

Pengaruh *Contrast Enhancement* terhadap Segmentasi Pembuluh Darah Retina Menggunakan CAS-UNet dengan *Coordinate Attention*

Hilya Zada Mardhatilla Al Haadiy¹⁾, Fetty Tri Anggraeny^{2)*}, Eva Yulia Puspaningrum³⁾

^{1),2),3)}Program Studi Informatika, Fakultas Ilmu Komputer,

Universitas Pembangunan Nasional Veteran Jawa Timur

Jl. Raya Rungkut Madya, Gunung Anyar, Kota Surabaya, Jawa Timur

E-Mail : 22081010172@student.upnjatim.ac.id ¹⁾; fettyanggraeny.if@upnjatim.ac.id ²⁾;

evapuspaningrum.if@upnjatim.ac.id ³⁾;

ABSTRAK

Variasi kontras yang rendah, distribusi intensitas yang tidak merata, serta keberadaan *noise* pada citra fundus retina menjadi kendala utama dalam proses segmentasi pembuluh darah, terutama pada struktur yang tipis dan kompleks. Kondisi ini menyebabkan model kesulitan membedakan antara pembuluh darah dan latar belakang secara akurat. Penelitian ini bertujuan untuk menganalisis pengaruh teknik *contrast enhancement* terhadap kinerja segmentasi pembuluh darah retina menggunakan arsitektur CAS-UNet yang dimodifikasi dengan *Coordinate Attention* (CA). Metode yang digunakan meliputi tiga skenario *preprocessing*, yaitu *grayscale*, *grayscale* + CLAHE, serta *grayscale* + CLAHE + *gamma correction*. Model dilatih menggunakan dataset DRIVE dan CHASE_DB1 dengan pembagian data 80:20, *optimizer* SGD, *learning rate* 0.01, serta fungsi *loss* gabungan BCE dan Dice selama 50 *epoch*. Evaluasi dilakukan menggunakan *confusion matrix* dengan metrik akurasi, sensitivitas, spesifisitas, F1-score, dan IoU. Hasil menunjukkan bahwa kombinasi *grayscale* + CLAHE memberikan performa terbaik dengan sensitivitas sebesar 81.46, F1-Score sebesar 81,63% dan IoU sebesar 69,01%, serta meningkatkan deteksi pembuluh darah kecil secara lebih konsisten. Temuan ini menunjukkan bahwa penerapan *contrast enhancement* yang tepat berperan penting dalam meningkatkan kualitas segmentasi citra medis.

Kata Kunci – segmentasi pembuluh darah retina, *contrast enhancement*, CAS-UNet, *coordinate attention*, CLAHE, citra fundus.

1. PENDAHULUAN

Retinopati diabetik merupakan salah satu komplikasi diabetes melitus yang berpotensi menyebabkan kebutaan apabila tidak dideteksi secara dini (Chazar, Adli, Pardede, & Ichwan, 2025). Berdasarkan data *World Health Organization* (WHO), retinopati diabetik berkontribusi sekitar 4,8% dari total 39 juta kasus kebutaan di seluruh dunia (Kemkes, 2023). Penggunaan citra fundus menjadi penting dalam mendukung deteksi dini perubahan struktur pembuluh darah retina karena mampu menampilkan struktur retina secara menyeluruh melalui metode non-invasif, meliputi pembuluh darah, makula, dan diskus optik (Agustianto, Choirunnisa, Afianah, & Huda, 2022).

Analisis citra fundus secara manual masih menjadi prosedur standar dalam diagnosis penyakit retina, namun memiliki keterbatasan berupa subjektivitas hasil yang bergantung pada keahlian dan pengalaman dokter, waktu pemeriksaan yang relatif lama, serta keterbatasan ketersediaan tenaga spesialis di berbagai wilayah (Das, Chakraborty, Mishra, & Majumder, 2024). Kondisi ini mendorong kebutuhan akan sistem segmentasi pembuluh darah retina yang otomatis dan akurat. Namun, proses segmentasi tidaklah sederhana karena pembuluh darah berukuran sangat kecil dengan percabangan halus, perbedaan intensitas yang rendah terhadap latar belakang, serta rentan terhadap *noise* dan variasi pencahayaan (Desiani, Zayanti, Primartha, Efriliyanti, & Andriani, 2021).

Peningkatan kualitas citra melalui teknik *contrast enhancement* merupakan tahapan penting

dalam *preprocessing* citra retina. Citra fundus umumnya mengalami degradasi akibat kontras rendah dan ketidakseimbangan pencahayaan yang menyulitkan identifikasi struktur vaskular. Teknik seperti *Contrast Limited Adaptive Histogram Equalization* (CLAHE) digunakan untuk meningkatkan kontras lokal pada setiap bagian citra sehingga mampu menghasilkan detail yang lebih jelas, khususnya pada area dengan kontras rendah (Attaqwa, Puspaningrum, & Saputra, 2024). CLAHE banyak digunakan untuk memperjelas detail pembuluh darah, khususnya kapiler kecil, tanpa menghilangkan informasi penting. Dengan demikian, penerapan *contrast enhancement* menjadi faktor fundamental dalam tahap *preprocessing* yang dapat mempengaruhi performa model segmentasi bahkan sebelum proses pembelajaran dilakukan.

Beberapa penelitian terdahulu telah menunjukkan bahwa pemilihan teknik *contrast enhancement* secara langsung mempengaruhi performa model segmentasi pembuluh darah retina. Li et al. membuktikan bahwa dengan menerapkan kombinasi CLAHE, median filtering, dan koreksi gamma adaptif sebagai pipeline *preprocessing* pada model Dense-U-Net berhasil meningkatkan informasi fitur vaskular sebelum proses pembelajaran berlangsung (Li, Jia, Yang, & Xu, 2021). Hernandez-Gutierrez et al. juga menggunakan *gamma correction* bersama CLAHE dalam skema *preprocessing few-shot learning* untuk segmentasi retina, menegaskan bahwa kedua teknik tersebut saling melengkapi dalam meningkatkan visibilitas pembuluh darah (Hernandez-Gutierrez et al., 2025). Di sisi lain, Kande

et al. melaporkan bahwa *pipeline preprocessing* menyeluruh yang mencakup CLAHE menghasilkan nilai *Accuracy*, *Dice*, dan *Sensitivity* tertinggi pada berbagai dataset *benchmark*, sementara nilai $\gamma > 1$ dipilih secara spesifik untuk memperkuat perbedaan intensitas antara *vessel* dan latar belakang (Kande, Nalluri, Manikandan, Cho, & Veerappampalayam Easwaramoorthy, 2025). Temuan-temuan ini mengindikasikan bahwa pengaruh *contrast enhancement* terhadap segmentasi retina bersifat kompleks dan sangat bergantung pada nilai parameter yang digunakan, sehingga analisis empiris yang sistematis sangat diperlukan untuk menentukan konfigurasi *preprocessing* yang optimal pada model segmentasi.

Seiring perkembangan *deep learning*, arsitektur U-Net yang mengadopsi struktur *encoder-decoder* dengan *skip connection* telah menjadi pilihan utama dalam segmentasi citra medis (Das et al., 2024). Model ini termasuk dalam algoritma berbasis *Convolutional Neural Network* (CNN) yang umum digunakan karena mampu menghasilkan akurasi yang baik dalam memproses data berbentuk citra (Wardhani, Anggraeny, & Rizki, 2024). Meskipun efektif, keterbatasan *encoder* yang sederhana menyebabkan model kesulitan menangkap pola kompleks, khususnya pada pembuluh darah kecil yang detail halusnya cenderung hilang saat *downsampling* berulang (Liu, Gu, & Xiao, 2022). Untuk mengatasi hal ini, You et al. (2023) mengembangkan CAS-UNet yang mengintegrasikan *cross-fusion channel attention* (CFCA), *additive attention gate*, dan *SoftPool*, menghasilkan akurasi 96,68% dan sensitivitas 83,21% pada dataset CHASE DB1, serta akurasi 95,86% dan sensitivitas 83,75% pada dataset DRIVE (You, Yu, Xiao, Peng, & Wei, 2023). Di sisi lain, Hou et al. (2021) memperkenalkan *Coordinate Attention* (CA) yang mengintegrasikan informasi spasial dan *channel* melalui dekomposisi arah horizontal dan vertikal, sehingga efektif dalam menjaga kontinuitas pola geometris pembuluh darah retina yang halus dan memanjang (Hou, Zhou, & Feng, 2021).

Meskipun berbagai pengembangan arsitektur berbasis *attention* seperti CAS-UNet dan *Coordinate Attention* telah menunjukkan peningkatan performa dalam segmentasi pembuluh darah retina, sebagian besar penelitian masih berfokus pada optimalisasi struktur model tanpa mempertimbangkan secara mendalam pengaruh tahapan *preprocessing* citra. Padahal, kualitas citra input, khususnya terkait kontras dan distribusi intensitas, memiliki peran penting dalam menentukan keberhasilan proses ekstraksi fitur oleh model. Teknik *contrast enhancement* berpotensi meningkatkan visibilitas pembuluh darah, terutama pada bagian yang tipis dan berkontras rendah, namun pemanfaatannya dalam kombinasi dengan arsitektur CAS-UNet berbasis *Coordinate Attention* masih belum banyak dieksplorasi secara sistematis. Oleh karena itu, penelitian ini bertujuan untuk menganalisis pengaruh penerapan *contrast enhancement* terhadap performa segmentasi pembuluh darah retina menggunakan CAS-UNet dengan *Coordinate Attention*, sehingga dapat memberikan pemahaman yang lebih komprehensif mengenai kontribusi tahap

preprocessing dalam meningkatkan kinerja model segmentasi.

2. TINJAUAN PUSAKA

Sebagai landasan penelitian ini, dilakukan kajian pustaka terhadap berbagai referensi ilmiah yang relevan. Teori-teori yang digunakan bersumber dari penelitian terdahulu dan dijadikan dasar dalam perancangan metode serta analisis hasil penelitian yang digunakan.

A. Segmentasi Citra

Segmentasi citra merupakan salah satu topik fundamental dalam bidang *computer vision* yang berperan penting sebagai dasar dalam proses pengenalan pola dan pemahaman visual (Yu et al., 2023). Perkembangan metode segmentasi tidak terlepas dari berbagai aplikasi luas, seperti pengenalan plat kendaraan (Kabiraj, Pal, Ganguly, Chatterjee, & Roy, 2023), teknologi medis cerdas (Zhao et al., 2021), *search engine* berbasis citra (Yao et al., 2021), inspeksi industri, hingga *augmented reality*. Pada prinsipnya, segmentasi citra bertujuan untuk memisahkan citra menjadi beberapa wilayah yang memiliki karakteristik berbeda serta mengidentifikasi *region of interest* (ROI) yang bersifat bermakna dan tidak saling tumpang tindih menurut persepsi manusia. Citra digital sendiri terdiri atas kumpulan piksel yang dapat dikelompokkan berdasarkan kesamaan fitur seperti warna dan tekstur menjadi *pixel sets* atau *superpixel*. Meskipun fitur-fitur ini mampu merepresentasikan informasi lokal, informasi global seperti bentuk dan posisi objek masih sulit diperoleh secara langsung.

Seiring perkembangannya sejak tahun 1970-an, berbagai pendekatan segmentasi citra telah dikembangkan oleh para peneliti. Metode konvensional umumnya berfokus pada ekstraksi informasi dari satu citra dan sering kali membutuhkan keterlibatan manusia serta pengetahuan khusus, namun memiliki keterbatasan dalam menangkap makna semantik tingkat tinggi. Pendekatan lain seperti *co-segmentation* mencoba menemukan objek yang sama dari beberapa citra dengan memanfaatkan pengetahuan awal, sehingga termasuk dalam kategori *semi-supervised* atau *weakly supervised*. Dengan semakin tersedianya dataset beranotasi dalam jumlah besar dan detail, metode berbasis *deep neural networks* kini menjadi pendekatan yang paling dominan.

B. Contrast Enhancement

Peningkatan citra (*image enhancement*) merupakan tahap penting dalam pengolahan citra yang bertujuan untuk memperbaiki kualitas visual agar informasi yang relevan menjadi lebih mudah dianalisis (Qi et al., 2022). Salah satu pendekatan yang banyak digunakan adalah peningkatan kontras berbasis histogram, di mana distribusi intensitas piksel dimodifikasi untuk menghasilkan perbedaan yang lebih jelas antara objek dan latar belakang. Metode *Histogram Equalization* (HE) mampu meningkatkan kontras secara global, namun kurang efektif dalam mempertahankan detail lokal. Untuk mengatasi keterbatasan tersebut, dikembangkan *Adaptive Histogram Equalization* (AHE) yang bekerja pada

wilayah lokal citra sehingga mampu memperjelas detail dan tepi objek. Meskipun demikian, AHE memiliki kelemahan berupa kecenderungan memperkuat *noise*, terutama pada area citra yang homogen.


Sebagai pengembangan dari AHE, metode *Contrast Limited Adaptive Histogram Equalization* (CLAHE) diperkenalkan untuk mengatasi permasalahan tersebut dengan membatasi peningkatan kontras agar tidak berlebihan (Mudjirahardjo, 2024). CLAHE bekerja dengan cara memotong (*clipping*) nilai histogram pada batas tertentu (*clip limit*) sebelum proses redistribusi intensitas dilakukan. Dengan pembatasan ini, amplifikasi *noise* dapat dikurangi tanpa menghilangkan kemampuan metode dalam meningkatkan kontras lokal. Secara mekanisme, CLAHE membagi citra menjadi beberapa bagian kecil (*tiles*), kemudian melakukan proses ekualisasi histogram pada masing-masing bagian. Nilai histogram yang melebihi batas akan didistribusikan kembali ke seluruh bin histogram, kemudian dilakukan perhitungan *cumulative distribution function* (CDF) untuk memetakan ulang intensitas piksel. Hasil dari tiap bagian citra selanjutnya digabungkan menggunakan interpolasi bilinear untuk menghasilkan citra akhir yang lebih halus dan tidak menimbulkan artefak batas antar wilayah.

Keunggulan utama CLAHE terletak pada kemampuannya dalam meningkatkan kontras lokal tanpa menimbulkan distorsi berlebih pada citra, yang membantu mengurangi *noise* serta meningkatkan kinerja proses ekstraksi fitur, sehingga model mampu memperoleh representasi fitur yang lebih kaya dan

informatif (Ariadi, Anggraeny, & Sihananto, 2024). Hal ini menjadikan CLAHE sangat efektif digunakan pada citra dengan kontras rendah dan struktur objek yang halus, seperti pada citra medis. Dengan demikian, dibandingkan metode konvensional, CLAHE memberikan keseimbangan yang lebih baik antara peningkatan kualitas visual dan preservasi informasi citra, sehingga banyak digunakan sebagai tahap *preprocessing* dalam berbagai penelitian segmentasi citra.

C. Arsitektur CAS-UNet

You et al. (2023) dalam penelitiannya memperkenalkan arsitektur CAS-UNet sebagai pendekatan segmentasi pembuluh darah retina yang mengintegrasikan berbagai mekanisme *attention* ke dalam kerangka U-Net. Arsitektur ini hasil perkembangan dari *Convolutional Neural Network* (CNN), yang memanfaatkan hubungan spasial untuk mengurangi jumlah parameter yang harus dipelajari, sehingga proses pelatihan melalui *feed forward* dan *backpropagation* dapat berlangsung lebih efisien dan optimal (Amir, Akbar, Hendra, Anwar, & Sulfayanti, 2023). Pengembangan ini didasarkan pada keterbatasan U-Net konvensional dalam menangkap struktur vaskular yang berukuran kecil, memiliki kontras rendah, serta pola yang kompleks. Oleh karena itu, CAS-UNet dirancang dengan menambahkan modul perhatian dan strategi pemrosesan fitur yang mampu mempertahankan informasi penting pada setiap tahapan ekstraksi. Adapun arsitektur CAS-UNet divisualisasikan pada Gambar 1.



Gambar 1. Arsitektur CAS-UNet

Secara struktural, CAS-UNet masih mengadopsi kerangka dasar U-Net yang terdiri dari *encoder*,

bottleneck, dan *decoder* yang saling terhubung melalui *skip connection* (You, Yu, Xiao, Peng, & Wei,


2023a). Bagian *encoder* berperan dalam mengekstraksi fitur dari citra masukan, sedangkan *bottleneck* merepresentasikan fitur semantik tingkat tinggi pada resolusi paling rendah. Selanjutnya, *decoder* bertugas merekonstruksi kembali resolusi spasial citra dengan memanfaatkan informasi dari *encoder*. Perbedaannya terletak pada penguatan tiap jalur tersebut melalui integrasi mekanisme *attention* dan strategi *downsampling* yang lebih adaptif untuk meningkatkan kualitas segmentasi.

Arsitektur CAS-UNet dibangun atas tiga komponen utama, yaitu *Cross-Fusion Channel Attention* (CFCA), *Additive Attention Gate* (AG+), dan *SoftPool*. Modul CFCA diterapkan pada *encoder* dan *decoder* melalui DC-Conv Block untuk meningkatkan representasi fitur pada setiap kanal serta memperkuat sensitivitas model terhadap karakteristik pembuluh darah retina. Sementara itu, AG+ ditempatkan pada jalur *skip connection* dengan tujuan menyaring fitur spasial yang relevan sehingga informasi yang diteruskan ke *decoder* menjadi lebih terfokus. Selain itu, penggunaan *SoftPool* sebagai pengganti metode *pooling* konvensional bertujuan untuk mengurangi kehilangan informasi, khususnya pada struktur pembuluh darah yang tipis dan berdekatan.

Pada tahap *decoding*, proses *upsampling* dilakukan menggunakan *transposed convolution* sebagaimana pada U-Net standar untuk mengembalikan resolusi spasial secara bertahap. Namun, CAS-UNet memanfaatkan hasil *upsampling* tersebut sebagai sinyal gating (g) dalam modul AG+. Berbeda dengan metode konvensional yang langsung menggabungkan fitur *encoder* dan *decoder*, pendekatan ini terlebih dahulu melakukan proses penyaringan terhadap fitur *encoder* menggunakan sinyal gating tersebut. Hasilnya kemudian dikombinasikan kembali melalui operasi penjumlahan, sehingga menghasilkan representasi fitur yang lebih selektif dan minim gangguan sebelum diproses lebih lanjut. Secara keseluruhan, kombinasi mekanisme *attention* dan strategi *pooling* pada CAS-UNet memungkinkan peningkatan kualitas segmentasi, khususnya dalam menangkap detail pembuluh darah retina pada berbagai tingkat resolusi.

D. Mekanisme Coordinate Attention

Coordinate Attention (CA) merupakan mekanisme perhatian yang dikembangkan untuk mengatasi keterbatasan pendekatan *channel attention* konvensional yang cenderung mengabaikan informasi spasial. Berbeda dengan metode sebelumnya seperti CFCA yang berfokus pada hubungan antar-*channel*, CA secara eksplisit memasukkan informasi posisi (koordinat) ke dalam proses pembobotan fitur (Hou et al., 2021). Dengan demikian, mekanisme ini tidak hanya menentukan fitur mana yang penting, tetapi juga memperhatikan lokasi fitur tersebut dalam citra. Pendekatan ini menjadikan CA lebih sesuai untuk tugas segmentasi, khususnya pada struktur geometris seperti pembuluh darah retina yang memiliki pola memanjang dan bercabang. Proses mekanisme CA ini ditunjukkan pada Gambar 2.




Gambar 2. Arsitektur Coordinate Attention

Secara umum, CA bekerja melalui dua tahap utama, yaitu pengkodean informasi koordinat dan pembangkitan *attention*. Pada tahap pertama, informasi spasial diekstraksi secara terpisah pada arah horizontal dan vertikal sehingga ketergantungan jarak jauh dapat ditangkap tanpa kehilangan posisi. Selanjutnya, informasi tersebut digabungkan untuk menghasilkan bobot perhatian yang diterapkan kembali pada peta fitur masukan. Mekanisme ini memungkinkan setiap piksel dipengaruhi oleh kombinasi informasi *channel* dan posisi spasialnya, sehingga menghasilkan representasi fitur yang lebih selektif dan terarah. Dalam penelitian ini, CA digunakan sebagai pengganti CFCA karena kemampuannya yang lebih efektif dalam mempertahankan struktur spasial dan meningkatkan akurasi segmentasi.

3. METODE PENELITIAN

Pelaksanaan penelitian memerlukan suatu alur kerja yang sistematis sebagai pedoman agar proses yang dilakukan tetap terarah. Alur ini disusun untuk memastikan bahwa seluruh tahapan penelitian mampu menjawab rumusan masalah serta mencapai tujuan yang telah ditetapkan. Rangkaian tahapan tersebut divisualisasikan dalam bentuk diagram alur penelitian yang ditunjukkan pada Gambar 3.



Gambar 3. Alur Penelitian

A. Pengumpulan Data

Pada penelitian ini digunakan data sekunder yang diperoleh dari dua dataset publik citra fundus retina, yaitu DRIVE (*Digital Retinal Images for Vessel Extraction*) dan CHASE DB1 (*Child Heart and Health Study in England*). Kedua dataset dipilih karena menyediakan anotasi pembuluh darah sebagai *ground truth* yang diperlukan dalam proses pelatihan dan evaluasi model segmentasi. Dataset DRIVE berasal dari program skrining retinopati diabetik di Belanda dan terdiri dari 40 citra beresolusi 565×584 piksel yang terbagi menjadi 20 citra pelatihan dan 20 citra pengujian, dengan anotasi manual oleh ahli sebagai referensi utama (Research Software Engineers, 2012). Sementara itu, CHASE_DB1

merupakan dataset citra retina anak-anak yang terdiri dari 28 citra beresolusi 999×960 piksel dari 14 subjek, di mana setiap citra dilengkapi dua anotasi dan dalam penelitian ini digunakan anotasi dari pakar pertama untuk menjaga konsistensi (Barman et al., 2012). Perbedaan karakteristik antara kedua dataset, baik dari segi usia subjek maupun struktur vaskular retina, memberikan variasi biologis yang penting, seperti perbedaan kerapatan pembuluh, kompleksitas percabangan, serta distribusi diameter vaskular. Oleh karena itu, kedua dataset digabungkan untuk menghasilkan distribusi data yang lebih heterogen, sehingga model yang dikembangkan diharapkan tidak hanya akurat pada satu kelompok tertentu, tetapi juga memiliki kemampuan generalisasi yang lebih baik terhadap variasi morfologi pembuluh darah pada kondisi nyata.

Pembagian data dalam penelitian ini dilakukan secara bertahap untuk memastikan keandalan hasil eksperimen. Berbeda dengan pendekatan umum yang menggabungkan seluruh data sebelum dilakukan pemisahan, penelitian ini terlebih dahulu memisahkan masing-masing dataset secara independen sebelum tahap penggabungan, dengan tujuan menjaga keseimbangan representasi antara citra retina dewasa (DRIVE) dan retina anak-anak (CHASE DB1) pada data pelatihan maupun pengujian. Dataset DRIVE yang terdiri dari 40 citra dibagi menjadi 20 data pelatihan dan 20 data pengujian, sedangkan CHASE DB1 yang berjumlah 28 citra dipisahkan menjadi 20 data pelatihan dan 8 data pengujian. Selanjutnya, data pelatihan dari kedua dataset digabungkan sehingga membentuk total 40 citra sebagai himpunan data latih, yang memungkinkan model mempelajari variasi karakteristik vaskular dari dua kelompok populasi yang berbeda. Proses serupa diterapkan pada data pengujian, yaitu dengan menggabungkan 20 citra uji dari DRIVE dan 8 citra uji dari CHASE DB1 sehingga diperoleh total 28 data pengujian. Strategi ini bertujuan agar model tidak hanya mampu belajar secara optimal dari data pelatihan, tetapi juga memiliki kemampuan generalisasi yang baik saat diuji pada data dengan karakteristik yang beragam.

B. Preprocessing

Tahap *preprocessing* merupakan langkah awal yang dilakukan untuk menyiapkan citra fundus retina sebelum digunakan dalam proses pelatihan model. Dalam penelitian ini, *preprocessing* tidak hanya bertujuan untuk meningkatkan kualitas citra, tetapi juga dirancang dalam tiga konfigurasi berbeda, yaitu *grayscale*, *grayscale* + CLAHE, serta *grayscale* + CLAHE + *gamma correction*, untuk menganalisis secara komprehensif pengaruh teknik *contrast enhancement* terhadap performa segmentasi yang dihasilkan.

Pada tahap awal *preprocessing*, citra fundus berformat RGB dikonversi menjadi citra keabuan (*grayscale*) untuk menyederhanakan representasi data dan mengurangi kompleksitas komputasi. Proses ini bertujuan untuk mengekstraksi informasi intensitas tanpa mempertimbangkan variasi warna, sehingga fitur struktural seperti pembuluh darah lebih mudah dianalisis. Konversi dilakukan menggunakan kombinasi bobot kanal warna merah, hijau, dan biru

yang dinyatakan dalam persamaan $I = 0,299R + 0,587G + 0,114B$ (1)

di mana kanal hijau memiliki kontribusi terbesar karena paling merepresentasikan detail pembuluh darah retina (PODDAR, BANERJEE, BANERJEE, SAHA ROY, & PAUL, 2026). Pendekatan ini umum digunakan dalam pengolahan citra medis karena mampu mempertahankan informasi penting dengan kompleksitas yang lebih rendah.

Pada konfigurasi kedua, citra *grayscale* diproses menggunakan metode *Contrast Limited Adaptive Histogram Equalization* (CLAHE) untuk meningkatkan kontras secara adaptif pada setiap region lokal (Herawati, Sindu Putra, & Suyanta, 2023). Metode ini bekerja dengan membagi citra menjadi beberapa *tile* dengan jumlah piksel $M = m \times n$, kemudian menghitung histogram lokal $h(k)$ untuk setiap tingkat keabuan. Untuk mencegah terjadinya *over-enhancement* seperti pada metode AHE, CLAHE menerapkan batas maksimum histogram (*clip limit*) yang dinyatakan sebagai $\beta = \frac{M}{N} \left(1 + \frac{\alpha}{100} (s_{max} - 1) \right)$ (2)

Histogram yang melebihi batas tersebut kemudian dipotong menggunakan persamaan

$$h_c(k) = \min(h(k), \beta) \quad (3)$$

dan kelebihan piksel didistribusikan kembali ke seluruh tingkat keabuan menjadi $h_r(k) = h_c(k) + \delta(k)$ (4)

Selanjutnya dihitung fungsi distribusi kumulatif (*Cumulative Distribution Function/CDF*) yang digunakan untuk memetakan intensitas piksel baru melalui transformasi

$$f(k) = \frac{(N-1)}{M} \times \text{CDF}(k) \quad (5)$$

Proses ini menghasilkan peningkatan kontras lokal yang lebih stabil serta mampu menonjolkan detail pembuluh darah tanpa menimbulkan artefak berlebih, sementara interpolasi antar *tile* dilakukan untuk menjaga kehalusan citra secara keseluruhan (Hidayat & Fitriani, 2025).

Pada konfigurasi ketiga, hasil citra dari proses CLAHE selanjutnya diproses menggunakan *gamma correction* untuk melakukan penyesuaian intensitas secara non-linear. Teknik ini bertujuan untuk meningkatkan visibilitas area gelap, seperti pembuluh darah retina, tanpa menyebabkan pencahayaan berlebih pada latar belakang. Transformasi dilakukan dengan mengubah hubungan antara intensitas piksel masukan dan keluaran berdasarkan parameter gamma

$$(\gamma), \text{ yang dirumuskan } I_{out} = \left(\frac{I_{in}}{255} \right)^\gamma \times 255 \quad (6)$$

Nilai γ menentukan tingkat kecerahan citra, di mana $\gamma < 1$ akan meningkatkan kecerahan dan $\gamma > 1$ akan menggelapkan citra (Galgani, 2024). Dalam penelitian ini digunakan nilai $\gamma = 0,8$ untuk memperhalus hasil peningkatan kontras dari CLAHE, sehingga struktur pembuluh darah menjadi lebih terlihat tanpa menghilangkan detail halus pada citra retina.

C. Ekstraksi Patch

Untuk meningkatkan jumlah data latih sekaligus menyesuaikan kebutuhan input model, citra fundus retina pada data pelatihan terlebih dahulu dipecah menjadi potongan-potongan kecil (*patch*) berukuran 48×48 piksel. Proses ini dilakukan dengan pendekatan *balanced random sampling*, sehingga distribusi patch

antara area pembuluh darah dan latar belakang tetap seimbang dan permasalahan class imbalance dapat diminimalkan. Melalui tahapan tersebut, dari total 40 citra pelatihan berhasil dihasilkan 40.000 *patch* yang digunakan dalam proses pembelajaran model.

Berbeda dengan data pelatihan, pada tahap pengujian digunakan pendekatan *sliding window* untuk mengekstraksi *patch* secara sistematis dari seluruh area citra. Metode ini memungkinkan setiap bagian citra diprediksi secara menyeluruh, kemudian hasil prediksi pada masing-masing *patch* digabungkan kembali (*stitching*) sehingga membentuk citra segmentasi retina yang utuh. Dengan demikian, evaluasi kinerja model dapat dilakukan secara lebih komprehensif terhadap keseluruhan struktur pembuluh darah dalam citra.

D. Perancangan Model

Arsitektur CAS-UNet merupakan pengembangan dari U-Net yang dirancang untuk meningkatkan kemampuan segmentasi citra medis, khususnya dalam mendeteksi struktur halus seperti pembuluh darah retina. Alur pemrosesan dimulai dari citra input berupa *patch fundus retina* berukuran 48×48 piksel yang kemudian diproses melalui jalur encoder untuk mengekstraksi fitur secara bertingkat. Pada tahap ini, setiap layer encoder menggunakan DC-Conv Block yang berfungsi untuk menangkap pola lokal maupun global dari citra. Operasi konvolusi dalam blok ini dapat dinyatakan dengan persamaan:

$$F = \text{ReLU}(\text{BN}(W * X + b)) \quad (7)$$

di mana proses ini bertujuan untuk mengekstraksi fitur penting seperti tepi pembuluh darah, pola percabangan, serta perbedaan intensitas antara objek dan latar belakang.

Pada varian model yang diusulkan, modul attention yang digunakan adalah *Coordinate Attention* (CA), yang disisipkan pada setiap DC-Conv Block. *Coordinate Attention* merupakan mekanisme perhatian yang tidak hanya memperhatikan hubungan antar-*channel*, tetapi juga mempertahankan informasi posisi spasial secara eksplisit. Pada tahap awal, dilakukan proses *coordinate information embedding*, yaitu pengkodean informasi spasial melalui dua arah, horizontal dan vertikal. Proses ini dilakukan dengan operasi pooling sebagai berikut:

$$z^h(i) = \frac{1}{W} \sum_{j=1}^W X(i, j), z^w(j) = \frac{1}{H} \sum_{i=1}^H X(i, j) \quad (8)$$

Vektor z^h merepresentasikan distribusi fitur sepanjang arah vertikal yang menjaga informasi baris, sedangkan z^w merepresentasikan distribusi sepanjang arah horizontal yang menjaga informasi kolom. Dengan memisahkan kedua arah ini, CA mampu mempertahankan informasi lokasi yang biasanya hilang pada global pooling konvensional.

Selanjutnya, kedua representasi tersebut digabungkan dan diproses menggunakan konvolusi 1×1 untuk membentuk representasi fitur yang lebih ringkas:

$$f = \delta(W \cdot [z^h, z^w]) \quad (9)$$

di mana δ merupakan fungsi aktivasi non-linear (ReLU). Tahap ini berfungsi sebagai bottleneck yang menyaring informasi koordinat paling relevan. Setelah

itu, fitur dipisahkan kembali sesuai arah koordinat dan dilewatkan ke fungsi sigmoid untuk menghasilkan bobot perhatian:

$$g^h = \sigma(f^h), g^w = \sigma(f^w) \quad (10)$$

Bobot ini kemudian digunakan untuk mengkalibrasi *feature map* awal:

$$Y(i, j) = X(i, j) \cdot g^h(i) \cdot g^w(j) \quad (11)$$

Proses ini memiliki fungsi penting, yaitu memperkuat fitur yang berada pada lokasi spasial yang relevan (misalnya pembuluh darah), serta menekan respon dari area yang tidak penting seperti *background*. Dengan demikian, CA sangat efektif dalam menjaga kontinuitas struktur pembuluh darah yang tipis dan memanjang.

Untuk menggantikan metode *downsampling* konvensional, CAS-UNet menggunakan *SoftPooling* yang mampu mempertahankan informasi lebih kaya dibandingkan *MaxPooling*. Pada *MaxPooling*, hanya nilai maksimum dalam jendela lokal yang dipertahankan:

$$\tilde{\alpha}_{\max} = \max(\alpha_i), i \in R \quad (12)$$

Pendekatan ini berpotensi menghilangkan informasi penting dari piksel lain. Oleh karena itu, *SoftPooling* digunakan dengan prinsip *weighted pooling* berbasis *SoftMax*, di mana bobot setiap elemen dihitung sebagai:

$$\omega_i = \frac{e^{\alpha_i}}{\sum_{j \in R} e^{\alpha_j}} \quad (13)$$

Selanjutnya, nilai keluaran dihitung sebagai kombinasi berbobot:

$$\tilde{\alpha} = \sum_{i \in R} (\omega_i \cdot \alpha_i) \quad (14)$$

Metode ini memungkinkan seluruh piksel dalam region tetap berkontribusi, sehingga informasi detail seperti pembuluh darah tipis tidak hilang selama proses reduksi dimensi.

Selanjutnya, setelah melalui tahap encoder dan perhatian spasial, fitur yang telah diperkaya kemudian masuk ke bagian *bottleneck* untuk menangkap representasi global citra. Selanjutnya, pada tahap decoder dilakukan proses rekonstruksi citra untuk mengembalikan resolusi spasial ke ukuran semula. Proses ini diawali dengan upsampling menggunakan *transposed convolution*:

$$g_l = W^T * F_b \quad (13)$$

yang berfungsi untuk memperbesar dimensi fitur secara bertahap. Untuk memastikan hanya fitur yang relevan yang digunakan, diterapkan mekanisme *Additive Attention Gate* (AG+).

Modul ini memanfaatkan dua fitur, yaitu x_l dari encoder dan g_l dari decoder, yang kemudian digabungkan untuk menghasilkan koefisien perhatian. Fitur yang telah dibobot dinyatakan sebagai:

$$\hat{x}_l = \alpha \cdot x_l \quad (22)$$

Koefisien *attention* dihitung dengan:

$$\alpha = \sigma_2(\psi(\sigma_1(\omega_x x_l + \omega_g g_l + b_g))) + b_\psi \quad (15)$$

Selanjutnya, hasil pembobotan digabungkan kembali dengan sinyal gating untuk menghasilkan output akhir:

$$\hat{x}_{out} = \sigma_2(\hat{x}_l + g_l) \quad (24)$$

Fungsi utama AG+ adalah menyaring informasi dari encoder sehingga hanya fitur yang relevan secara kontekstual yang diteruskan ke decoder, yang sangat penting untuk mengurangi *noise* dari *backgorund*.

Fitur hasil penggabungan kemudian diproses kembali menggunakan DC-Conv Block dan modul *Coordinate Attention* untuk memperhalus hasil segmentasi. Pada tahap akhir, dilakukan konvolusi 1×1 untuk memetakan *feature map* menjadi satu kanal output yang merepresentasikan probabilitas keberadaan pembuluh darah:

$$Y = \sigma(W * F) \quad (17)$$

Nilai probabilitas ini kemudian dikonversi menjadi citra biner melalui proses *thresholding* sehingga dihasilkan *mask* segmentasi yang memisahkan pembuluh darah dari latar belakang.

Dengan demikian, kombinasi antara modul *Coordinate Attention* dalam DC-Conv Block, *SoftPooling*, dan *Additive Attention Gate* memungkinkan model untuk tidak hanya mengekstraksi fitur secara mendalam, tetapi juga mempertahankan informasi spasial yang krusial. Hal ini menjadikan CAS-UNet dengan CA sangat efektif dalam menangani segmentasi pembuluh darah retina yang memiliki karakteristik tipis, kompleks, dan berkontras rendah.

E. Pelatihan Model

Pada pelatihan model, 40.000 *patch* data latih yang telah diperoleh selanjutnya dibagi menjadi *data training* dan *validation* dengan rasio 80:20. Pembagian ini bertujuan untuk memastikan bahwa model tidak hanya belajar dari data latih, tetapi juga dapat dievaluasi secara berkala menggunakan data *validation* guna memantau kemampuan generalisasi serta mencegah terjadinya *overfitting*. Proses pelatihan dilakukan menggunakan *optimizer Stochastic Gradient Descent* (SGD) dengan *learning rate* sebesar 0.01, yang dipilih karena kestabilannya dalam proses pembaruan bobot secara bertahap. Model dilatih selama 50 *epoch*, di mana setiap *epoch* merepresentasikan satu siklus penuh pelatihan terhadap seluruh *data training*.

Dalam penelitian ini, fungsi *loss* yang digunakan merupakan kombinasi antara *Binary Cross Entropy* (BCE) dan *Dice Loss*. BCE berfungsi untuk mengukur kesalahan klasifikasi pada setiap piksel dengan membandingkan nilai prediksi dan *ground truth*, sedangkan *Dice Loss* digunakan untuk mengoptimalkan kesesuaian antara area prediksi dan *ground truth*, khususnya dalam menangani ketidakseimbangan kelas antara pembuluh darah dan latar belakang. Kombinasi kedua fungsi *loss* ini bertujuan untuk meningkatkan akurasi segmentasi baik dari sisi klasifikasi piksel maupun kesesuaian bentuk objek. Dengan konfigurasi tersebut, diharapkan model mampu menghasilkan performa segmentasi yang optimal, khususnya dalam

mendeteksi struktur pembuluh darah retina yang berukuran kecil dan kompleks.

F. Evaluasi Model

Pada tahap evaluasi model, kinerja segmentasi yang dihasilkan dianalisis menggunakan *confusion matrix* sebagai dasar perhitungan berbagai metrik evaluasi. *Confusion matrix* membandingkan hasil prediksi model dengan *ground truth* pada tingkat piksel, yang diklasifikasikan ke dalam empat kategori, yaitu *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN). Berdasarkan nilai-nilai tersebut, digunakan beberapa metrik evaluasi untuk mengukur performa model secara komprehensif.

Akurasi digunakan untuk mengukur proporsi keseluruhan piksel yang berhasil diklasifikasikan dengan benar, yang dirumuskan sebagai:

$$\text{Accuracy} = \frac{TP+TN}{TP+TN+FP+FN} \quad (18)$$

Sensitivitas (*recall*) digunakan untuk mengukur kemampuan model dalam mendeteksi piksel pembuluh darah secara benar:

$$\text{Sensitivity} = \frac{TP}{TP+FN} \quad (19)$$

Sedangkan spesifisitas mengukur kemampuan model dalam mengenali piksel latar belakang dengan tepat:

$$\text{Specificity} = \frac{TN}{TN+FP} \quad (20)$$

Selanjutnya, *F1-Score* digunakan untuk menyeimbangkan antara nilai *precision* dan *recall*, sehingga memberikan gambaran performa yang lebih stabil:

$$\text{F1-Score} = \frac{2TP}{2TP+FP+FN} \quad (21)$$

Selain itu, digunakan juga metrik *Intersection over Union* (IoU) untuk mengukur tingkat kesesuaian antara area prediksi dan *ground truth*:

$$\text{IoU} = \frac{TP}{TP+FP+FN} \quad (22)$$


Penggunaan metrik ini bertujuan untuk memberikan evaluasi yang lebih menyeluruh, terutama dalam konteks segmentasi pembuluh darah retina yang memiliki ketidakseimbangan kelas antara objek (pembuluh darah) dan latar belakang. Dengan demikian, performa model tidak hanya dinilai dari ketepatan klasifikasi secara umum, tetapi juga dari kemampuannya dalam mendeteksi struktur pembuluh darah secara akurat dan konsisten.

4. HASIL DAN PEMBAHASAN

A. Input Citra

Input citra pada penelitian ini merupakan hasil ekstraksi *patch* berukuran 48×48 piksel yang diperoleh dari citra fundus retina setelah melalui tahap *preprocessing*. Tahap *preprocessing* dilakukan sebelum proses pelatihan model dengan tujuan meningkatkan kualitas visual citra, khususnya dalam memperjelas struktur pembuluh darah, meningkatkan kontras, serta menyesuaikan distribusi intensitas piksel agar proses ekstraksi fitur oleh model *deep learning* dapat berlangsung lebih optimal. Pada penelitian ini diterapkan tiga skenario *preprocessing* yang berbeda, yaitu *grayscale*, *grayscale* dengan

CLAHE, serta kombinasi *grayscale*, CLAHE, dan *gamma correction*.



Gambar 4. Hasil Preprocessing

Gambar 4 menunjukkan perbandingan hasil *preprocessing* pada salah satu patch citra retina dari dataset yang digunakan. Gambar 4 (a) merupakan salah satu citra fundus retina sebelum dilakukan *preprocessing*. Pada konfigurasi pertama, citra RGB dikonversi menjadi *grayscale* untuk menyederhanakan representasi warna menjadi satu kanal intensitas, sebagaimana ditunjukkan pada Gambar 4 (b). Meskipun tahap ini mampu mengurangi kompleksitas data, kontras antara pembuluh darah dan latar belakang masih relatif rendah, sehingga beberapa struktur vaskular halus belum terlihat secara optimal.

Pada konfigurasi kedua, citra *grayscale* diproses menggunakan metode *Contrast Limited Adaptive Histogram Equalization* (CLAHE) untuk meningkatkan kontras lokal, seperti ditunjukkan pada Gambar 4 (c). Penerapan CLAHE menghasilkan peningkatan visibilitas pembuluh darah, terutama pada area dengan intensitas rendah, tanpa menyebabkan peningkatan *noise* yang berlebihan. Struktur pembuluh darah menjadi lebih tegas dan mudah dibedakan dari latar belakang, sehingga beberapa berpotensi meningkatkan kemampuan model dalam mendeteksi fitur penting.


Selanjutnya, pada konfigurasi ketiga ditambahkan tahap *gamma correction* setelah CLAHE, sebagaimana ditunjukkan pada Gambar 4 (d). Proses ini bertujuan untuk menyesuaikan distribusi luminansi citra secara non-linear sehingga area gelap, khususnya pembuluh darah retina, menjadi lebih terang. Namun, secara visual terlihat bahwa peningkatan intensitas ini tidak selalu diikuti dengan peningkatan kualitas detail, karena pada beberapa bagian terjadi kecenderungan *over-enhancement* yang dapat mengurangi kejelasan struktur pembuluh kecil.

Secara keseluruhan, hasil *preprocessing* menunjukkan bahwa setiap konfigurasi menghasilkan karakteristik citra yang berbeda. CLAHE memberikan peningkatan kontras yang paling seimbang, sedangkan penambahan *gamma correction* cenderung mengubah distribusi intensitas secara lebih agresif. Perbedaan karakteristik ini menjadi faktor penting yang mempengaruhi performa model pada tahap pelatihan dan evaluasi, khususnya dalam mendeteksi pembuluh darah berukuran kecil dan bercabang kompleks.

B. Hasil Pelatihan


Proses pelatihan model dilakukan selama 50 *epoch* dengan menggunakan kombinasi *loss function* *Binary Cross Entropy* dan *Dice Loss*. Berdasarkan grafik *loss* yang dihasilkan, terlihat bahwa ketiga konfigurasi *preprocessing* menunjukkan pola konvergensi yang berbeda. Pada konfigurasi *Grayscale Only* yang ditunjukkan oleh Gambar 5, nilai *loss* awal relatif tinggi (train: 0.3370, val: 0.2660) dan mengalami penurunan signifikan pada 10 *epoch*

pertama. Setelah itu, penurunan *loss* berlangsung lebih lambat hingga mencapai nilai optimal pada *epoch* ke-49 dengan *validation loss* sebesar 0.1116. Pola kurva menunjukkan bahwa jarak antara training *loss* dan *validation loss* relatif kecil, yang mengindikasikan tidak adanya *overfitting* yang signifikan. Namun, fluktuasi kecil pada *validation loss* di beberapa *epoch* menandakan bahwa representasi fitur yang dihasilkan masih belum sepenuhnya stabil, khususnya dalam menangkap struktur pembuluh darah berukuran kecil.



Gambar 5. Grafik Loss Konfigurasi 1


Berbeda dengan itu, konfigurasi *Grayscale + CLAHE* pada Gambar 6 di bawah menunjukkan proses konvergensi yang lebih cepat dan stabil. Nilai awal *loss* sudah lebih rendah (val: 0.2112), yang mengindikasikan bahwa peningkatan kontras melalui CLAHE membantu model dalam mengenali pola sejak awal pelatihan. Penurunan *loss* berlangsung lebih halus dengan fluktuasi yang minimal, hingga mencapai nilai terbaik pada *epoch* ke-50 dengan *validation loss* sebesar 0.1083. Stabilitas ini menunjukkan bahwa distribusi intensitas citra yang lebih merata berkontribusi pada proses pembelajaran yang lebih efektif. Selain itu, jarak antara training dan *validation loss* tetap kecil sepanjang pelatihan, yang menandakan generalisasi model yang baik terhadap data validasi.



Gambar 6. Grafik Loss Konfigurasi 2

Sementara itu, konfigurasi *Grayscale + CLAHE + Gamma* pada Gambar 7 juga menunjukkan pola penurunan *loss* yang cukup baik, dengan nilai awal *validation loss* sebesar 0.2074 dan mencapai nilai terbaik sebesar 0.1100 pada *epoch* ke-50. Meskipun secara umum kurva terlihat stabil, terdapat fluktuasi yang sedikit lebih tinggi dibandingkan konfigurasi CLAHE saja, khususnya pada *epoch* menengah hingga akhir. Hal ini mengindikasikan bahwa penambahan *gamma correction* cenderung meningkatkan kompleksitas distribusi intensitas citra,

sehingga model memerlukan adaptasi lebih lanjut untuk mencapai konvergensi yang optimal.



Gambar 7. Grafik Loss Konfigurasi 3

Jika dibandingkan secara keseluruhan, konfigurasi Grayscale + CLAHE menghasilkan kurva *loss* yang paling stabil dan konvergen secara optimal. Hal ini ditunjukkan oleh penurunan *loss* yang konsisten, minimnya fluktuasi, serta nilai *validation loss* akhir yang paling rendah di antara ketiga konfigurasi. Sebaliknya, konfigurasi tanpa peningkatan kontras (Grayscale Only) menunjukkan proses pembelajaran yang lebih lambat, sedangkan penambahan *gamma correction* tidak memberikan peningkatan signifikan terhadap stabilitas pelatihan. Temuan ini memperkuat bahwa kualitas *preprocessing*, khususnya dalam meningkatkan kontras lokal citra retina, memiliki pengaruh langsung terhadap efisiensi pembelajaran model deep learning.

C. Hasil Segmentasi

Hasil segmentasi pembuluh darah retina pada penelitian ini dievaluasi menggunakan pendekatan kuantitatif melalui *confusion matrix* serta metrik turunan yang meliputi akurasi, sensitivitas, spesifisitas, F1-score, dan *Intersection over Union* (IoU). Evaluasi dilakukan terhadap tiga konfigurasi *preprocessing*, yaitu Grayscale Only, Grayscale + CLAHE, dan Grayscale + CLAHE + Gamma Correction. Analisis ini bertujuan untuk mengidentifikasi pengaruh strategi peningkatan kontras terhadap performa segmentasi, khususnya dalam mendeteksi struktur pembuluh darah yang halus dan berukuran kecil.

Tabel 1. Hasil Evaluasi Metrik

Konfigurasi	Metrik (%)				
	Acc	Sen	Spe	F1-Score	IoU
Grayscale	97.11	79.80	98.65	81.41	68.73
Grayscale + CLAHE	97.09	81.46	98.49	81.63	69.01
Grayscale + CLAHE + Gamma	97.08	78.89	98.72	81.12	68.32


Berdasarkan Tabel 1 hasil pengujian pada 28 citra uji, terlihat bahwa seluruh konfigurasi *preprocessing* menghasilkan performa yang relatif tinggi dengan nilai akurasi di atas 97%. Namun, metrik akurasi tidak sepenuhnya merepresentasikan kualitas segmentasi karena adanya ketidakseimbangan kelas antara piksel pembuluh darah dan latar belakang. Oleh karena itu, analisis difokuskan pada F1-score, IoU, dan sensitivitas yang

lebih sensitif terhadap performa segmentasi objek kecil.

Konfigurasi Grayscale + CLAHE menghasilkan performa terbaik dengan F1-score sebesar 81.63% dan IoU sebesar 69.01%, yang menunjukkan peningkatan dibandingkan Grayscale Only (F1: 81.41%, IoU: 68.73%). Peningkatan ini mengindikasikan bahwa CLAHE mampu memperbaiki kontras lokal sehingga fitur pembuluh darah lebih mudah dipelajari oleh model.


Sebaliknya, penambahan *gamma correction* pada konfigurasi Grayscale + CLAHE + Gamma justru menurunkan performa, dengan F1-score menjadi 81.12% dan IoU 68.32%. Hal ini menunjukkan bahwa meskipun *gamma correction* dapat meningkatkan pencahayaan global, efeknya cenderung mereduksi detail halus atau menyebabkan *over-enhancement* pada area tertentu.

Dari sisi sensitivitas, konfigurasi Grayscale + CLAHE juga menunjukkan nilai tertinggi (81.46%), yang berarti model lebih mampu mendeteksi piksel pembuluh darah (*true positive*). Namun, spesifisitas sedikit menurun dibandingkan konfigurasi lain, yang menunjukkan adanya peningkatan kesalahan klasifikasi pada piksel latar belakang. Hasil evaluasi model segmentasi pembuluh darah retina dianalisis lebih lanjut menggunakan *confusion matrix* untuk memahami distribusi prediksi terhadap kelas positif (pembuluh darah) dan negatif (latar belakang) pada setiap konfigurasi *preprocessing*.




Gambar 8. Confusion Matrix Konfigurasi 1

Pada *confusion matrix* konfigurasi Grayscale Only Gambar 8, menunjukkan bahwa model menghasilkan nilai *true negative* (TN) sebesar 8,379,729 dan *true positive* (TP) sebesar 591,794, dengan *false negative* (FN) mencapai 152,810. Nilai FN yang relatif tinggi menunjukkan bahwa masih terdapat sejumlah pembuluh darah yang tidak terdeteksi, khususnya pada struktur yang berukuran kecil atau memiliki kontras rendah. Meskipun demikian, nilai *false positive* (FP) yang rendah (114,547) mengindikasikan bahwa model cukup baik dalam membedakan latar belakang, sehingga menghasilkan spesifisitas yang tinggi. Hal ini menunjukkan bahwa tanpa peningkatan kontras, model cenderung bersifat konservatif, yaitu lebih berhati-hati dalam mengklasifikasikan piksel sebagai pembuluh darah.



Gambar 9. Confusion Matrix Konfigurasi 2

Pada konfigurasi *confusion matrix* Grayscale + CLAHE Gambar 9, terjadi peningkatan performa yang signifikan pada deteksi pembuluh darah. Hal ini ditunjukkan dengan meningkatnya nilai TP menjadi 603,779 serta menurunnya FN menjadi 140,825. Peningkatan ini mengindikasikan bahwa metode CLAHE mampu memperbaiki kontras lokal citra sehingga struktur pembuluh darah, terutama yang berukuran kecil, menjadi lebih jelas dan lebih mudah dikenali oleh model. Meskipun nilai FP sedikit meningkat menjadi 128,415, peningkatan ini masih dalam batas yang dapat diterima karena berkontribusi terhadap peningkatan sensitivitas dan F1-Score secara keseluruhan. Dengan demikian, konfigurasi ini menunjukkan keseimbangan yang optimal antara kemampuan mendeteksi pembuluh darah dan mempertahankan akurasi klasifikasi latar belakang.



Gambar 10. Confusion Matrix Konfigurasi 3


Pada Gambar 10, konfigurasi Grayscale + CLAHE + Gamma Correction, terlihat adanya penurunan kemampuan model dalam mendeteksi pembuluh darah. Hal ini tercermin dari meningkatnya nilai FN menjadi 160,579 serta menurunnya TP menjadi 584,025. Meskipun konfigurasi ini menghasilkan nilai TN tertinggi (8,385,357) dan FP terendah (108,919), yang menunjukkan kemampuan sangat baik dalam mengenali latar belakang, peningkatan FN mengindikasikan bahwa banyak pembuluh darah yang tidak terdeteksi. Kondisi ini menunjukkan bahwa penambahan *gamma correction* cenderung menyebabkan hilangnya detail halus pada citra, sehingga mengurangi sensitivitas model terhadap struktur pembuluh darah yang tipis.

Secara keseluruhan, analisis *confusion matrix* menunjukkan bahwa peningkatan performa pada konfigurasi Grayscale + CLAHE tidak hanya tercermin dari nilai metrik evaluasi yang lebih tinggi, tetapi juga dari distribusi prediksi yang lebih baik, yaitu meningkatnya jumlah deteksi benar pada pembuluh darah (TP) serta berkurangnya kesalahan kehilangan objek (FN). Sebaliknya, penambahan *gamma correction* meskipun meningkatkan spesifisitas, justru mengorbankan sensitivitas model. Oleh karena itu, dalam konteks segmentasi pembuluh darah retina yang memiliki karakteristik objek kecil dan kontras rendah, kemampuan mendeteksi piksel positif secara akurat menjadi faktor yang lebih krusial dibandingkan sekadar mempertahankan akurasi global yang tinggi.

Selain evaluasi numerik, perbandingan visual hasil segmentasi juga menunjukkan perbedaan yang jelas antar konfigurasi. Pada Grayscale Only, segmentasi sudah cukup stabil, namun beberapa pembuluh kecil masih terputus atau tidak terdeteksi. Konfigurasi Grayscale + CLAHE menghasilkan segmentasi yang lebih lengkap dan kontinu, terutama pada pembuluh berukuran kecil, karena peningkatan kontras lokal membantu model mengenali batas pembuluh dengan lebih baik. Sementara itu, pada Grayscale + CLAHE + Gamma, meskipun citra tampak lebih terang, detail pembuluh kecil cenderung hilang dan hasil segmentasi menjadi lebih kasar. Untuk memperjelas perbandingan tersebut, hasil segmentasi ditampilkan pada Tabel 2.

Tabel 2. Citra Hasil Segmentasi

Citra	Ground Truth	Konfigurasi		
		Grayscale	Grayscale + CLAHE	Grayscale + CLAHE + Gamma



D. Analisis Pengaruh Contrast Enhancement terhadap Segmentasi

Penggunaan teknik *contrast enhancement* dalam tahap *preprocessing* terbukti memberikan pengaruh signifikan terhadap kinerja model dalam melakukan segmentasi pembuluh darah retina. Hal ini disebabkan oleh karakteristik citra retina yang umumnya memiliki kontras rendah, terutama pada pembuluh darah berukuran kecil, sehingga diperlukan peningkatan kualitas visual agar fitur dapat diekstraksi secara optimal oleh model.

Berdasarkan hasil penelitian, penerapan metode CLAHE (*Contrast Limited Adaptive Histogram Equalization*) mampu meningkatkan kualitas segmentasi secara konsisten. CLAHE bekerja dengan memperbaiki kontras lokal pada citra, sehingga struktur pembuluh darah menjadi lebih menonjol dibandingkan latar belakang. Dampak dari peningkatan kontras ini terlihat pada meningkatnya nilai sensitivitas, F1-Score, dan IoU, yang menunjukkan bahwa model lebih mampu mendeteksi piksel pembuluh darah secara akurat. Selain itu, hasil *confusion matrix* juga menunjukkan penurunan nilai *false negative*, yang mengindikasikan berkurangnya pembuluh darah yang tidak terdeteksi, khususnya pada struktur yang tipis.

Namun demikian, peningkatan kontras juga memiliki konsekuensi terhadap kesalahan klasifikasi. Pada konfigurasi dengan CLAHE, terjadi sedikit peningkatan nilai *false positive*, yang menunjukkan bahwa beberapa area latar belakang mulai terdeteksi sebagai pembuluh darah. Meskipun demikian, peningkatan ini masih dalam batas yang dapat diterima karena memberikan kontribusi lebih besar terhadap peningkatan sensitivitas model secara keseluruhan.

Sebaliknya, penambahan *gamma correction* setelah CLAHE tidak memberikan peningkatan performa, bahkan cenderung menurunkan kualitas segmentasi. Meskipun *gamma correction* dapat meningkatkan pencahayaan global citra dan menghasilkan nilai spesifisitas yang lebih tinggi, metode ini menyebabkan hilangnya detail halus pada pembuluh darah kecil. Hal ini tercermin dari meningkatnya nilai *false negative* serta menurunnya sensitivitas dan IoU. Dengan kata lain, model menjadi lebih baik dalam mengenali latar belakang, namun kurang mampu mendeteksi objek utama yang menjadi fokus segmentasi.

Secara keseluruhan, dapat disimpulkan bahwa teknik *contrast enhancement* yang tepat, khususnya CLAHE, mampu meningkatkan performa segmentasi

dengan memperjelas struktur pembuluh darah dan mengurangi kehilangan informasi penting. Namun, penerapan metode tambahan seperti *gamma correction* perlu dilakukan secara hati-hati karena berpotensi menurunkan sensitivitas model terhadap detail objek yang kecil. Oleh karena itu, keseimbangan antara peningkatan kontras dan preservasi informasi citra menjadi faktor kunci dalam menghasilkan segmentasi yang optimal.

5. KESIMPULAN

Berdasarkan hasil penelitian, model CAS-UNet dengan mekanisme *Coordinate Attention* mampu memberikan kinerja yang baik dalam segmentasi pembuluh darah retina, ditunjukkan dengan nilai akurasi di atas 97% serta F1-score dan IoU yang cukup tinggi pada seluruh konfigurasi. Dari sisi *preprocessing*, konfigurasi Grayscale + CLAHE terbukti memberikan hasil terbaik dengan F1-score sebesar 81.6263% dan IoU sebesar 69.0131%, karena mampu meningkatkan kontras lokal sehingga pembuluh darah, khususnya yang berukuran kecil, dapat terdeteksi dengan lebih baik. Analisis *confusion matrix* juga menunjukkan peningkatan *true positive* dan penurunan *false negative*, yang menandakan peningkatan sensitivitas model. Sebaliknya, penambahan *gamma correction* cenderung menurunkan performa karena menyebabkan hilangnya detail halus, sehingga meningkatkan jumlah pembuluh darah yang tidak terdeteksi.

Secara keseluruhan, penelitian ini menegaskan bahwa pemilihan teknik *contrast enhancement* pada *preprocessing* yang tepat berperan penting dalam meningkatkan kualitas segmentasi, dengan CLAHE sebagai metode yang paling optimal dalam menjaga keseimbangan antara peningkatan kontras dan preservasi detail citra. Untuk penelitian selanjutnya, disarankan mengeksplorasi metode peningkatan kontras lain yang lebih adaptif dan melakukan pengujian pada dataset dengan variasi yang lebih beragam juga diperlukan untuk menguji generalisasi model terhadap kondisi citra yang berbeda.

6. DAFTAR PUSTAKA

- Agustianto, K., Choirunnisa, S., Afianah, N., & Huda, C. (2022). Deteksi Pembuluh Darah pada Citra Fundus Retina Menggunakan Gabungan Metode Segmentasi Pembuluh Darah Lebar dan Tipis. *Jurnal Teknologi Informasi Dan Terapan*, 9(1), 41–46. <https://doi.org/10.25047/jtit.v9i1.276>
- Amir, S. B. H., Akbar, S. N. A. F., Hendra, H.,

- Anwar, A. M., & Sulfayanti, S. (2023). Deteksi Citra X-Ray Paru-Paru Terinfeksi COVID-19 dengan Algoritma CNN berbasis Aplikasi Web. *Informatika Mulawarman: Jurnal Ilmiah Ilmu Komputer*, 17(1), 37–41.
- Ariadi, K., Anggraeny, F. T., & Sihananto, A. N. (2024). Perbandingan Performa Metode SVM dan KNN dalam Mengklarifikasi Citra Infeksi Telinga. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 8(6), 11342–11347.
- Attaqwa, S. I., Puspaningrum, E. Y., & Saputra, W. S. J. (2024). Implementasi Contrast Limited Adaptive Histogram Equalization dalam Pengolahan Citra pada Algoritma Generative Adversarial Network. *Jurnal Informatika Dan Teknik Elektro Terapan*, 12(3S1).
- Barman, S., Hoppe, A., Fraz, M. M., Uyyanonvara, B., Rudnicka, A. R., & Owen, C. G. (2012). CHASE_DB1 retinal vessel reference dataset. <https://doi.org/10.1109/TBME.2012.2205687>
- Chazar, C., Adli, M. A., Pardede, J., & Ichwan, M. (2025). Pendekatan Augmentasi Citra Fundus pada Model EfficientNet untuk Klasifikasi Tingkat Keparahan Retinopati Diabetik dengan Dataset Tidak Seimbang. *MIND (Multimedia Artificial Intelligent Networking Database) Journal*, 10(2), 180–194.
- Das, S., Chakraborty, S., Mishra, M., & Majumder, S. (2024). Assessment of retinal blood vessel segmentation using U-Net model: A deep learning approach. *Franklin Open*, 8(January), 100143. <https://doi.org/10.1016/j.fraope.2024.100143>
- Desiani, A., Zayanti, D. A., Primartha, R., Efriliyanti, F., & Andriani, N. A. C. (2021). Variasi Thresholding untuk Segmentasi Pembuluh Darah Citra Retina. *Jurnal Edukasi Dan Penelitian Informatika (JEPIN)*, 7(2), 255. <https://doi.org/10.26418/jp.v7i2.47205>
- Galgani, F. (2024). What Is Gamma Correction? Retrieved from Baeldung website: <https://www.baeldung.com/cs/gamma-correction-brightness>
- Herawati, I. A. M., Sindu Putra, I. B. K., & Suyanta, I. W. (2023). Meningkatkan Literasi Lingkungan Anak Usia 5-6 Tahun Melalui Proyek Eco Enzyme. *Kumara Cendekia*, 11(3), 251. <https://doi.org/10.20961/kc.v11i3.76862>
- Hernandez-Gutierrez, F. D., Avina-Bravo, E. G., Ibarra-Manzano, M. A., Ruiz-Pinales, J., Ovalle-Magallanes, E., & Avina-Cervantes, J. G. (2025). Retinal Vessel Segmentation Based on a Lightweight U-Net and Reverse Attention. *Mathematics*, Vol. 13, p. 2203. <https://doi.org/10.3390/math13132203>
- Hidayat, J., & Fitriani, A. (2025). Perbandingan Metode Power Law Dengan Contrast Limited Adaptive Histogram Equalization (Clahe) Pada Perbaikan Kualitas Citra Satelit. *RELE (Rekayasa Elektrikal Dan Energi): Jurnal Teknik Elektro*, 8(1), 301–306.
- Hou, Q., Zhou, D., & Feng, J. (2021). Coordinate Attention for Efficient Mobile Network Design. *Conference on Computer Vision and Pattern Recognition (CVPR)*, 13713–13722.
- Kabiraj, A., Pal, D., Ganguly, D., Chatterjee, K., & Roy, S. (2023). Number plate recognition from enhanced super-resolution using generative adversarial network. *Multimedia Tools and Applications*, 82(9), 13837–13853.
- Kande, G. B., Nalluri, M. R., Manikandan, R., Cho, J., & Veerappampalayam Easwaramoorthy, S. (2025). Multi scale multi attention network for blood vessel segmentation in fundus images. *Scientific Reports*, 15(1), 3438.
- Kemkes. (2023). Pedoman Nasional Pelayanan Kedokteran: Tata Laksana Retinopati Diabetika. *Kementerian Kesehatan Republik Indonesia*, 1–36.
- Li, Z., Jia, M., Yang, X., & Xu, M. (2021). Blood Vessel Segmentation of Retinal Image Based on Dense-U-Net Network. *Micromachines*, 12, 1478. <https://doi.org/https://doi.org/10.3390/mi12121478>
- Liu, C., Gu, P., & Xiao, Z. (2022). Multiscale U-Net with Spatial Positional Attention for Retinal Vessel Segmentation. *Journal of Healthcare Engineering*, 2022. <https://doi.org/10.1155/2022/5188362>
- Mudjirahardjo, P. (2024). The effect of grayscale, CLAHE image and filter images in convolution process. *Int. J. Adv. Multidiscip. Res. Stud*, 4(3), 943–946.
- PODDAR, D. K., BANERJEE, P., BANERJEE, A., SAHA ROY, R., & PAUL, R. (2026). Digital Image Transformation and Enhancement Using Blurring, Cartoonization, Grayscale Conversion, and Edge Detection in Python. *Cartoonization, Grayscale Conversion, and Edge Detection in Python (February 21, 2026)*.
- Qi, Y., Yang, Z., Sun, W., Lou, M., Lian, J., Zhao, W., ... Ma, Y. (2022). A comprehensive overview of image enhancement techniques. *Archives of Computational Methods in Engineering*, 29(1), 583–607.
- Research Software Engineers. (2012). DRIVE: Digital Retinal Images for Vessel Extraction. Retrieved from Grand Challenge website: <https://drive.grand-challenge.org/>
- Wardhani, A. S., Anggraeny, F. T., & Rizki, A. M. (2024). Penerapan Model Hibrida Cnn-Knn Untuk Klasifikasi Penyakit Mata. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 8(3), 3662–

- 3667.
- Yao, T., Qu, C., Liu, Q., Deng, R., Tian, Y., Xu, J., ... Fogo, A. B. (2021). Compound figure separation of biomedical images with side loss. *MICCAI Workshop on Deep Generative Models*, 173–183. Springer.
- You, Z., Yu, H., Xiao, Z., Peng, T., & Wei, Y. (2023a). CAS-UNet: a retinal segmentation method based on attention. *Electronics*, 12(15), 3359.
- You, Z., Yu, H., Xiao, Z., Peng, T., & Wei, Y. (2023b). CAS-UNet: A Retinal Segmentation Method Based on Attention. *Electronics (Switzerland)*, 12(15).
- <https://doi.org/10.3390/electronics12153359>
- Yu, Y., Wang, C., Fu, Q., Kou, R., Huang, F., Yang, B., ... Gao, M. (2023). Techniques and challenges of image segmentation: A review. *Electronics*, 12(5), 1199.
- Zhao, M., Liu, Q., Jha, A., Deng, R., Yao, T., Mahadevan-Jansen, A., ... Huo, Y. (2021). VoxelEmbed: 3D instance segmentation and tracking with voxel embedding based deep learning. *International Workshop on Machine Learning in Medical Imaging*, 437–446. Springer.