kasus patah tulang baru pada tahun 2019 meningkat sebesar 33,4% dibandingkan tahun 1990. Pada tahun yang sama, terdapat 455 juta kasus fraktur tulang akut maupun kronis, dan fraktur tulang menyebabkan 25,8 juta tahun orang menjadi tidak dapat bergerak karenanya. Peningkatan ini lebih banyak terlihat pada orang lanjut usia, terutama wanita. Wanita lebih rentan terhadap fraktur kerapuhan karena trauma rendah, seperti jatuh dari posisi berdiri. Karena peningkatan umur rata-rata dan populasi, diperkirakan masalah fraktur kerapuhan akan meningkat di masa

depan. Situasi seperti ini akan terjadi di Indonesia juga. Data dari Riset Kesehatan Dasar [5], patah tulang mencakup 5,7% dari seluruh kasus cedera yang tercatat pada tahun 2018. Insiden patah tulang bertentangan dengan umur produktif berusia sekitar 15 sampai 64 tahun, dan masalah pada laki-laki lebih tinggi di kelompok usia tersebut 6.2% daripada wanita. Hal yang sama juga terjadi di wilayah perkotaan berbanding terbalik dengan desa 6.4% berbanding 5.3%. Kenyataan tersebut masih menunjukkan fraktur tulang adalah masalah kesehatan masyarakat yang signifikan di seluruh dunia dan di seluruh negeri. Selain itu, kualitas gambar *X-ray* yang digunakan dalam diagnosis klinis sangat bervariasi karena banyak faktor teknis maupun non-teknis. Ini menimbulkan masalah besar bagi proses deteksi fraktur tulang secara otomatis. Akibat paparan sinar-X yang buruk, banyak gambar memiliki kontras rendah atau distribusi intensitas yang tidak merata. Ini membuat batas tulang menjadi tidak jelas dan sulit diidentifikasi. Selain itu, kebisingan (*noise*) dari *pixel grayscale* dan sensor detektor sering mengaburkan detail pecahan garis tipis. Selain itu, artefak seperti gangguan gerakan, bayangan benda asing, lipatan kulit, dan tumpang tindih struktur anatomi dapat membuat gambar menjadi lebih gelap. Oleh karena itu, perkembangan sistem *AI* berdasarkan deteksi fraktur tulang otomatis diperlukan untuk mendukung proses diagnosis yang cepat, akurat, dan efisien di bidang Radiologi. Manfaat deteksi dini yang akurat dan cepat adalah penentuan penanganan yang tepat dan mencegah komplikasi. Karena murah, cepat, dan mudah diakses di banyak fasilitas kesehatan, radiografi *X-Ray* masih modalitas pencitraan yang disukai [6]. Alhasil, pengembangan model deteksi berbasis *deep learning* seperti *YOLOv8* yang dipadukan dengan *CLAHE Preprocessing* berpotensi meningkatkan akurasi dan efisiensi dalam proses identifikasi fraktur tulang, khususnya jika akan diimplementasikan ke dalam suatu sistem maka dapat membantu analisis citra medis secara lebih objektif dan konsisten.

Penelitian yang berjudul Segmentasi Deteksi Tepi pada Citra Digital Patah Tulang Orang Dewasa Menggunakan Metode *Sobel* dan Metode *Prewitt* membahas permasalahan kualitas citra *X-Ray* yang sering menurun akibat *noise*, kabur, dan kontras rendah sehingga menyulitkan deteksi fraktur. Metode yang digunakan adalah *Sobel* dan *Prewitt* untuk *edge detection*. Hasil penelitian menunjukkan bahwa kedua metode tersebut berhasil mengekstraksi tepi citra tulang, sehingga memudahkan analisis pola fraktur, dengan evaluasi menggunakan *MSE* dan *PSNR* [7].

Sejauh ini, tidak banyak penelitian yang menggunakan *YOLOv8* secara khusus untuk deteksi fraktur tulang [8]. Namun, beberapa penelitian pada bidang citra medis yang memiliki fitur serupa, seperti mendeteksi struktur tulang gigi melalui radiografi, menunjukkan bahwa *YOLOv8* mampu mendeteksi objek dengan batas yang kompleks dengan baik [8]. Oleh karena itu,

dapat menjadi keterbaharuan yang efektif untuk digunakan dalam kasus deteksi fraktur tulang. Selain itu, metode *CLAHE* lebih disukai daripada metode peningkatan lainnya seperti *Histogram Equalization (HE)* dan *median filtering* karena mampu meningkatkan kontras citra secara lokal tanpa memperkuat *noise* berlebihan [9]. Ini karena metode *CLAHE* lebih baik dalam menonjolkan detail pecahan yang seringkali memiliki perbedaan intensitas yang halus [10].

Penelitian lain yang berjudul *Klasifikasi Analisis Tekstur Citra Radiografi Panoramik Gigi untuk Deteksi Osteoporosis* mengangkat permasalahan keterbatasan alat DXA sehingga diperlukan metode alternatif berbasis citra digital. Metode yang digunakan adalah ekstraksi fitur menggunakan *Grey Level Co-occurrence Matrix (GLCM)* serta klasifikasi dengan *K-Nearest Neighbor (KNN)*. Hasil penelitian menunjukkan akurasi sebesar 78,57%, sensitivitas 100%, dan spesifisitas 66,67% dengan fitur kontras, energi, dan homogenitas [11].

Pada penelitian yang berjudul “*Analysis for diagnosis of pneumonia symptoms using chest X-ray based on MobileNetV2 models with image enhancement using white balance and contrast limited adaptive histogram equalization (CLAHE)*”, Salah satu masalah utama yang diangkat adalah masalah interpretasi gambar *X-ray* yang disebabkan oleh variasi kualitas gambar, seperti ketidakseimbangan warna dan kontras yang rendah. Untuk mengatasi masalah ini, *preprocessing* gambar dilakukan menggunakan *white balance* untuk menormalkan warna dan *CLAHE* untuk meningkatkan kontras dan detail gambar, sehingga model lebih mudah mengidentifikasi fitur penting gambar. Selain itu, gambar dengan kualitas yang ditingkatkan diproses menggunakan model *CNN MobileNetV2* yang efisien secara komputasi. Model ini memiliki kemampuan untuk membedakan antara kondisi *pneumonia* dan *non-pneumonia* dalam skenario dua kelas dan tiga kelas. Hasil penelitian menunjukkan hasil yang sangat baik; pengujian dengan 50 *epoch* menunjukkan akurasi yang sangat tinggi, mencapai 99,76% untuk klasifikasi dua kelas dan 91,17% untuk klasifikasi tiga kelas. Namun, perlu diperhatikan bahwa ada perbedaan antara meningkatkan *epoch* dengan risiko *overfitting* dan waktu komputasi yang diperlukan. Secara keseluruhan, penelitian ini menunjukkan bahwa kombinasi model *deep learning* dan teknik peningkatan citra mampu meningkatkan akurasi diagnosis *pneumonia* serta berpotensi menjadi alat bantu yang efektif bagi tenaga medis [12].

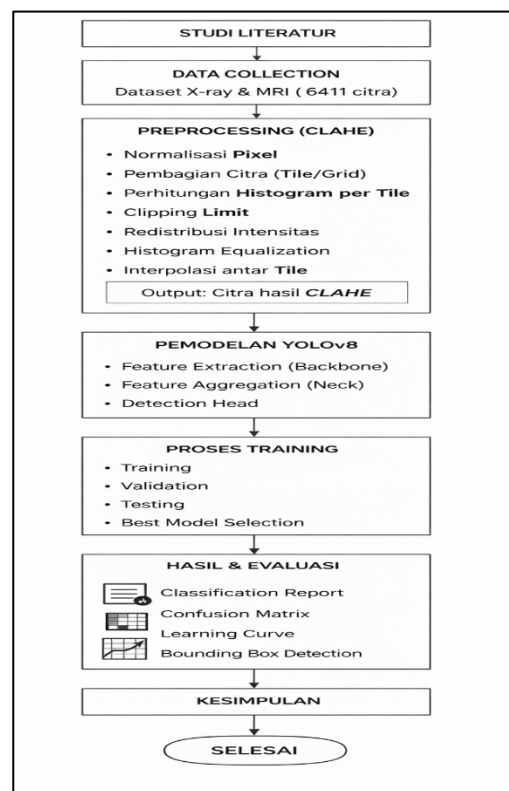
Sebagai hasil dari kemajuan *AI*, terutama di *Computer Vision* dan *Deep Learning*, telah ada peluang besar untuk meningkatkan akurasi dan efisiensi analisis citra medis. *You Only Look Once*, yang terkenal karena mendeteksi objek secara *real-time* dengan kecepatan yang sangat tinggi, adalah salah satu arsitektur terbaru yang banyak digunakan. *YOLOv8* bisa sangat cocok karena kecepatan, fleksibilitas, dan kinerja terbaik dari

generasi sebelumnya, yang merupakan sistem deteksi dan klasifikasi fraktur tulang pada gambar *X-Ray* [13]. Bagaimanapun, gambar sinar-X sering kali mengalami perubahan kualitas karena faktor-faktor teknis dan pasien, sehingga melemahkan performa algoritma deteksi [14]. *CLAHE* berperan sebagai komponen kunci dalam penelitian ini karena mampu meningkatkan kontras citra secara lokal sehingga detail fraktur yang sebelumnya sulit terlihat menjadi lebih jelas, berbeda dengan metode *enhancement* lain seperti *Histogram Equalization (HE)* yang bersifat global atau median *filtering* yang cenderung menghaluskan detail penting, sehingga kombinasi *CLAHE* dan *YOLOv8* memberikan pendekatan yang lebih efektif dalam mendeteksi fraktur pada citra X-ray dengan kualitas yang bervariasi. Demikianlah *Contrast Limited Adaptive Histogram Equalization* yang secara adaptif meningkatkan kontras citra tanpa menghadirkan *noise* tambahan yang signifikan, memperjelas detail struktur tulang dan membuatnya lebih mudah dikenali oleh sistem *deep learning* adalah salah satu *image enhancement* yang populer dan sering digunakan untuk meningkatkan kualitas gambar sinar-X. [15]. Keterbaruan dalam penelitian ini adalah mengembangkan model deteksi *YOLOv8* dengan *Preprocessing CLAHE*, model ini diharapkan dapat dikembangkan untuk deteksi dan klasifikasi fraktur tulang yang lebih cepat, tepat, dan kuat terhadap variabilitas kualitas gambar oleh gabungan *CLAHE preprocessing* dan kelas arsitektur *YOLOv8*. Harapan penelitian ini adalah membawa keuntungan penelitian pada kemajuan *computer-aided diagnosis (CAD)* dalam diagnosis fraktur pada bidang *medical imaging* dan *CAD* dan membantu tenaga medis dalam diagnostik medis yang lebih cepat, diagnostik yang lebih akurat, dan lebih meningkatkan layanan kesehatan, khususnya di fasilitas dengan kurangnya radiolog tanpa menghilangkan fungsi tenaga medis.

## 2. Metode Penelitian

Proses penelitian dimulai dengan mengidentifikasi masalah dan membaca literatur tentang deteksi fraktur tulang pada gambar *X-ray*. Tujuan dari tahap ini adalah untuk memahami teori dasar dan temuan penelitian sebelumnya untuk membangun model. Peneliti kemudian mengumpulkan *dataset* yang digunakan dalam penelitian ini berasal dari sumber data terbuka *Kaggle* yang dapat diakses melalui laman <https://www.kaggle.com/datasets/jockeroika/human-bone-fractures-image-dataset/data>, dengan data berjumlah 641 citra yang terdiri dari citra *X-ray* dan *MRI*, dengan pembagian data sebanyak 449 citra untuk pelatihan (*training*), 128 citra untuk validasi (*validation*), dan 64 citra untuk pengujian (*testing*). Sebelum memasuki tahap pengolahan, data yang dikumpulkan dipilih untuk memenuhi standar kualitas dan keseragaman format. *Dataset* hanya bersumber dari sumber terbuka tersebut tanpa sumber data lainnya.

Jumlah *epoch* 100, ukuran gambar (*image size*) 640 x 640 piksel, ukuran batch yang disesuaikan dengan kapasitas GPU, dan penggunaan *optimizer YOLOv8 standar* dengan *learning rate* awal 0.01 sebagai adalah *hyperparameter* yang digunakan dalam penelitian ini. Selain itu, pada tahap pengujian (*testing*), ambang keyakinan sebesar 0.25 dan ambang *IoU* sebesar 0.50 digunakan untuk menentukan validitas deteksi objek. Tujuan dari pemilihan *hyperparameter* ini adalah untuk mengimbangi kecepatan pelatihan dan performa model dalam mendeteksi objek secara akurat.



Gambar 1. Tahapan dan Prosedur Penelitian

Proses penelitian dalam diagram pada gambar 1 bahwa penelitian dimulai dengan penelitian literatur dan pengumpulan data dari gambar *X-ray* dan *MRI*. Kemudian, tahap *preprocessing* menggunakan metode *CLAHE* untuk meningkatkan kualitas dan kontras gambar dilakukan. Setelah itu, gambar-gambar ini digunakan dalam pemodelan *YOLOv8*, yang melibatkan proses agregasi fitur, ekstraksi fitur, dan deteksi objek. Selanjutnya, model melewati proses pelatihan, validasi, dan pengujian untuk memastikan bahwa ia bekerja dengan baik. Hasilnya dinilai dengan metrik seperti laporan klasifikasi, matriks *confusion*, kurva pembelajaran, dan visualisasi kotak batas. Pada akhirnya, kesimpulan adalah langkah akhir dari penelitian.

### 2.1. Pengolahan Citra Digital dengan *CLAHE Preprocessing*

Pengolahan citra digital adalah serangkaian metode yang digunakan untuk mengubah, menganalisis, dan mengekstrak informasi dari gambar digital dengan

tujuan meningkatkan kualitas gambar atau mendapatkan informasi tertentu yang penting untuk proses yang lebih kompleks [11]. Proses pengolahan citra digital biasanya terdiri dari beberapa langkah utama, yaitu akuisisi gambar, *preprocessing*, segmentasi, ekstraksi fitur, dan klasifikasi [12]. Tahap akuisisi gambar adalah proses pengambilan gambar dari sensor atau alat pencitraan digital, dan tujuan *preprocessing* adalah untuk meningkatkan kualitas gambar dan mengurangi gangguan (*noise*) [16], sehingga informasi penting dapat disimpan. *Filtering*, *equalization histogram*, dan peningkatan kontras adalah teknik *preprocessing* yang umum digunakan [13]. Untuk meningkatkan kontras saat diproses, terutama untuk gambar dengan pencahayaan yang tidak merata atau kontras rendah, *Adaptive Histogram Equalization Limited* adalah salah satu metode peningkatan kualitas citra. Dalam sejarah penelitian ini, metode peningkatan kontras ini biasanya dikenal sebagai *CLAHE*. *CLAHE* pada umumnya adalah tipe *algorithm* dari *Adaptive Histogram Equalization*. Tetapi *CLAHE* memiliki pembatasan pada mekanisme untuk mengatasi *noise* yang berlebihan. *Contrast Limited Adaptive Histogram Equalization (CLAHE)* adalah evolusi dari metode *Adaptive Histogram Equalization (AHE)*. Tujuan *CLAHE* adalah untuk meningkatkan kontras citra secara lokal dengan membagi citra menjadi beberapa bagian kecil (*tile*) dan mengimbangi masing-masing bagian tersebut [17]. Berbeda dengan *Histogram Equalization (HE)* konvensional yang bersifat global, *CLAHE* membatasi peningkatan kontras melalui parameter *clipping* batas untuk mencegah *alignment* yang tidak proporsional [18]. Untuk gambar *X-ray* yang memiliki perbedaan intensitas yang halus, proses ini sangat efektif karena mempertahankan detail lokal gambar dan menghasilkan distribusi intensitas yang lebih merata [15]. Selain itu, metode ini didukung oleh gagasan peningkatan kualitas gambar (*image enhancement*), yang bertujuan untuk meningkatkan visibilitas fitur penting sebelum dilakukan ekstraksi fitur oleh model *deep learning* [19]. Semua *image processing* dan *image enhancement* menggunakan *CLAHE* atau *Enhanced Algorithm Histogram Equalization* karena tidak akan merusak [20].

#### Program CLAHE Preprocessing

```
clahe_root = "/content/dataset_clahe"
os.makedirs(clahe_root, exist_ok=True)

def build_target_dirs(src_images_dir):
    # contoh: ../../train/images ->
    /content/dataset_clahe/train/images
    rel = os.path.relpath(src_images_dir,
        start=os.path.commonpath([src_images_dir,
        base_dir]))
    target_images =
    os.path.join(clahe_root, rel)
    target_labels =
    os.path.join(os.path.dirname(target_images)
        , "labels")
    os.makedirs(target_images,
        exist_ok=True)
    os.makedirs(target_labels,
        exist_ok=True)
    return target_images, target_labels
```

```
# Parameter CLAHE - Anda bisa sesuaikan
CLAHE_CLIP_LIMIT = 2.0
CLAHE_TILE_GRID = (8, 8)

def apply_clahe_to_image(img_bgr):
    # Banyak X-ray grayscale; untuk
    robust, kita konversi ke LAB dan aplikasikan
    CLAHE di channel L
    lab = cv2.cvtColor(img_bgr,
        cv2.COLOR_BGR2LAB)
    l, a, b = cv2.split(lab)
    clahe =
    cv2.createCLAHE(clipLimit=CLAHE_CLIP_LIMIT,
        tileGridSize=CLAHE_TILE_GRID)
    cl = clahe.apply(l)
    limg = cv2.merge((cl, a, b))
    enhanced = cv2.cvtColor(limg,
        cv2.COLOR_LAB2BGR)
    return enhanced

def process_split(src_images_dir,
    src_labels_dir):
    tgt_images_dir, tgt_labels_dir =
    build_target_dirs(src_images_dir)

    # Salin semua label apa adanya
    for lbl in
    tqdm(glob.glob(os.path.join(src_labels_dir,
        "*.txt")), desc=f"Copy labels ->
    {os.path.basename(tgt_labels_dir)}"):
        shutil.copy2(lbl,
            os.path.join(tgt_images_dir,
            os.path.basename(lbl)))

    # Proses CLAHE untuk semua gambar
    img_exts = (".jpg", ".jpeg", ".png",
        ".bmp", ".tif", ".tiff")
    for img_path in
    tqdm(sorted(glob.glob(os.path.join(src_image_dir,
        "*")), desc=f"CLAHE ->
    {os.path.basename(tgt_images_dir)}"):
        if
        img_path.lower().endswith(img_exts):
            continue
        img = cv2.imread(img_path)
        if img is None:
            continue
        out = apply_clahe_to_image(img)
    cv2.imwrite(os.path.join(tgt_images_dir,
        os.path.basename(img_path)), out)

    process_split(train_dir, train_labels)
    process_split(val_dir, val_labels)
    process_split(test_dir, test_labels)

    print("Contoh struktur hasil CLAHE (level
    2):")

!tree -L 2 "$clahe_root" || ls -R
"$clahe_root"
```

Pada prinsipnya, *CLAHE* bekerja dengan membagi gambar menjadi beberapa blok atau area kecil yang disebut *tiles*. Pada tahap pertama, citra masukan dibagi menjadi beberapa sub-blok atau *tile* berukuran seragam [21]. Setiap blok diproses secara terpisah untuk memodifikasi distribusi intensitas piksel di dalam blok. Sebagai hasilnya, tercipta perbedaan kontras yang lebih tinggi antar area yang berbeda di gambar. Setelah semua blok diproses, hasilnya digabungkan kembali dengan menggunakan metode interpolasi bilinear. Metode ini memungkinkan gambaran yang halus tanpa ada batas antar wilayah [22].

#### 2.2. YOLOv8

Algoritma *You Only Look Once (YOLO)* adalah teknik berbasis pembelajaran mendalam berbasis jaringan saraf konvolusional, yang memungkinkan pengenalan

dan klasifikasi objek dengan cepat [23]. Gambar dibagi menjadi beberapa *grid*, dan setiap *grid* harus menebak posisi kotak batas, atau kotak batas, dan kelas objek yang ada di dalamnya. *YOLO* dapat digunakan dalam aplikasi *real-time* seperti pengenalan wajah, pengawasan lalu lintas, dan bahkan analisis citra medis, karena sangat efektif. Karena deteksi dan klasifikasi dilakukan secara bersamaan, metode ini disebut sebagai deteksi satu tahap. Berbeda dengan teknik dua tahap seperti *Faster R-CNN*.

Berdasarkan kesuksesan *YOLOv5*, *Ultralytics* mengembangkan versi *YOLOv8*, yang dirilis pada tahun 2023, menawarkan kerangka kerja yang lebih komprehensif dan tingkat akurasi yang lebih tinggi untuk berbagai tugas penglihatan komputer. Dengan menambahkan deteksi tanpa *anchor*, model ini membuat arsitektur model lebih sederhana dan meningkatkan kinerja pada objek kecil. Ini sangat penting dalam banyak kasus penerapan di tepi [24]. *Ultralytics* mengembangkan versi *YOLOv8*, yang memiliki arsitektur yang lebih ringan dan meningkatkan kecepatan, akurasi, dan efisiensi komputasi dibandingkan versi sebelumnya.

### 2.3. Evaluasi

Evaluasi pemodelan adalah langkah penting dari penelitian berbasis *deep learning* yang ditujukan untuk menilai kemampuan model untuk deteksi dan klasifikasi [25]. Dalam konteks gambar pencitraan medis yang diasumsikan, objek menjadi area fraktur kasus dan tujuan evaluasi adalah untuk mengevaluasi objek diidentifikasi saat penelitian pada gambar *X-Ray*. Pada tahap evaluasi, peneliti memiliki akses ke gambar uji yang belum pernah digunakan. Oleh karena itu, mereka dapat memilih data yang diperlukan dan mendapatkan hasil prediksi dari model yang sama, diizinkan untuk mengeksekusi setelah proses pelatihan adalah selesai [26]. Kinerja model diuji pada domain deteksi, apakah dapat mencari kotak batas yang tepat di sekitar lokasi fraktur, dan domain klasifikasi, menerapkannya memberi label kelas fraktur.

Dalam evaluasi model deteksi objek, beberapa metrik yang umum digunakan antara lain *Precision*, *Recall*, dan *mAP* (*mean Average Precision*) [27]. *Precision* mengukur tingkat ketepatan hasil deteksi model terhadap objek yang benar, sedangkan *recall* mengukur seberapa banyak objek yang berhasil terdeteksi dari total objek sebenarnya [28]. Sementara *mAP* digunakan untuk mengukur akurasi deteksi rata-rata pada berbagai ambang batas *Intersection over Union (IoU)*, nilai menunjukkan keseimbangan antara *Precision* dan *Recall* [29]. Nilai *mAP* berkorelasi positif dengan kemampuan model untuk menemukan dan mengklasifikasikan objek secara akurat. Nilai *mAP* yang mendekati 1 menunjukkan bahwa model dapat menemukan dan melokalisasi objek dengan sangat akurat [30].

Rumus yang digunakan dalam melakukan perhitungan berbasis *confusion matrix* adalah sebagai berikut [31]:

$$recall = \frac{TP}{TP + FN} \quad (1)$$

$$precision = \frac{TP}{TP + FP} \quad (2)$$

$$F1 - score = 2 \times \frac{precision \times recall}{precision + recall} \quad (3)$$

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \quad (4)$$

$$accuracy = \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \quad (5)$$

Dengan keterangan sebagai berikut :

1. *Recall*: mengevaluasi kemampuan model untuk menemukan semua objek (sensitivitas).
2. *Precision*: mengukur akurasi prediksi positif model dalam mendeteksi objek
3. *F1 Score*: rata-rata harmonis antara *precision* dan *recall*, mengimbangi keduanya.
4. *mAP* : rata-rata nilai *Precision Average (AP)* untuk setiap kelas objek
5. *TP*: *True Positive* (prediksi objek benar)
6. *FP*: *False Positive* (prediksi salah sebagai objek)
7. *FN*: *False Negative* (objek yang ada namun tidak terdeteksi)
8. *n* : jumlah titik *recall* yang dihitung
9. *Precision (r<sub>i</sub>)* : presisi pada titik (*r<sub>i</sub>*)
10. *N*: jumlah kelas (berbagai jenis objek yang dideteksi)
11. *AP<sub>i</sub>* : nilai *average precision* untuk kelas ke-*i*
12. *Accuracy*: tingkat akurasi model yang diperoleh selama *training*

### 2.4. Visualisasi

Proses evaluasi model *deep learning* sangat penting, terutama dalam penelitian yang berfokus pada deteksi objek seperti deteksi fraktur tulang pada gambar *X-ray*. Tujuan utama visualisasi adalah untuk menunjukkan secara langsung bagaimana model mengenali dan menandai objek pada gambar uji [32]. Dalam penelitian ini, visualisasi digunakan untuk menunjukkan hasil deteksi area fraktur [33]. Ini dilakukan dengan menunjukkan kotak pembatas, atau kotak pembatas, di sekitar bagian tulang yang diidentifikasi mengalami keretakan [34]. Peneliti dan praktisi medis dapat memahami seberapa sesuai hasil deteksi dengan kondisi sebenarnya pada gambar radiografi dengan visualisasi ini.

Selain menunjukkan area deteksi, visualisasi hasil juga membantu menganalisis kesalahan model, seperti

kasus *false positive* (dalam penelitian model mendeteksi fraktur padahal tidak ada) dan *false negative* (dalam penelitian ini model tidak mendeteksi fraktur yang sebenarnya ada [35]). Analisis terhadap hasil visualisasi membantu peneliti menemukan kelemahan model, seperti ketika model gagal mendeteksi fraktur kecil atau di area dengan kontras rendah. Dengan mengetahui kesalahan tersebut, peneliti dapat mengoptimalkan kinerja dengan menyesuaikan tahap pelatihan, preprocessing gambar, atau parameter model.

### 3. Hasil dan Pembahasan

Sumber data yang diterapkan pada penelitian ini yaitu dari sumber data terbuka *Kaggle* yang dapat diakses melalui laman <https://www.kaggle.com/datasets/jockeroika/human-bone-fractures-image-dataset/data>, dengan data berjumlah 641 citra yang terdiri dari citra *X-ray* dan MRI, dengan pembagian data sebanyak 449 citra untuk pelatihan (*training*), 128 citra untuk validasi (*validation*), dan 64 citra untuk pengujian (*testing*).



Gambar 2. Data Gambar dalam Dataset

#### 3.1. Hasil *Preprocessing* dengan *CLAHE*

Sebelum pelatihan model deteksi dan klasifikasi dilakukan, mekanisme prapemrosesan merupakan permulaan yang sangat fundamental dalam pengolahan citra *X-Ray*. Dalam penelitian ini, metode *CLAHE* (*Contrast Limited Adaptive Histogram Equalization*) digunakan untuk meningkatkan kualitas visual citra tulang. Teknik ini bekerja dengan membagi citra menjadi beberapa blok kecil, juga dikenal sebagai *tiles*, dan kemudian memodifikasi *histogram* setiap bagian untuk meningkatkan kontras citra tanpa menyebabkan *noise* berlebih. Gambar *X-Ray* dikonversi ke *grayscale*. Ini memungkinkan penyesuaian kontras untuk berkonsentrasi pada intensitas cahaya tanpa mempertimbangkan warna. Kemudian, Ukuran *tileGridSize* (8,8) dan nilai batas klip 2.0 digunakan. Setelah uji coba dilakukan untuk mendapatkan hasil terbaik tanpa *noise* yang lebih besar, nilai ini diperoleh seperti pada hasil perhitungan berikut :

$$\begin{aligned} \text{Citra : } I: \Omega \subset \mathbb{Z}^2 &\rightarrow \{0, \dots, 255\}, |\Omega| = 640 \times 640 \\ \text{Pembagian Tile : } N_x = N_y = 4, T_x &= \frac{640}{4} = 160, \\ T_y &= \frac{640}{4} = 160 \\ \text{Ukuran Pertile} = n = T_x T_y &= 160 \times 160 = 256000 \end{aligned}$$

$$\text{Clip Limit} = C_L = \alpha n, \alpha = 0.01 \rightarrow C_L = 0.01 \times 256000 = 256$$

Histogram per-tile ( $i, j$ ) :

$$h_{ij}(k), \text{ Hasil Clipping } h''_{ij}(k), k \in \{0, \dots, 255\}$$

$$\sum_{k=0}^{255} h_{ij}(k) = \sum_{k=0}^{255} h''_{ij}(k) = 25600 \text{ (konstan)}$$

$$\begin{aligned} \text{CDF per-tile} = F_{ij}(g) \\ = \frac{1}{n} \sum_{k=0}^g h''_{ij}(k), g \in \{0, \dots, 255\} \end{aligned}$$


$$\text{Pemetaan Intensitas (CLAHE)} = s_{ij}(g) =$$

$$\text{round} \left( 255 \times f_{ij}(g) \right) \quad (6)$$

Dengan nilai dari  $g = 128$  dan nilai dari  $E_{ij}$  (*mis. energy atau entropi*),  $F_{ij}(128)$  dan  $s_{ij}(128)$  untuk setiap tile ( $i, j$ ),  $i, j \in \{1, \dots, 4\}$  adalah :

$$E = \begin{bmatrix} 9234 & 4598 & 2239 & 4370 \\ 6614 & 1956 & 2239 & 2769 \\ 12936 & 2437 & 3281 & 3780 \\ 22052 & 3422 & 5504 & 4515 \end{bmatrix}$$

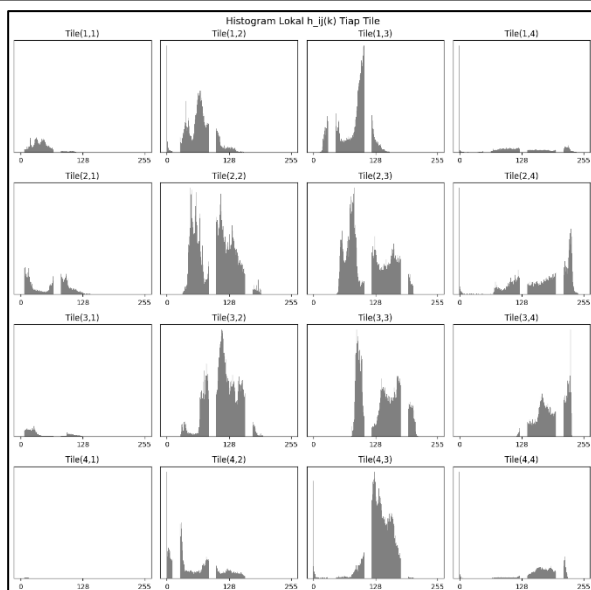
Sehingga menghasilkan segmentasi *tile* yang dapat divisualisasikan sebagai berikut :



Gambar 3. Proses Pembagian *tile* & Hasil *CLAHE* per-tile

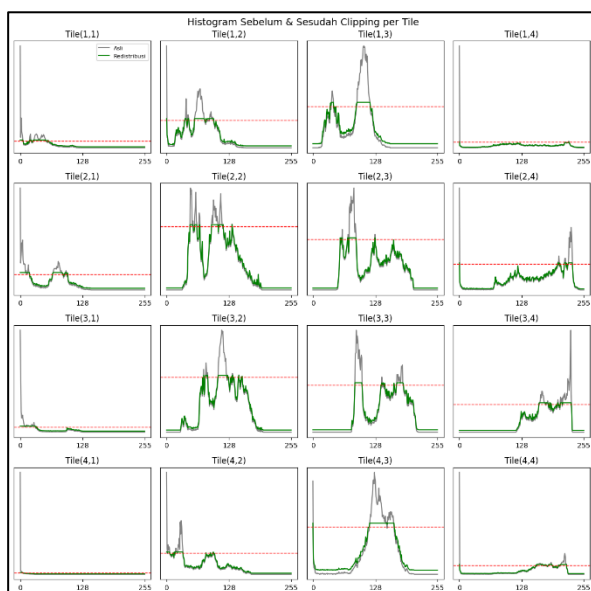
Nilai *histogram* lokal ( $h_{ij}(k)$ ) yang menunjukkan jumlah piksel dengan intensitas keabuan  $k$  dan probabilitas distribusi ( $p_{ij}(k)$ ) untuk setiap *tile* dihitung, menggunakan rumus  $p_{ij}(k) = \frac{h_{ij}(k)}{n}$ , di mana  $n = T_x \times T_y = 25600$ . Hasil perhitungan menunjukkan bahwa nilai  $\sum h_{ij}(k) = n$  benar-benar konsisten, menunjukkan bahwa distribusi piksel telah dihitung secara valid.

Intensitas keabuan citra dengan ukuran  $640 \times 640$ , adalah  $I_{(x,y)} \in [0,255]$ . Kemudian, citra dibagi menjadi  $n_r = 4$  dan  $n_c = 4$  sehingga terdapat  $n_r \times n_c = 16$ . Ukuran tiap *tile* adalah  $T_x = \frac{640}{4} = 160$ ,  $T_y = \frac{640}{4} = 160$ , sehingga jumlah *pixel* dalam satu *tile* adalah  $n = T_x T_y = 160 \times 160 = 256000$ .



Gambar 4. Histogram Lokal  $h_{ij}(k)$  Tiap Tile

Ada distribusi intensitas yang tinggi pada beberapa tile, seperti Tile (1,1) dengan puncak  $p_{11}(0) = 0.148$ , yang menunjukkan dominasi area gelap di sebagian besar gambar 3. Di sisi lain, tile dengan nilai  $p_{ij}(k)$  yang rendah menunjukkan area dengan kecerahan atau kontras yang rendah. Selanjutnya, proses CLAHE memotong histogram, atau memotongnya, untuk mencegah dominasi intensitas tertentu, dan menerapkan ekualisasi pada setiap tile sebelum interpolasi antar tile.




Gambar 5. Visualisasi Histogram Sebelum dan Sesudah Clipping

Gambar 5. di atas menunjukkan histogram, atau hasil distribusi intensitas keabuan, sebelum dan setelah proses clipping pada setiap tile berukuran 160 x 160 piksel. Garis abu-abu menunjukkan histogram asli, dan garis hijau menunjukkan hasil redistribusi setelah clipping. Garis putus-putus merah menunjukkan batas nilai clipping limit maksimum yang digunakan dalam proses CLAHE.

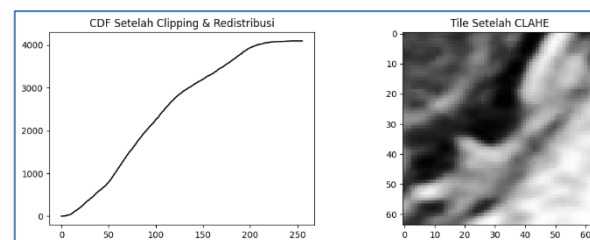
Secara umum, sebagian besar tile, terutama tile (1,1), (1,4), (3,1), dan (4,1), memiliki puncak histogram yang tinggi di rentang intensitas rendah (0–50), yang menunjukkan bahwa area gelap mendominasi citra X-ray. Setelah redistribusi, puncak histogram tersebut menurun secara signifikan, sementara nilai intensitas menengah hingga tinggi tersebar lebih merata. Hal ini menunjukkan bahwa teknik CLAHE efektif dalam mengurangi dominasi intensitas tertentu dan meningkatkan jangkauan dinamis kontras citra lokal.

Selain itu, hasil menunjukkan bahwa proses clipping pada setiap tile mampu mempertahankan informasi struktural tulang sambil menonjolkan detail halus seperti garis fraktur, karena tile dengan intensitas menengah seperti tile (2,2) dan tile (4,2) menunjukkan perubahan distribusi yang lebih seimbang setelah redistribusi, menunjukkan peningkatan kontras tanpa kehilangan detail yang signifikan.



Gambar 6. Kurva CDF dan Hasil Ekualisasi per-Tile

Kurva Fungsi Distribusi Kumulatif (CDF) untuk setiap tile yang dihasilkan dari proses ekualisasi CLAHE ditunjukkan pada Gambar 5. Kurva CDF menunjukkan distribusi kumulatif intensitas keabuan piksel setelah proses redistribusi dilakukan pada setiap tile berukuran 160 x 160 piksel.



Gambar 7. Visualisasi CDF Per-Tile


Seluruh kurva pada gambar 6 dan divalidasi dengan gambar serta tabel statistik intensitas tile menunjukkan pola peningkatan yang relatif halus dan cenderung berbentuk linier, menunjukkan bahwa distribusi

intensitas setelah ekualisasi lebih merata daripada sebelum penerapan proses *CLAHE*. *Tile* (1,2), *Tile* (2,2), dan *Tile* (4,2) menunjukkan peningkatan rentang intensitas setelah sebelumnya memiliki kontras rendah dan distribusi intensitas sempit. Ini menunjukkan keberhasilan *CLAHE* dalam memperluas rentang dinamis citra secara lokal tanpa menimbulkan efek saturasi.

Tabel 1. Statistik Intensitas Tile

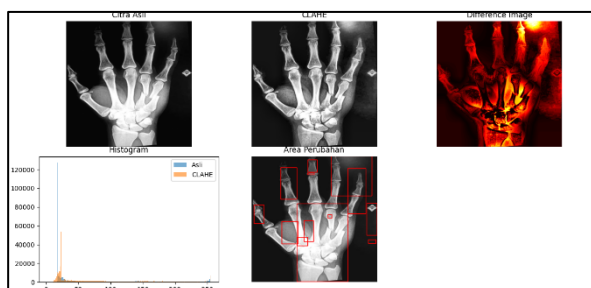
Tipe	Mean	Std	Min	Max
Asli	99.03	54.26	4	246
CLAHE	125.80	72.69	0	255

Beberapa *tile*, seperti *tile* (1,1) dan *tile* (4,1), menunjukkan kurva yang mendekati garis diagonal sempurna, yang menunjukkan distribusi kontras yang telah seimbang antara area terang dan gelap. Hasil ini menunjukkan bahwa ekualisasi *CLAHE* efektif dalam menormalkan distribusi intensitas piksel di setiap area gambar. Ini meningkatkan kualitas visual pada struktur tulang dan detail fraktur yang sebelumnya kurang terlihat, yang semuanya disebabkan oleh proses ekualisasi.



Gambar 8. Perbandingan Citra Asli dan Citra Hasil Tahap Equasi per-tile dalam Preprocessing CLAHE

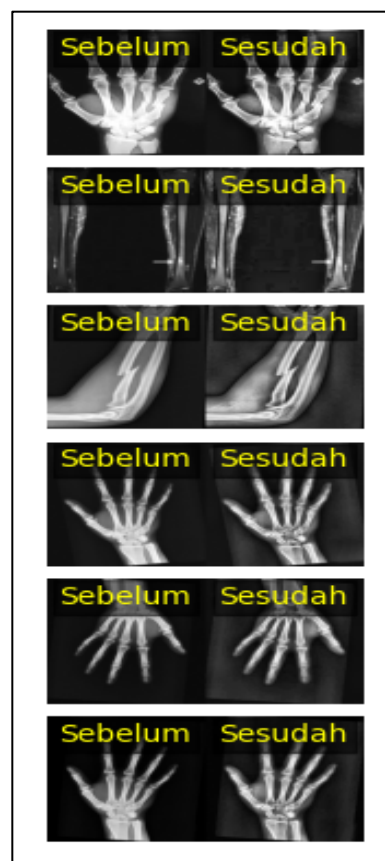
Gambar 8 membandingkan gambar *X-ray* asli dengan hasil preprocessing menggunakan metode *CLAHE* manual dengan interpolasi bilinear. Secara visual, gambar hasil *CLAHE* menunjukkan kontras yang lebih besar, terutama di area tulang metakarpal dan sendi, di mana struktur kortikal dan trabekular tulang lebih jelas dibandingkan dengan gambar asli.



Gambar 9. Perbedaan dan Bukti Perubahan Citra Asli dan Citra dengan *CLAHE*

Gambar 9 di atas menunjukkan hasil perbandingan antara gambar *X-ray* asli dan gambar yang telah diproses menggunakan metode *CLAHE* untuk meningkatkan kontras lokal. Secara visual, gambar yang telah diproses *CLAHE* menunjukkan detail struktur tulang yang lebih jelas dibandingkan gambar

asli, dan histogram menunjukkan bahwa distribusi intensitas piksel pada gambar *CLAHE* lebih tersebar dibandingkan gambar asli, yang menunjukkan peningkatan kontras. Gambar perbedaan menunjukkan perubahan intensitas piksel yang signifikan, terutama di bagian tulang yang lebih terang. Selain itu, anotasi *bounding box* pada area perubahan menunjukkan area gambar dengan kontras yang paling tinggi, ini biasanya terletak pada struktur tulang dan tepiannya. Hasil *preprocessing* dengan *CLAHE* menunjukkan peningkatan kualitas gambar yang signifikan dibandingkan dengan gambar awal. Gambar hasil *CLAHE* pada gambar 10 menunjukkan tekstur dan garis fraktur yang lebih tajam, membantu sistem membedakan antara tulang normal dan yang mengalami keretakan. Area tulang yang sebelumnya tampak gelap atau kurang jelas menjadi lebih kontras dan detail. Oleh karena itu, tahap *preprocessing* menggunakan *CLAHE* menunjukkan peningkatan kualitas data gambar.



Gambar 10. Sample Citra Asli dan Citra Hasil *CLAHE Preprocessing*

### 3.2. Hasil Analisis YOLOv8 dan *CLAHE Preprocessing*

Proses *CLAHE* terdiri dari ekualisasi *histogram* secara lokal, pembagian citra menjadi beberapa wilayah, atau *tile*. Selanjutnya, tahap interpolasi bilinear digunakan untuk menghaluskan transisi antar *tile* sehingga tidak ada *artifact* yang diblokir. Hasil validasi menunjukkan selisih piksel rata-rata sebesar 22,8928 dan selisih maksimum sebesar 75, yang menunjukkan bahwa ada

perbedaan intensitas yang terjadi selama proses interpolasi karena redistribusi kontras dan efek rounding numerik.

Perbedaan ini dapat diterima secara kuantitatif dan menunjukkan bahwa algoritma *CLAHE* manual membuat gambar yang lebih informatif tanpa mengubah struktur anatomis asli. Dengan citra hasil ekualisasi yang memiliki distribusi intensitas yang lebih seimbang antara area terang dan gelap, detail mikro seperti garis fraktur halus yang sulit dilihat pada gambar awal ditampilkan.

Oleh karena itu, tahap *preprocessing* yang digunakan menggunakan *CLAHE* terbukti berhasil meningkatkan kualitas visual dan kontras gambar *X-ray*. Selain itu, tahap ini memberikan basis yang lebih kuat bagi model deteksi *YOLOv8*, yang memungkinkan pengenalan pola fraktur dengan tingkat akurasi yang lebih tinggi.

Analisis kuantitatif dilakukan untuk mengevaluasi dampak penerapan *Equalization Contrast Limited Adaptive Histogram (CLAHE)* terhadap perubahan distribusi intensitas dan kualitas visual gambar *X-ray* tulang. Beberapa parameter statistik, termasuk mean, standar deviasi (*Std Dev*), *entropi*, dan kontras *Michelson*, digunakan untuk membandingkan hasil *CLAHE* dengan gambar asli.

Tabel 2. Evaluasi Dampak CLAHE Terhadap Citra Asli


Parameter	Citra Asli	Hasil CLAHE	Perubahan (%)
Mean	96.8867	105.7144	+9.11
Standar Deviasi	67.6865	69.8175	+3.15
Entropi	7.4528	7.5885	+1.71
Michelson Contrast	1.0000	0.9922	-0.78

Keempat parameter ini mampu menunjukkan kualitas gambar yang lengkap. Nilai *mean* menunjukkan tingkat kecerahan, standar deviasi menunjukkan penyebaran intensitas atau kontras global, *entropy* menunjukkan kompleksitas informasi gambar, dan koefisien *Michelson* mengukur kontras relatif antara area terang dan gelap. Keempat parameter ini dipilih karena dapat mewakili kualitas gambar yang lengkap. Berdasarkan temuan, Tingkat rata-rata peningkatan 9.11% menunjukkan bahwa hasil *CLAHE* memiliki tingkat kecerahan lebih tinggi daripada gambar asli. Ini sejalan dengan tujuan *CLAHE* untuk memperluas rentang kontras lokal dengan meningkatkan intensitas area gelap tanpa menyebabkan saturasi yang berlebihan.

Dengan peningkatan standar deviasi sebesar 3.15%, variasi intensitas antar piksel meningkat, yang menunjukkan bahwa distribusi keabuan menjadi lebih tersebar. Nilai entropi yang meningkat sebesar 1.71% menunjukkan bahwa kompleksitas informasi visual meningkat, yang menunjukkan bahwa gambar hasil *CLAHE* memiliki detail yang lebih kaya dan tekstur tulang yang lebih jelas.

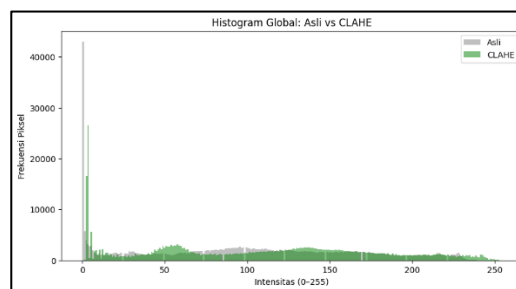
Sebaliknya, *Michelson Contrast* mengalami penurunan kecil sebesar 0,78%. Ini terjadi karena pergeseran intensitas di area terang yang sebelumnya mendominasi. Namun, penurunan ini tidak signifikan secara visual dan justru membantu mengurangi paparan berlebihan pada beberapa bagian gambar *X-ray*.

Secara keseluruhan, temuan ini menunjukkan bahwa penerapan *CLAHE* menghasilkan kualitas visual yang seimbang dengan meningkatkan kecerahan dan kontras lokal tanpa menghilangkan detail penting tentang struktur anatomi tulang.



Gambar 11. Perbandingan Sebuah Citra Asli dan Citra Sesudah Preprocessing CLAHE

Dibandingkan dengan gambar aslinya, gambar hasil *CLAHE* memiliki sebaran intensitas yang lebih luas dan merata, seperti yang ditunjukkan pada grafik. Pada gambar aslinya, sebagian besar piksel terkonsentrasi di rentang intensitas rendah (sekitar 0–50), yang menunjukkan dominasi area gelap dan rendah kontras. Setelah penerapan *CLAHE*, distribusi piksel menjadi lebih tersebar di seluruh rentang intensitas, terutama di rentang menengah (sekitar 50–200), yang menunjukkan peningkatan perataan.



Gambar 12. Histogram Perbandingan Citra Asli dan Citra CLAHE

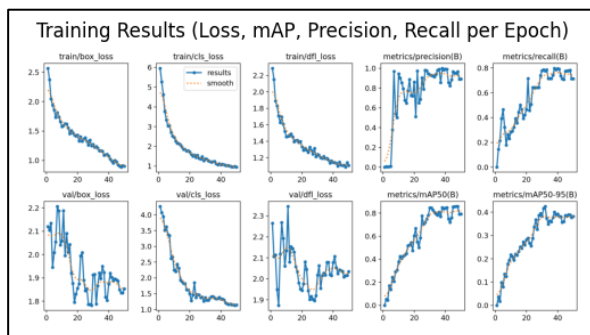
Nilai standar deviasi (*Std Dev*) meningkat sebesar 3.15%, menunjukkan peningkatan kontras kuantitatif, seperti yang ditunjukkan oleh hasil analisis statistik yang diperoleh, yang disajikan dalam tabel 2. Selain itu, ada peningkatan nilai entropi sebesar 1.71%, yang menunjukkan bahwa distribusi informasi visual menjadi lebih kaya dan detail halus pada struktur tulang menjadi lebih jelas. Selain itu, ada peningkatan 9.11% pada nilai mean, yang menunjukkan peningkatan besar dalam kecerahan rata-rata gambar.

Secara keseluruhan, hasil *histogram* internasional pada gambar 12 menunjukkan bahwa penerapan *CLAHE* berhasil meningkatkan kontras dan kecerahan gambar tanpa menghilangkan data penting. Sebaran intensitas

yang lebih merata membantu model *YOLOv8* menemukan tepi dan pola fraktur dengan lebih akurat.

### 3.3. Hasil Pelatihan dan Pengujian Model

Gambar 13. menunjukkan hasil pelatihan model *YOLOv8*, termasuk kurva kehilangan pelatihan, kehilangan validasi, ketepatan, dan *recall* terhadap jumlah *epoch*. Proses pelatihan model *YOLOv8* dilakukan selama 100 *epoch* dengan total waktu sekitar 0,831 jam atau ±49,86 menit, dengan demikian estimasi yang diperlukan untuk menyelesaikan satu *epoch* adalah sekitar 29,9 detik. Pada tahap pengujian (*testing*), model menggunakan *IoU threshold* sebesar 0,7, sedangkan *confidence threshold* mengikuti nilai bawaan sistem prediksi *YOLOv8* pada saat validasi untuk menyeleksi bounding box yang memiliki tingkat keyakinan tertentu. Seluruh jenis kehilangan (kehilangan *boks*, kehilangan klasifikasi, dan kehilangan *DFL*) menunjukkan penurunan yang signifikan sejak awal pelatihan hingga ketika semuanya mulai stabil pada *epoch* 80-an, menurut grafik tersebut. Hal ini menunjukkan bahwa model berhasil konvergensi dengan tingkat kesalahan deteksi yang semakin kecil seiring jumlah iterasi yang dilakukan.



Gambar 13. Training Results

Pada metrik evaluasi, nilai ketepatan dan *recall* meningkat tajam pada sepuluh *epoch* pertama dan kemudian stabil di antara 0,9 dan 1,0. Ini mengartikan yaitu model mempunyai keharmonisan yang mempuni selain kemampuan mendeteksi fraktur yang benar dan menghindari kesalahan deteksi. Nilai *mAP@0.5* meningkat secara bertahap hingga mencapai sekitar 0,94 pada akhir pelatihan, Ini menunjukkan tingkat presisi deteksi yang kuat pada berbagai tingkat *Intersection over Union (IoU)*.

Tidak ada *overfitting* yang signifikan pada model, seperti yang ditunjukkan oleh perbedaan kecil antara kehilangan pelatihan dan kehilangan validasi. Proses validation yang stabil juga menunjukkan bahwa teknik *preprocessing CLAHE* berhasil meningkatkan konsistensi pencahayaan citra. Ini memungkinkan model untuk belajar lebih baik tentang perbedaan kontras dan intensitas pada *dataset* radiografi. Secara keseluruhan, model *YOLOv8* dengan *preprocessing CLAHE* mampu mendeteksi berbagai jenis fraktur tulang dengan konvergensi cepat, stabilitas pelatihan yang baik, dan akurasi deteksi tinggi.

Untuk mengevaluasi kinerja akhir model *YOLOv8*, pengujian ini menggunakan *preprocessing Contrast Limited Adaptive Histogram Equalization (CLAHE)* terhadap data uji yang tidak digunakan selama proses pelatihan dan validasi. Dataset uji terdiri dari 128 gambar radiografi *X-ray* dari sepuluh kelas: sehat, *comminuted*, *greenstick*, *linear*, *oblique*, *oblique displaced*, *segmental*, *spiral*, dan *transversal*. Tujuan utama pengujian ini adalah untuk mengukur kemampuan generalisasi model untuk menemukan dan mengklasifikasikan berbagai jenis fraktur tulang dengan tingkat akurasi dan stabilitas yang tinggi.

Tabel 3. Classification Report Tiap Kelas

Kelas	Precision (P)	Recall (R)	mAP@0.5
Comminuted	0.991	0.927	0.963
Greenstick	0.930	0.600	0.607
Healthy	0.916	1.000	0.995
Linear	0.996	1.000	0.995
Oblique	0.963	0.867	0.962
Displaced	0.996	1.000	0.995
Segmental	0.996	1.000	0.995
Spiral	0.942	1.000	0.995
Transverse	0.924	0.754	0.831
Displaced	0.968	1.000	0.995
Rata-rata (All)	0.965	0.888	0.934

Hasil evaluasi kuantitatif menunjukkan kemampuan deteksi model yang baik di berbagai tingkat *Intersection over Union (IoU)*. Nilai ketelitian sejumlah 0,965, nilai *recall* sebesar 0,901, dan nilai *mAP@0.5* sebesar 0,941, masing-masing. Kelas *segmental* memperoleh nilai *mAP* tertinggi sebesar 0,860 dan 0,561, masing-masing, menunjukkan kemampuan model untuk mendeteksi pola fraktur kompleks dengan baik. Sebaliknya, karena jumlah data yang terbatas dan kesamaan morfologi dengan kelas lain, kelas *Linear* dan *Greenstick* lebih buruk.

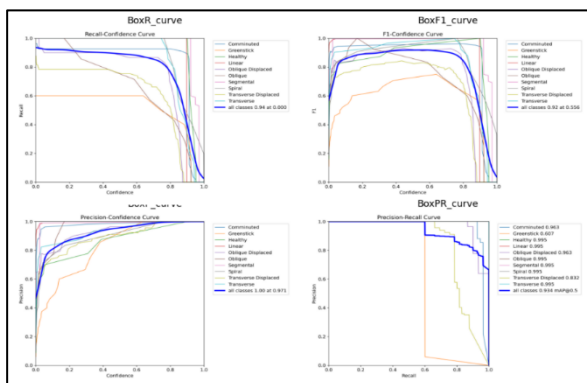
Tabel 4. Hasil Evaluasi Model *YOLOv8* Tanpa *CLAHE* dan Model *YOLOv8* dengan *CLAHE*

Metrik / Kelas	Nilai Tanpa <i>CLAHE</i>	Nilai dengan <i>CLAHE</i>	Selisih	Keterangan
Precision (P)	0.939	0.965	+0.026	Deteksi sangat akurat, minim false positive
Recall (R)	0.887	0.901	+0.014	Sedikit lebih banyak objek terdeteksi
mAP@0.5	0.933	0.941	+0.008	Terbaik untuk IoU=0.5 (deteksi umum)
Comminuted (mAP50-95)	0.449	0.561	+0.112	Stabil di semua eksperimen

<i>Greenstick</i>	0.222	0.274	+0.052	Perlu lebih banyak data untuk naik
<i>Healthy</i>	0.714	0.718	+0.004	Deteksi tulang normal hampir sempurna
<i>Linear</i>	0.199	0.298	+0.099	Sedikit lebih presisi dibanding sebelumnya
<i>Oblique Displaced</i>	0.441	0.446	+0.005	G3 sedikit menaik
<i>Oblique</i>	0.538	0.644	+0.106	Kelas kecil tapi performa tinggi
<i>Segmental</i>	0.788	0.860	+0.072	Kelas paling stabil dan akurat
<i>Spiral</i>	0.499	0.522	+0.023	Baik walau data kecil
<i>Transverse Displaced</i>	0.342	0.346	+0.004	Stabil, tanpa peningkatan signifikan
<i>Transverse</i>	0.563	0.584	+0.021	Konsisten tinggi
<i>Inference Speed</i>	8.3 ms/img	8.3 ms/img	-	Paling cepat ( <i>real-time</i> )

Secara visual, hasil inferensi menunjukkan bahwa model mampu mendeteksi lokasi fraktur dengan posisi bounding box yang presisi serta tingkat kepercayaan tinggi. Citra hasil *CLAHE* memberikan peningkatan kontras yang signifikan, sehingga model dapat mengenali garis fraktur halus yang sebelumnya sulit terdeteksi pada citra asli. Waktu inferensi rata-rata sebesar 8,3 milidetik per citra menunjukkan bahwa model ini efisien dan dapat diterapkan untuk sistem deteksi fraktur real-time di lingkungan klinis.

Analisis kurva metrik yang ditunjukkan melalui *Precision-Confidence*, *Recall-Confidence*, *F1-Confidence*, dan *Precision-Recall Curve* memperkuat hasil tersebut. Kurva *F1* menunjukkan performa optimal pada confidence threshold 0.55 dengan rata-rata *F1-score* sebesar 0.92, yang mengindikasikan keseimbangan ideal antara ketepatan dan kelengkapan deteksi. Kurva *Precision-Recall* memperlihatkan nilai rata-rata *mAP@0.5* sebesar 0.934, menunjukkan kemampuan model yang stabil dalam mengenali berbagai bentuk fraktur meskipun terdapat variasi intensitas pencahayaan dan kontras citra.




Gambar 14. Kurva Evaluasi Utama YOLOv8

Berdasarkan grafik pada gambar 14 tersebut, kehilangan kotak instruksi (garis biru) menurun drastis pada sepuluh *epoch* pertama, turun dari sekitar 2,5 menjadi 1,5. Kemudian turun secara bertahap hingga mencapai sekitar 1,0 pada *epoch* ke-50. Pola ini menunjukkan bahwa model mampu belajar dengan baik dan mengalami proses konvergensi yang stabil. Sementara itu, kehilangan kotak validasi (garis oranye) berubah pada awal pelatihan, tetapi kemudian cenderung stabil pada nilai 1,7–1,9 setelah *epoch* ke-20.

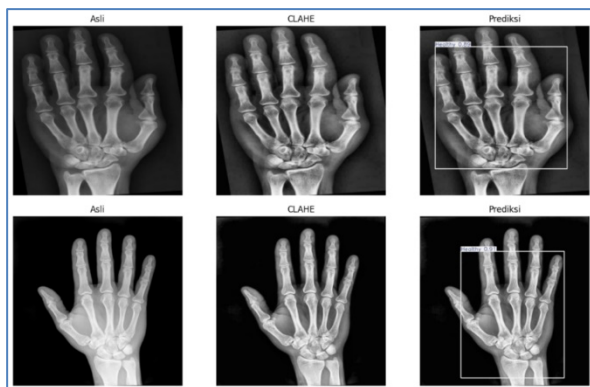
Perbedaan kecil antara kehilangan pembelajaran dan kehilangan validasi menunjukkan bahwa model tidak mengalami overfitting yang signifikan dan generalisasi model terhadap data baru dianggap baik. Selain itu, kestabilan kehilangan validasi setelah beberapa periode menunjukkan bahwa penerapan preprocessing *CLAHE* membantu model belajar dari gambar dengan distribusi kontras yang lebih seragam.

Secara keseluruhan, grafik pada gambar 15 menunjukkan bahwa model *YOLOv8-CLAHE* mencapai konvergensi optimal dengan kinerja validasi yang konsisten dan tingkat kesalahan deteksi posisi objek yang semakin menurun. Ini menunjukkan bahwa model sudah siap untuk tahap pengujian terhadap data *X-ray* yang belum pernah dilihat sebelumnya.



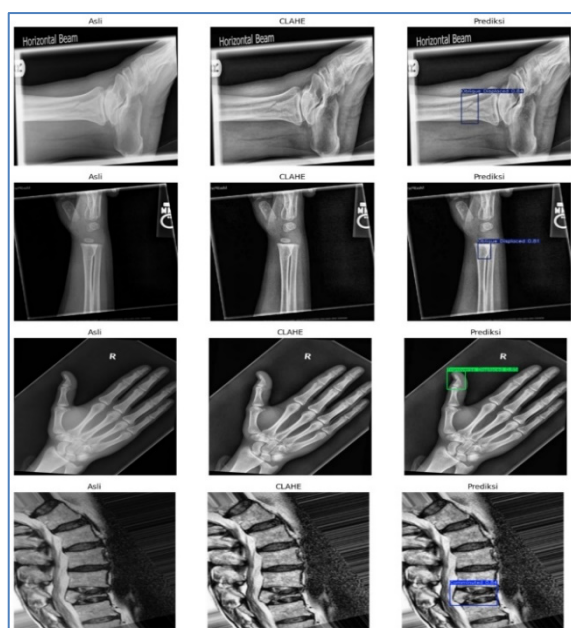
Gambar 15. Training and Validation Loss

Hasil analisis pada gambar 16 menunjukkan bahwa penerapan preprocessing *CLAHE* (*Contrast Limited Adaptive Histogram Equalization*) pada gambar radiografi *X-ray* tangan dapat meningkatkan kualitas kontras dan memperjelas struktur tulang. Ini berarti bahwa model *YOLOv8* dapat membantu dalam proses deteksi dan klasifikasi fraktur. Gambar hasil pengujian menunjukkan bahwa dengan memberikan label "Kesehatan" dan tingkat keyakinan tinggi (0,89 dan 0,91), model dapat mengenali area tulang dengan tepat. Ini menunjukkan bahwa gambar yang telah melalui proses *CLAHE* lebih mudah membedakan fitur tulang seperti kontur dan tekstur. Kualitas gambar yang ditingkatkan ini secara langsung memengaruhi kinerja model, memberikan deteksi yang lebih akurat dan konsisten dibandingkan dengan gambar asli tanpa preprocessing. Oleh karena itu, integrasi *CLAHE* dalam pipeline *YOLOv8* terbukti berguna untuk mendukung pengembangan sistem deteksi fraktur tulang yang bergantung pada gambar radiografi digital.



Gambar 16. Model Berhasil Mendeteksi Citra Kategori Sehat

Hasil pengujian pada sejumlah gambar radiografi *X-ray* menunjukkan bahwa penerapan *CLAHE* meningkatkan kejelasan struktur tulang. Selain itu, aplikasi *CLAHE* membantu model *YOLOv8* menemukan dan mengklasifikasikan dengan akurasi tinggi berbagai jenis fraktur. Gambar 17 hasil prediksi menunjukkan bahwa model dapat membedakan beberapa jenis fraktur: "*Oblique Displaced*" dengan keyakinan 0,84 dan 0,81, "*Comminuted*" dengan keyakinan 0,84, dan "*Transverse Non-Displaced*" dengan keyakinan 0,93. Dengan peningkatan kontras yang dihasilkan oleh *CLAHE*, tepi tulang dan garis patahan yang sebelumnya kurang terlihat pada gambar asli menjadi lebih jelas. Ini membuat pemahaman model tentang fitur visual yang relevan lebih mudah. Hal ini menunjukkan betapa pentingnya proses *preprocessing* untuk meningkatkan sensitivitas model terhadap perubahan tekstur dan pola patahan tulang. Secara keseluruhan, kombinasi *CLAHE* dan *YOLOv8* terbukti efektif dalam mendeteksi berbagai jenis fraktur dengan tingkat kepercayaan tinggi dan memberikan hasil deteksi yang stabil dan presisi. Ini membuatnya kandidat untuk sistem pendukung diagnosis radiografi digital berbasis kecerdasan buatan.



Gambar 17. Model Berhasil Mendeteksi Fraktur

Berdasarkan hasil evaluasi pada Tabel tersebut, model menunjukkan performa yang sangat baik dalam mengklasifikasikan berbagai jenis fraktur tulang. Ini ditunjukkan oleh nilai *precision*, *recall*, dan *F1-score* yang tinggi pada sebagian besar kelas; ini terutama berlaku untuk kelas yang mencapai nilai sempurna: *Healthy*, *Linear*, *Oblique*, *Segmental*, *Spiral*, dan *Transverse*. Selain itu, nilai *mAP@0.5* sebesar 0.941 dan *mAP@0.5:0.95* sebesar 0.561 mendukung performa deteksi model, yang menunjukkan bahwa model dapat menemukan objek dengan tingkat akurasi yang tinggi pada berbagai ambang *IoU*. Secara keseluruhan, model memperoleh nilai akurasi sebesar 0.92, dengan rata-rata *macro* dan berat yang tinggi. Selain itu, dalam penelitian ini dapat diindikasikan bahwa model dapat digeneralisasi dengan baik, meskipun beberapa kelas minoritas, seperti *Greenstick*, memiliki kinerja yang lebih buruk karena jumlah data yang terbatas dan pola fraktur yang kompleks.

Tabel 5. Classification Report

Kelas	Precision	Recall	F1-Score	Support
Comminuted	0.80	0.80	0.80	15
Greenstick	0.60	0.60	0.60	10
Healthy	1.00	1.00	1.00	7
Linear	1.00	1.00	1.00	1
Oblique Displaced	0.93	0.93	0.93	30
Oblique	1.00	1.00	1.00	7
Segmental	1.00	1.00	1.00	3
Spiral	1.00	1.00	1.00	5
Transverse Displaced	0.91	0.91	0.91	65
Transverse	1.00	1.00	1.00	14
mAP@0.5	-	-	0.941	-
mAP@0.5:0.95	-	-	0.561	-
Accuracy	-	-	0.92	157
Macro Avg	0.92	0.92	0.92	157
Weighted Avg	0.91	0.92	0.91	157

Model *YOLOv8* dengan *preprocessing CLAHE* menunjukkan kinerja yang sangat baik dalam mendeteksi dan mengklasifikasikan berbagai jenis fraktur tulang pada citra radiografi *X-ray*, berdasarkan hasil *Confusion Matrix Normalized*. Sebagian besar kelas *Linear*, *Oblique*, *Segmental*, *Spiral*, dan *Transverse* memiliki akurasi sempurna (1.00), sementara kelas *Oblique Displaced* dan *Comminuted* masing-masing memiliki akurasi tinggi sebesar 0.93 dan 0.80, masing-masing. Namun, meskipun terjadi Hasil ini menunjukkan bahwa menggunakan *CLAHE* dapat meningkatkan kontras dan memperjelas karakteristik tulang yang relevan. Ini memungkinkan model untuk mengenali pola fraktur dengan lebih akurat dan konsisten, menjadikannya sistem yang berguna untuk membantu diagnosis radiografi berbasis AI.

Untuk setiap kelas, *precision*, *recall*, dan *F1-score* misalnya untuk kelas *Comminuted*, diketahui *precision* = 0,80 dan *recall* = 0,80, sehingga *F1-score* dihitung dengan:

$$F1 = 2 \times \frac{0.80 \times 0.80}{0.80 + 0.80}$$

$$F1 = 2 \times \frac{0.64}{1.60} = 0.80$$

Untuk kelas *Greenstick*, *precision* = 0,60 dan *recall* = 0,60, maka:

$$F1 = 2 \times \frac{0.60 \times 0.60}{0.60 + 0.60}$$

$$F1 = 2 \times \frac{0.36}{1.20} = 0.60$$

Untuk kelas *Oblique Displaced*, *precision* = 0,93 dan *recall* = 0,93, maka:

$$F1 = 2 \times \frac{0.93 \times 0.93}{0.93 + 0.93}$$

$$F1 = 2 \times \frac{0.8649}{1.86} \approx 0.93$$

Kelas lain seperti *Healthy*, *Linear*, *Oblique*, *Segmental*, *Spiral*, dan *Transverse* memiliki *precision* dan *recall* sebesar 1,00, sehingga nilai *F1-score* juga menjadi 1,00.

Selanjutnya, *Macro Average* dihitung dengan mengambil rata-rata sederhana dari seluruh nilai setiap kelas tanpa memperhatikan jumlah data pada masing-masing kelas. Untuk *precision*:

$$\text{Macro Precision} = \frac{0.80 + 0.60 + 1.00 + \dots + 0.91 + 1.00}{10}$$

$$\text{Macro Precision} = \frac{9.24}{10} = 0.924 \approx 0.92$$

Karena nilai *recall* dan *F1-score* tiap kelas pada tabel juga hampir sama polanya, maka diperoleh:

$$\text{Macro Recall} \approx 0.92$$

$$\text{Macro F1-score} \approx 0.92$$

Kemudian, *Weighted Average* dihitung dengan mempertimbangkan jumlah data tiap kelas (*support*). Rumus umumnya:

$$\text{Weighted Precision} = \frac{\sum(\text{Precision}_i \times \text{Support}_i)}{\sum \text{Support}_i}$$

Substitusinya menjadi:

$$\text{Weighted Precision} = \frac{(0.80 \times 15) + (0.60 \times 10) + \dots + (1.00 \times 14)}{157}$$

$$= \frac{12 + 6 + 7 + 1 + 27.9 + 7 + 3 + 5 + 59.15 + 14}{157}$$

$$= \frac{142.05}{157} \approx 0.905 \approx 0.91$$

Dengan cara yang sama diperoleh:

$$\text{Weighted Recall} \approx 0.92$$

$$\text{Weighted F1-score} \approx 0.91$$

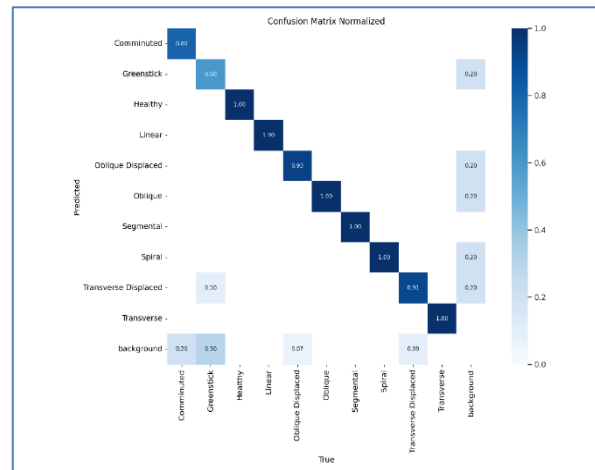
Untuk *accuracy*, pada tabel nilainya 0,92. Secara umum *accuracy* dihitung dengan:

$$\text{Accuracy} = \frac{\text{jumlah prediksi benar}}{\text{jumlah seluruh data}}$$

Karena total *support* adalah 157, maka secara konseptual:

$$\text{Accuracy} \approx \frac{144}{157} \approx 0.92$$

Sehingga didapatkan suatu visualisasi *Confusion Matrix* sebagai berikut:



Gambar 18. Confusion Matrix

### 3.4. Keterbatasan Penelitian

Untuk pengembangan di masa mendatang, penelitian ini masih memiliki beberapa keterbatasan. Pertama, model belum sepenuhnya mewakili semua jenis fraktur dan variasi anatomi tulang manusia karena jumlah dan variasi data radiografi *X-ray* yang digunakan masih terbatas. Kedua, variasi kualitas gambar seperti noise, perbedaan intensitas pencahayaan, dan posisi pengambilan gambar yang tidak seragam dapat mempengaruhi kinerja deteksi model. Ketiga, meskipun *CLAHE* terbukti efektif untuk meningkatkan kontras gambar, artefak di beberapa area dapat mengganggu hasil ekstraksi fitur. Selain itu, penelitian ini hanya melihat model *YOLOv8* dan tidak membandingkannya dengan arsitektur deteksi objek lain seperti *Faster R-CNN* atau *EfficientDet*. Terakhir, penelitian ini belum memasukkan sistem deteksi ke dalam evaluasi klinis langsung oleh tenaga medis, yang berarti uji eksperimental berbasis data masih dapat memvalidasi hasil.

## 4. Kesimpulan

Hasil pengujian menunjukkan bahwa *CLAHE* memperjelas struktur tulang, meningkatkan kualitas gambar, sehingga model dapat dengan akurat mendeteksi area fraktur dengan hasil akurasi terbaik diperoleh dari model *YOLOv8-CLAHE (balanced)* dengan capaian *mAP@0.5* sebesar 0.941, *precision* sebesar 0.965, dan *recall* sebesar 0.901. Berdasarkan

hasil visualisasi dan *confusion matrix*, model mampu mengenali dengan sangat akurat berbagai jenis fraktur, termasuk fraktur sudut, komplemen, dan vertikal, bahkan beberapa kelas mencapai nilai sempurna. Secara keseluruhan, hasil deteksi yang akurat dan konsisten yang dihasilkan oleh kombinasi *CLAHE* dan *YOLOv8* memungkinkan pengembangan sistem pendukung diagnosis radiografi. Untuk meningkatkan reliabilitas dan generalisasi model, penelitian selanjutnya masih perlu memperbaiki beberapa masalah terkait kualitas gambar, variasi dataset, dan validasi klinis. Kelas dengan jumlah data terbatas seperti *Linear* dan *Greenstick* memiliki tingkat akurasi yang lebih rendah, tetapi kelas *Segmental* dan *Comminuted* memiliki tingkat deteksi terbaik. Selain itu, model memiliki kecepatan inferensi 8,3 milidetik per gambar, yang menunjukkan bahwa itu dapat digunakan dalam lingkungan klinis secara real-time. Secara keseluruhan, penelitian ini menunjukkan bahwa kombinasi *CLAHE* dan *YOLOv8* meningkatkan kinerja sistem deteksi fraktur tulang. Kombinasi ini dapat digunakan sebagai pendukung diagnosis otomatis di bidang radiologi ortopedi.

## 5. Saran

Untuk meningkatkan kemampuan generalisasi model, diperlukan peningkatan jumlah dan keragaman dataset untuk penelitian lebih lanjut, terutama pada kelas seperti *Linear* dan *Greenstick* yang masih memiliki jumlah data terbatas. Untuk menemukan model deteksi fraktur terbaik, Anda juga harus membandingkan arsitektur lain seperti *Faster R-CNN*, *YOLOv9*, atau *EfficientDet*. Untuk mengetahui pengaruhnya terhadap peningkatan akurasi dan stabilitas model, Anda juga dapat mencoba metode *preprocessing* tambahan, seperti persamaan histogram atau filter gaussian. Untuk memastikan bahwa model ini andal dan akurat dalam praktik nyata, implementasi sistem ini dengan antarmuka klinis interaktif dan validasi langsung oleh tenaga medis profesional akan sangat penting. Dengan melakukan langkah-langkah ini, sistem deteksi berbasis *YOLOv8-CLAHE* dapat diperluas menjadi alat bantu diagnosis otomatis yang efektif, akurat, dan berguna di bidang radiologi ortopedi kontemporer.

## Daftar Rujukan

- [1] E. Hulu, Derlini, and Mulyadi, "Pemodelan Kekuatan Tekan Femur Menggunakan Analisa Elemen Hingga," *J. Dunia Pendidik.*, vol. 5, no. 5, Mar. 2025, doi: 10.55081/juridip.v5i5.3838.
- [2] N. Sahabuddin, Arman Bausat, Evi Silviani Gusnah, Fadil Mula Putra, and Rahmawati, "Gambaran Faktor Risiko Kejadian Fraktur Terbuka Tertutup Os Tibia," *Fakumi Med. J. Mhs. Kedokt.*, vol. 4, no. 3, pp. 204–210, Apr. 2024, doi: 10.33096/fmj.v4i3.404.
- [3] P. B. Taliabo Bahriah; Bintari Rahayu, Sri; Sartika, Sartika, "Gambaran Karakteristik Kejadian Fraktur Di Instalasi Gawat Darurat Rumah Sakit Andi Makkasau Kota Parepare," *Diagnosis J. Ilm. Kesehatan.*, no. Vol. 20 No. 2 (2025); *Diagnosis: Jurnal Ilmiah Kesehatan*, pp. 19–23, 2025, [Online]. Available: <https://jurnal.stikesnh.ac.id/index.php/jikd/article/view/2734/1243>
- [4] B. P. Meliana, A. W. S. Budi, and R. Rahmawanto, "Pengaruh Pemasangan Balut Bidai dan Relaksasi Nafas Dalam terhadap Penurunan Skala Nyeri pada Pasien Fraktur," *J. Penelit. Perawat Prof.*, vol. 6, no. 6 SE-Articles, May 2024, doi: 10.37287/jppp.v6i6.3430.
- [5] Badan Penelitian dan Pengembangan Kesehatan, "Laporan Risetdas 2018 Nasional.pdf," 2018. [Online]. Available: [https://repository.badankebijakan.kemkes.go.id/eprint/3514/1/Laporan\\_Risetdas\\_2018\\_Nasional.pdf](https://repository.badankebijakan.kemkes.go.id/eprint/3514/1/Laporan_Risetdas_2018_Nasional.pdf)
- [6] S. Angella, D. Hulmansyah, and A. Annisa, "Optimalisasi Kualitas Citra Radiograf Menggunakan Digital Radiography (DR) Pada Pemeriksaan Anatomi Thorax Proyeksi Antero - Posterior(AP)," *Innov. J. Soc. Sci. Res.*, vol. 5, no. 4 SE-Articles, pp. 5885–5895, Jul. 2025, doi: 10.31004/innovative.v5i4.20377.
- [7] K. J. Aditya, I. Kanedi, and A. Sudarsono, "SEGMENTASI DETEKSI TEPI PADA CITRA DIGITAL PATAH TULANG ORANG DEWASA MENGGUNAKAN METODE SOBEL DAN METODE PREWITT," *Djtechno J. Teknol. Inf.*, vol. 3, no. 2, pp. 224–233, Dec. 2022, doi: 10.46576/djtechno.v3i2.2735.
- [8] I. A. M. I. SUMINAR, "SISTEM DETEKSI LOKASI KARIES GIGI PADA CITRA GAMBAR RONTGEN MENGGUNAKAN YOLO V8 DENGAN VISUALISASI AREA TERDETEKSI," Nusa Putra University, 2025.
- [9] F. P. Pratama and A. R. Widiarti, "Enhancing Visibility in Low-Illumination Street Images Using HE, AHE, and CLAHE Techniques," *J. INFORMATICS Telecommun. Eng.*, vol. 9, no. 1, pp. 261–270, 2025.
- [10] R. M. Badri and S. Aningsih, *BUKU AJAR TEKNOLOGI PENGOLAHAN CITRA DIGITAL*, 1st ed. Lampung: ITERA Press, 2025.
- [11] Y. Diputra, S. Syafrijon, and E. Mirshad, "Klasifikasi Analisis Tekstur Citra Radiografi Panoramik Gigi Untuk Deteksi Osteoporosis Menggunakan Metode K-Nearest Neighbor (KNN)," *Voteteknika (Vocational Tek. Elektron. dan Inform.*, vol. 11, no. 3, p. 304, Sep. 2023, doi: 10.24036/voteteknika.v11i3.124871.
- [12] A. M. Rifai, S. Raharjo, E. Utami, and D. Ariatmanto, "Analysis for diagnosis of pneumonia symptoms using chest X-ray based on MobileNetV2 models with image enhancement using white balance and contrast limited adaptive histogram equalization (CLAHE)," *Biomed. Signal Process. Control.*, vol. 90, p. 105857, Apr. 2024, doi: 10.1016/j.bspc.2023.105857.
- [13] M. A. Mansyur and N. Pratiwi, "Deteksi Manusia Dengan Algoritma YOLO Untuk Pemutaran Audio Otomatis Di Area Tertentu," *JUPI (Jurnal Ilm. Penelit. dan Pembelajaran Inform.*, vol. 10, no. 1, pp. 667–674, Jan. 2025, doi: 10.29100/jupi.v10i1.5967.
- [14] Z. Y. Hamd *et al.*, "Optimization of chest X-ray exposure factors using machine learning algorithm," *J. Radiat. Res. Appl. Sci.*, vol. 16, no. 1, p. 100518, Mar. 2023, doi: 10.1016/j.jrras.2022.100518.
- [15] [Y. Lorinez S, A. Yusuf Al Hafiz, A. Khoiri Nasution, A. Denil Sitepu, and H. Syahputra, "IMPLEMENTASI TEKNIK HISTOGRAM EQUALIZATION UNTUK MENINGKATKAN KUALITAS CITRA PADA FOTO LAMA YANG PUDAR," *JATI (Jurnal Mhs. Tek. Inform.*, vol. 9, no. 5, pp. 7524–7530, Jul. 2025, doi: 10.36040/jati.v9i5.14723.
- [16] J. J. Hidayat, M. D. I. Amin, E. K. Fitri, A. N. Anggraini, A. P. Werdana, and C. Setyowati, "Implementasi Model EfficientNetB0 Pada Pembuatan Aplikasi Desktop Untuk Identifikasi Hama Tanaman Sawi Berbasis Deep Learning," *J. Teknol. Inf. Digit.*, vol. 1, no. 2, pp. 82–89, [Online]. Available: <https://jurnal.ipdig.id/index.php/jtid/article/view/195>
- [17] N. E. P. Nadira Eka Putri, R. R. Reni Rahmadewi, and S. M. P. Salsanabila Mariestiara Putri, "Studi Komparasi HE dan CLAHE pada Image Enhancement untuk Segmentasi Citra dalam Deteksi Tumor pada Otak," *Telekontran J. Ilm. Telekomun. Kendali dan Elektron. Terap.*, vol. 13, no. 2, pp. 298–307, Oct. 2025, doi: 10.34010/telekontran.v13i2.18163.
- [18] K. Zuiderveld, "Contrast limited adaptive histogram equalization," in *Graphics Gems IV*, USA: Academic Press

- Professional, Inc., 1994, pp. 474–485.
- [19] I. A. N. Rachman, E. N. F. Dewi, I. R. N. Shofa, and Z. S. Anzana, *INOVASI DEEP LEARNING DALAM HATCHERY: Klasifikasi Embrio Telur Bebek Melalui Pengolahan Citra Candlering*. Sada Kurnia Pustaka, 2025.
- [20] W. K. Pratt, *Digital Image Processing, 4th Edition*, vol. 16, no. 2, 2007. doi: 10.1117/1.2744044.
- [21] S. M. Pizer, R. E. Johnston, J. P. Ericksen, B. C. Yankaskas, and K. E. Muller, “Contrast-limited adaptive histogram equalization: speed and effectiveness,” in *[1990] Proceedings of the First Conference on Visualization in Biomedical Computing*, IEEE Comput. Soc. Press, pp. 337–345. doi: 10.1109/VBC.1990.109340.
- [22] J. Liu *et al.*, “Multi-Scale FPGA-Based Infrared Image Enhancement by Using RGF and CLAHE,” *Sensors*, vol. 23, no. 19, p. 8101, Sep. 2023, doi: 10.3390/s23198101.
- [23] J. Zophie and H. Himawan Triharminto, “9. Implementasi Algoritma You Only Look Once (YOLO) menggunakan Web Camera untuk Mendeteksi Objek Statis dan Dinamis,” *TNI Angkatan Udar.*, vol. 1, no. 1, Jan. 2023, doi: 10.62828/jpb.v1i1.50.
- [24] G. Jocher, Q. Jing, and A. Chaurasia, “Ultralytics YOLO,” 2023, *AGPL-3.0*: 8.0.0. [Online]. Available: <https://github.com/ultralytics/ultralytics>
- [25] Y. K. Bintang and H. Imaduddin, “PENGEMBANGAN MODEL DEEP LEARNING UNTUK DETEKSI RETINOPATI DIABETIK MENGGUNAKAN METODE TRANSFER LEARNING,” *JIPi (Jurnal Ilm. Penelit. dan Pembelajaran Inform.*, vol. 9, no. 3, pp. 1442–1455, Aug. 2024, doi: 10.29100/jipi.v9i3.5588.
- [26] J. J. Hidayat, C. Setyowati, M. D. I. Amin, K. Bimasakti, and A. P. Werdana, “Deep Learning-based Sentiment Analysis of Public Comments on Military Education Using RoBERTa Algorithm and Rule-Based Hybrid Parameters,” *J. Media Comput. Sci.*, vol. 4, no. 2 SE-Articles, Jul. 2025, doi: 10.37676/jmcs.v4i2.8769.
- [27] Efi Mukaromah, Fauzan Masykur, and Adi Fajaryanto Cobantoro, “DETEKSI PENYAKIT DAUN TANAMAN STROBERI MENGGUNAKAN YOLOV8 PENDEKATAN BERBASIS DEEP LEARNING DI TAWANGMANGU,” *MEKAR J. Inf. Syst. Comput. Appl.*, vol. 1, no. 1, pp. 41–52, Aug. 2025, doi: 10.65475/9mr3se03.
- [28] J. J. Hidayat *et al.*, “Prediksi Diabetes Menggunakan Deep Neural Network dengan Penyesuaian Hiperparameter Berbasis Bayesian Optimization,” *J. Pract. Comput. Sci.*, vol. 5, no. 2, pp. 130–143, Jan. 2026, doi: 10.37366/jpcs.v5i2.6419.
- [29] D. J. Marcelleno and M. P. K. Putra, “PERFORMANCE EVALUATION OF YOLOV8 IN REAL-TIME VEHICLE DETECTION IN VARIOUS ENVIRONMENTAL CONDITIONS,” *J. Tek. Inform.*, vol. 6, no. 1, pp. 269–279, Feb. 2025, doi: 10.52436/1.jutif.2025.6.1.3916.
- [30] Q. Aini, N. Lutfiani, H. Kusumah, and M. S. Zahran, “Deteksi dan Pengenalan Objek Dengan Model Machine Learning: Model Yolo,” *CESS (Journal Comput. Eng. Syst. Sci.*, vol. 6, no. 2, p. 192, Jul. 2021, doi: 10.24114/cess.v6i2.25840.
- [31] I. M. D. D. Pranata I Wayan Agus Surya; Sandhiyasa, I Made Subrata; Wiguna, I Komang Arya Ganda, “Strawberry Disease Detection Based on YOLOv8 and K-Fold Cross-Validation,” *J. Ilm. Merpati (Menara Penelit. Akad. Teknol. Informasi)*, no. Vol 11 No 3 (2023): Vol. 11, No. 3, December 2023, pp. 199–210, 2023, [Online]. Available: <https://ojs.unud.ac.id/index.php/merpati/article/view/109400/52916>
- [32] A. M. Rifa'i, M. A. Burhanuddin, W. Hadikristanto, A. Saputra, D. Ariatmanto, and M. S. Mozamir, “Improving Blood Cell Subtype Classification Performance Using Data Augmentation with MobileNetV2,” in *2025 International Conference on Smart Computing, IoT and Machine Learning (SIML)*, IEEE, Jun. 2025, pp. 1–6. doi: 10.1109/SIML65326.2025.11081145.
- [33] P. Triono and M. Murinto, “Aplikasi Pengolahan Citra Untuk Mendeteksi Fraktur Tulang Dengan Metode Deteksi Tepi Canny,” *J. Inform. Ahmad Dahlan*, vol. 9, no. 2, 2015.
- [34] J. J. Hidayat, C. Setyowati, and A. P. Werdana, “Perancangan Sistem Prediksi Penyakit pada Tanaman Padi Berbasis Image Processing Menggunakan Algoritma VGG-16 Transfer Learning dan K-Means Segmentation,” *J. Pract. Comput. Sci.*, vol. 5, no. 1, pp. 1–15, May 2025, doi: 10.37366/jpcs.v5i1.5759.
- [35] Z. Z. Hulafah Al Abrori and E. R. Subhiyakto, “Analisis Komparatif Akurasi Prediksi Kanker Payudara Menggunakan Algoritma Random Forest dan Logistic Regression,” *J. Algoritm.*, vol. 22, no. 1, pp. 300–311, May 2025, doi: 10.33364/algoritma/v.22-1.2164.