

Implementasi *Deep Learning* untuk Transformasi Spektrum Warna Citra Digital dalam Mendukung Aksesibilitas Pengguna Buta Warna

1st Jerdin Vanesa

Program Studi S1 Informatika
Universitas Telkom Surabaya
Surabaya, Indonesia

jerdinvanesa@student.telkomuniversity.ac.id

2nd Ardian Yusuf Wicaksono, S.Kom.,
M.Kom.

Program Studi S1 Informatika
Universitas Telkom Surabaya
Surabaya, Indonesia

ardiany@telkomuniversity.ac.id

3rd Vessa Rizky Oktavia, S.Kom.,
M.Kom.

Program Studi S1 Informatika
Universitas Telkom Surabaya
Surabaya, Indonesia

vessarizky@telkomuniversity.ac.id

Abstrak — Buta warna parsial seperti *protanomaly* dan *deutanomaly* menyebabkan penderitanya mengalami kesulitan dalam membedakan warna tertentu, sehingga berdampak pada berbagai aktivitas visual sehari-hari. Penelitian ini bertujuan membangun sistem berbasis *deep learning* yang mampu mendeteksi jenis buta warna parsial secara otomatis serta melakukan transformasi warna agar citra lebih mudah dikenali penderita. Metode yang diusulkan terdiri atas dua tahap utama, yaitu deteksi jenis buta warna menggunakan Convolutional Neural Network dan transformasi warna menggunakan model generatif. Pada tahap deteksi, digunakan tiga arsitektur CNN, yaitu SqueezeNet, MobileNetV2, dan EfficientNet-B0. Hasil pengujian menunjukkan SqueezeNet memberikan performa terbaik dengan akurasi 96%, melampaui dua arsitektur lainnya. Hal ini menunjukkan arsitektur ringan lebih efektif menangkap pola warna mikro hasil simulasi buta warna. Pada tahap transformasi warna, diterapkan arsitektur U-Net dan Autoencoder dengan memanfaatkan paired dataset hasil daltonisasi. Untuk meningkatkan representasi visual, penelitian ini mengintegrasikan *monogram image processing* yang menambahkan informasi *brightness*, *edge*, dan *contrast* menjadi citra *multi-channel*. Evaluasi menunjukkan U-Net berbasis monogram menghasilkan kualitas terbaik dengan nilai PSNR di atas 36, SSIM mendekati 0.97, serta Delta E2000 rendah pada *protanomaly* dan *deutanomaly*. Dengan demikian, integrasi CNN ringan, U-Net, dan *monogram image processing* terbukti efektif, adaptif, dan berpotensi diterapkan secara *real-time* untuk meningkatkan aksesibilitas visual penderita buta warna parsial.

Kata kunci—Buta warna parsial, konversi warna, deteksi warna, *deep learning*

I. PENDAHULUAN

Warna merupakan elemen fundamental dalam persepsi visual manusia yang berperan penting dalam menyampaikan informasi, membangun makna, serta mendukung aktivitas navigasi dan pengambilan keputusan dalam kehidupan sehari-hari. Namun, tidak semua individu mampu melihat spektrum warna secara utuh. Gangguan persepsi warna atau

Color Vision Deficiency (CVD), yang umum dikenal sebagai buta warna, merupakan kondisi visual yang membatasi kemampuan seseorang dalam membedakan warna tertentu, khususnya merah, hijau, dan biru. Berdasarkan data [1], lebih dari 200 juta orang di dunia mengalami buta warna, dengan lebih dari 99% kasus termasuk dalam kategori *red-green color blindness*. Di Indonesia, prevalensi buta warna mencapai 0,7% [2], yang berdampak signifikan terhadap akses Pendidikan dan peluang kerja di bidang-bidang yang menuntut kemampuan persepsi warna yang baik, seperti kedokteran, teknik, desain grafis, dan lain sebagainya.

Dalam konteks pengolahan citra digital dan pengembangan aplikasi berbasis visual, warna menjadi dimensi krusial dalam representasi dan pemrosesan informasi. Sayangnya, sebagian besar sistem digital saat ini belum dirancang secara inklusif untuk mendukung pengguna dengan keterbatasan penglihatan warna. [3] melaporkan bahwa hanya sekitar 10% aplikasi digital yang memperhatikan aspek aksesibilitas warna, sehingga menciptakan ketimpangan dalam penyampaian informasi visual. Kondisi ini menjadi semakin kompleks bagi penderita buta warna parsial, khususnya *protanomaly* dan *deutanomaly*, yang mengalami gangguan pada reseptor warna merah dan hijau di retina. Akibatnya, warna-warna seperti merah, hijau, coklat, dan oranye sering kali tampak kusam, serupa, atau bahkan menyatu, meskipun secara nilai RGB memiliki perbedaan yang signifikan. Dampak dari keterbatasan ini tidak hanya bersifat estetis, tetapi juga berpotensi membahayakan, seperti kesalahan dalam membaca lampu lalu lintas yang dapat berujung pada risiko keselamatan.

Berbagai pendekatan telah dikembangkan untuk membantu penderita buta warna, seperti pengguna *color filter*, *simulation-based recoloring*, dan metode klasifikasi warna sederhana. Namun, sebagian besar solusi tersebut masih bersifat umum dan belum mempertimbangkan variasi tingkat keparahan serta karakteristik individual penderita. [4] menegaskan bahwa teknologi rekayasa warna digital saat ini

cenderung menerapkan pendekatan *one size fits all*, sehingga efektivitasnya masih terbatas. Selain itu, sebagian besar sistem belum mampu mengintegrasikan proses deteksi jenis buta warna dengan mekanisme konversi warna yang adaptif dan berjalan secara *real-time*.

Seiring dengan perkembangan teknologi kecerdasan buatan, khususnya *deep learning* dengan pendekatan berbasis *Convolutional Neural Network* (CNN) menunjukkan potensi besar dalam klasifikasi citra dan pemahaman pola visual. Arsitektur CNN ringan seperti MobileNetV2, EfficientNet-B0, dan SqueezeNet telah terbukti efisien dalam mengenali fitur warna dengan kebutuhan komputasi yang relative rendah. Di sisi lain, teknik *image-to-image translation* berbasis U-Net dan Autoencoder memungkinkan transformasi warna citra secara lebih halus dan kontekstual. Integrasi metode *Monogram Image Processing* sebagai teknik segmentasi warna juga berperan penting dalam memetakan ulang warna secara lebih akurat sebelum proses konversi dilakukan, sehingga hasil transformasi dapat disesuaikan dengan persepsi pengguna.

Berdasarkan permasalahan tersebut. Penelitian ini bertujuan untuk membangun sistem berbasis *deep learning* yang tidak hanya mampu mendeteksi warna-warna yang sulit dibedakan oleh penderita buta warna parsial, khususnya *protanomaly* dan *deuteranomaly*, tetapi juga melakukan konversi warna secara adaptif agar lebih mudah dikenali. Dengan mengintegrasikan CNN untuk deteksi, *Monogram Image Processing* untuk segmentasi, serta model U-Net dan Autoencoder untuk transformasi warna, sistem yang diusulkan diharapkan mampu memberikan pengalaman visual yang lebih inklusif dan personal. Pendekatan ini diharapkan dapat membantu penderita buta warna parsial dalam mengakses informasi berbasis warna secara lebih aman, akurat, dan efektif dalam berbagai konteks kehidupan sehari-hari.

II. KAJIAN TEORI

A. Teori Buta Warna

Buta warna atau *Color Vision Deficiency* (CVD) merupakan gangguan persepsi warna akibat kelainan pada sel kerucut (*cone cells*) di retina, khususnya L-cone (merah) dan M-cone (hijau), yang menyebabkan individu kesulitan membedakan warna tertentu secara normal. Kondisi ini umumnya bersifat genetik dan berdampak langsung pada persepsi visual sehari-hari [5].

Buta warna parsial termasuk dalam kategori *trichromacy anomaly*, di mana ketiga pigmen kerucut masih ada, tetapi sensitivitas salah satunya mengalami pergeseran. Dua tipe yang paling umum adalah *protanomaly*, yaitu gangguan sensitivitas pigmen merah (L-cone), dan *deuteranomaly*, yaitu gangguan pada pigmen hijau (M-cone). Kedua kondisi ini menyebabkan warna merah dan hijau beserta turunannya tampak serupa atau redup. Dalam konteks citra digital, gangguan ini mengakibatkan hilangnya kontras dan perbedaan warna, sehingga informasi visual berbasis warna menjadi sulit diakses oleh penderita CVD.

B. Teori Klasifikasi dan Arsitektur CNN

Convolutional Neural Network (CNN) merupakan arsitektur *deep learning* yang dirancang khusus untuk pengolahan citra digital melalui ekstraksi fitur spasial secara hierarkis. CNN terdiri dari lapisan konvolusi, aktivasi, *pooling*, dan *fully connected* yang memungkinkan model mengenali pola visual kompleks secara efisien [6].

Penelitian ini memanfaatkan tiga arsitektur CNN ringan, yaitu MobileNetV2, EfficientNet-B0, dan SqueezeNet, yang dipilih karena efisiensi komputasi dan performa tinggi pada tugas klasifikasi citra. MobileNetV2 menggunakan *inverted residual* dan *linear bottleneck* untuk mengurangi jumlah parameter [7], EfficientNet-B0 menerapkan *compound scaling* untuk menyeimbangkan kedalaman dan resolusi jaringan [8], sedangkan SqueezeNet memanfaatkan *fire module* untuk menghasilkan model berukuran kecil dengan akurasi kompetitif [9]. Ketiga model digunakan sebagai pembandingan untuk menentukan arsitektur paling optimal dalam mendeteksi jenis buta warna parsial.

C. Teori Konversi Warna dan Arsitektur Model

Konversi warna bertujuan untuk mentransformasikan citra ke skema warna yang lebih mudah dibedakan oleh penderita CVD tanpa menghilangkan konteks visual. Pendekatan *image-to-image translation* memungkinkan pemetaan citra dari domain warna asli ke domain warna kompensasi secara otomatis [4].


Penelitian ini mengombinasikan *monogram image processing* sebagai tahap awal untuk menyederhanakan representasi visual dan meningkatkan segmentasi warna, dengan model U-Net dan Autoencoder sebagai arsitektur utama konversi warna. U-Net mempertahankan detail struktur melalui *skip connection* [10], sedangkan Autoencoder mempelajari representasi laten untuk menghasilkan citra hasil konversi yang tetap natural. Integrasi ini diharapkan mampu meningkatkan keterbacaan warna dan menjaga struktur visual penting bagi penderita buta warna parsial.

Simulasi dan konversi warna dilakukan menggunakan ruang warna LMS yang merepresentasikan respons biologis sel kerucut mata manusia. Transformasi RGB-LMS digunakan untuk mensimulasikan persepsi penderita *protanomaly* dan *deuteranomaly* melalui matriks *daltonization*, kemudian dikembalikan ke RGB untuk ditampilkan.

Evaluasi performa sistem klasifikasi dilakukan menggunakan akurasi, *precision*, *recall*, dan *F1-score* [11]. Sementara itu, kualitas konversi warna dievaluasi menggunakan Delta E2000 untuk perbedaan perseptual warna [12], *Structural Similarity Index* (SSIM) untuk kesamaan struktur visual [13], dan *Peak Signal-to-Noise Ratio* (PSNR) untuk kualitas rekonstruksi citra [14].

D. Penulisan Rumus dan Persamaan

Penelitian ini, terdapat rumus dan persamaan yang digunakan untuk mendukung proses simulasi buta warna parsial, konversi warna, pelatihan model *deep learning*, serta evaluasi performa.



GAMBAR 1

(REPRESENTASI RUANG WARNA (A) CIELAB, (B) RGB, (C) LMS) [15].

Ruang warna LMS merepresentasikan respon tiga sel kerucut pada retina mata manusia: *Long* (L), *Medium* (M), dan *Short* (S) pada simulasi Daltonize. Transformasi dari RGB ke ruang tristimulus XYZ dapat dinyatakan dalam bentuk matriks:

$$\begin{bmatrix} X \\ Y \\ Z \end{bmatrix} = M_{RGB \rightarrow XYZ} \begin{bmatrix} R \\ G \\ B \end{bmatrix} \quad (1)$$

dengan matriks konversi:

$$M_{RGB \rightarrow XYZ} = \begin{bmatrix} l_{11} & l_{12} & l_{13} \\ l_{21} & l_{22} & l_{23} \\ l_{31} & l_{32} & l_{33} \end{bmatrix} \quad (2)$$

kemudian XYZ diubah ke ruang LMS menggunakan matriks Hunt-Pointer-Estevéz (HPE):

$$\begin{bmatrix} L \\ M \\ S \end{bmatrix} = M_{XYZ \rightarrow LMS} \cdot \begin{bmatrix} X \\ Y \\ Z \end{bmatrix} \quad (3)$$

dengan:

$$M_{RGB \rightarrow LMS} = \begin{bmatrix} l_{11} & l_{12} & l_{13} \\ l_{21} & l_{22} & l_{23} \\ l_{31} & l_{32} & l_{33} \end{bmatrix} \quad (4)$$

sehingga konversi langsung RGB ke LMS Adalah:

$$M_{RGB \rightarrow LMS} = M_{XYZ \rightarrow LMS} \cdot M_{RGB \rightarrow XYZ} \quad (5)$$

dan transformasinya:

$$\begin{bmatrix} L \\ M \\ S \end{bmatrix} = M_{RGB \rightarrow LMS} \begin{bmatrix} R \\ G \\ B \end{bmatrix} \quad (6)$$

Dimana:

R, G, B = Komponen warna *input* dalam format *Red*, *Green*, dan *Blue* yang dinormalisasi ke rentang 0-1.

L, M, S = Hasil konversi intensitas respons sel kerucut L, M, dan S yang menyerupai persepsi biologis mata manusia terhadap warna.

l_{ij} = Elemen dari matriks transformasi (3×3) yang mengubah RGB menjadi LMS.

Matriks ini sebagai hasil kalibrasi dari eksperimen sensitivitas retina manusia terhadap warna. Nilai-nilainya ditentukan dari model penglihatan yang dipakai untuk simulasi buta warna.

Model daltonize simulasi buta warna menggunakan matriks transformasi untuk mensimulasikan persepsi warna bagi penderita buta warna aparsial, khususnya protanomaly dan deuteranomaly.

Persamaan umum simulasi buta warna parsial sebagai berikut:

$$LMS' = M_{CB} \cdot LMS \quad (7)$$

protanomaly (hilangnya channel L)

$$M_P = \begin{bmatrix} l_{11} & l_{12} & l_{13} \\ l_{21} & l_{22} & l_{23} \\ l_{31} & l_{32} & l_{33} \end{bmatrix} \quad (8)$$

deuteranomaly (hilangnya channel M)

$$M_D = \begin{bmatrix} l_{11} & l_{12} & l_{13} \\ l_{21} & l_{22} & l_{23} \\ l_{31} & l_{32} & l_{33} \end{bmatrix} \quad (9)$$

citra simulasi kembali dikembalikan ke RGB menggunakan:

$$RGB_{sim} = M_{LMS \rightarrow RGB} \cdot LMS' \quad (10)$$

dengan:

$$M_{LMS \rightarrow RGB} = M_{LMS \rightarrow RGB}^{-1} \quad (11)$$

Dimana:

LMS' = Hasil transformasi dari LMS normal.

RGB_{sim} = Hasil transformasi dari RGB normal.

M_{CB} = Matriks simulasi buta warna (p, d).

LMS = Vektor warna hasil warna LMS normal.

Rumus ini berguna mensimulasikan bagaimana seorang penderita buta warna parsial melihat warna, dengan cara mengalihkan vector asli LMS dengan matriks transformasi yang sesuai T_{cud} . Sehingga dapat melatih sistem konversi warna agar menghasilkan citra yang bisa dilihat dengan baik oleh penderita buta warna.

Perhitungan *error* yaitu informasi warna yang hilang, untuk mengembalikan informasi warna yang hilang, error diproyeksikan ulang ke bagian spektrum yang masih mampu dilihat oleh penderita CVD menggunakan matriks *error* modifikasi:

$$LMS' = M_{CB} \cdot LMS \quad (12)$$

hasil akhir daltonized:

$$RGB_{daltonized} = RGB \cdot E' \quad (13)$$

dan akhirnya dilakukan pembatasan nilai sebagai *clipping*:

$$RGB_{out} = \min(1, \max(0, RGB_{daltonized})) \quad (14)$$

Setelah itu, masuk ke sebelum dan sesudah transformasi dilakukan koreksi gamma RGB:

gamma correction:

$$C_{linear} = \begin{cases} \frac{C}{x}, & C \leq x \\ \left(\frac{C+x}{x}\right)^{2.4}, & C > x \end{cases} \quad (15)$$

inverse Gamma Correction:

$$C_{srgb} = \begin{cases} xC, & C \leq x \\ C^{\frac{1}{2.4}} - x, & C > x \end{cases} \quad (16)$$

Dimana:

RGB_{out} = membatasi nilai warna agar valid (0-1).

$RGB_{daltonized}$ = gambar baru hasil penambahan informasi warna yang hilang.

C_{linear} = mengubah warna dari RGB ke linear untuk perhitungan.

C_{srgb} = mengubah warna linear ke RGB untuk ditampilkan.

Model *image-to-image translation* seperti U-Net dan Autoencoder mempelajari fungsi kompleks sebagai konversi warna [16].

Dengan persamaan:

$$f : X \rightarrow Y \quad (17)$$

$$Y = f(X; \theta) \quad (18)$$

Dimana:

X = Citra *input* dari hasil simulasi buta warna.

Y = Citra *output* dari hasil konversi warna yang dikompensasi.

f = Fungsi transformasi *neural network* dari U-Net atau Autoencoder.

θ = Parameter-parameter dari *neural network*, seperti bobot dan bias, yang dipelajari selama proses pelatihan (*training*).

Tujuan rumus ini untuk merepresentasikan bahwa model *deep learning* berusaha mempelajari fungsi f yang dapat mengubah *input* X menjadi *output* Y secara otomatis, melalui tahapan pelatihan terhadap data dan pembaharuan parameter θ [16].

Fungsi *loss* sebagai *categorical cross-entropy* yang dimana untuk klasifikasi multi-kelas jenis buta warna [16].

Didefinisikan sebagai:

$$L = - \sum_{n=0}^C y_i \log(\hat{y}_i) \quad (19)$$

Dimana:

L = Nilai *loss* yang dihitung oleh model jika semakin kecil nilai L , semakin baik performa model.

$\sum_{i=1}^C$ = Penjumlahan dilakukan dari kelas ke-1 hingga kelas ke- C , di mana C sebagai jumlah kelas. Kelas = jenis buta warna (normal, *protanomaly*, *deutanomaly* berarti $C = 3$).

y_i = Nilai label sebenarnya (*ground truth*) untuk kelas ke- i . Ditulis dalam bentuk *one-hot encoding*, artinya hanya satu nilai yang bernilai 1 (kelas yang benar), sisanya 0.

$\hat{y}_i$ = Probabilitas hasil prediksi model untuk kelas ke- i , sebagai hasil dari fungsi.

$\log(\hat{y}_i)$ = Logaritma dari probabilitas prediksi untuk kelas ke- i . Hanya log dari kelas yang benar (karena $y_i = 1$ untuk satu kelas, sisanya 0) yang berkontribusi terhadap *loss*.

Metrik evaluasi klasifikasi sebagai evaluasi performa model klasifikasi oleh [11] jenis buta warna (normal, *protanomaly*, *deutanomaly*), dapat digunakan beberapa metrik sebagai berikut:

Akurasi dihitung dengan rumus:

$$\text{Akurasi} = \frac{\text{Jumlah prediksi benar}}{\text{Total data}} \quad (20)$$

Dimana:

Jumlah prediksi benar = Total prediksi model yang sesuai dengan label sebenarnya.

Total data = Jumlah seluruh sampel yang diuji.

precision untuk kelas i adalah:

$$\text{Precision}_i = \frac{TP_i}{TP_i + FP_i} \quad (21)$$

recall untuk kelas i adalah:

$$\text{Recall}_i = \frac{TP_i}{TP_i + FN_i} \quad (22)$$

F1-Score untuk kelas i dirumuskan sebagai:

$$F1_i = 2 \times \frac{\text{Precision}_i \times \text{Recall}_i}{\text{Precision}_i + \text{Recall}_i} \quad (23)$$

Dimana:

TP_i = Jumlah data kelas i yang diprediksi benar oleh model (*True Positive*).

FP_i = jumlah data yang bukan kelas i tetapi salah diklasifikasikan sebagai kelas i (*False Positive*).

FN_i = Jumlah data kelas i yang salah diklasifikasikan sebagai kelas lain (*False Negative*).

Precision = Ketepatan model dalam memprediksi kelas i .

Recall = Kemampuan model dalam menemukan semua data dari kelas i .

F1-score = Kesimbangan antara *Precision* dan *Recall*.

Metrik-metrik ini digunakan untuk mengevaluasi performa klasifikasi model [11].

Menentukan atau menilai keberhasilan konversi warna pada penelitian menggunakan beberapa metrik evaluasi. Hal ini untuk mengukur seberapa dekat hasil konversi warna bagi penderita buta warna parsial terhadap warna yang dilihat oleh penglihatan normal. Tiga metrik utama yang digunakan adalah:

Delta E2000 menggunakan CIELAB sebagai metrik untuk mengukur perbedaan warna secara perseptual berdasarkan ruang warna CIELAB. Metrik ini menghitung jarak warna antara dua kategori warna, yaitu warna asli dan warna hasil konversi. Semakin kecil nilai ΔE_{00} maka semakin kecil pula perbedaan warna yang dirasakan oleh mata manusia [12]. Rumus dapat dinyatakan sebagai:

$$\Delta E_{00} = \sqrt{\left(\frac{\Delta L'}{k_L S_L}\right)^2 + \left(\frac{\Delta C'}{k_C S_C}\right)^2 + \left(\frac{\Delta H'}{k_H S_H}\right)^2 + R_T \cdot \left(\frac{\Delta C'}{k_C S_C}\right) \cdot \left(\frac{\Delta H'}{k_H S_H}\right)} \quad (24)$$

Dimana:

$\Delta L'$ = Perbedaan *lightness* (kecerahan) antara dua warna dalam ruang warna CIELAB.

$\Delta C'$ = Perbedaan *chroma* (kejenuhan warna) yang telah dikoreksi.

$\Delta H'$ = Perbedaan *hue* (nada warna) yang telah dikoreksi.

k_L, k_C, k_H = Faktor koreksi untuk *lightness*, *chroma*, dan *hue*. Biasanya diatur sebagai 1 (yaitu $k_L = k_C = k_H = 1$) dalam aplikasi standar.

S_L, S_C, S_H = Fungsi skala yang mengatur sensitivitas penglihatan manusia terhadap perubahan pada dimensi L, C, dan H. Hal ini saling menyesuaikan antar kontribusi masing-masing komponen dalam total perbedaan.

R_T = Faktor rotasi yang mempertimbangkan interaksi antara perbedaan *chroma* dan *hue*, terutama warna *hue* di sekitar biru keunguan yang memiliki sensitivitas perseptual khusus.

Penggunaan Delta E 2000 dalam penelitian ini penting dikarenakan buta warna merupakan masalah persepsi visual. Oleh karena itu, evaluasi berdasarkan perbedaan perseptual menjadi sangat relevan [12].

Structural Similarity Indeks (SSIM) diterapkan untuk mengukur kesamaan antara dua gambar berdasarkan persepsi struktur visual. SSIM mempertimbangkan perubahan dalam luminasi, kontras, dan struktur. Nilai SSIM berada dalam rentang antara -1 hingga 1, di mana nilai 1 menunjukkan bahwa kedua gambar sangat mirip secara struktural [13]. Rumus SSIM dinyatakan sebagai berikut:

$$SSIM(x, y) = \frac{(2\mu_x \mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (25)$$

Dimana:

μ_x, μ_y = Rata-rata intensitas piksel dari gambar x dan y .

σ_x^2, σ_y^2 = Variansi masing-masing gambar.

σ_{xy} = Kovariansi antara keduanya.

C_1, C_2 = Konstanta stabilisasi.

Metrik ini guna untuk menilai apakah struktur keseluruhan dari gambar tetap terjaga setelah proses konversi [13].

Peak Signal-to-Noise Ratio (PSNR) sebuah metrik berbasis kesalahan piksel yang banyak digunakan untuk mengukur kualitas gambar yang dikompresi atau direkonstruksi. PSNR dihitung berdasarkan *Mean Squared Error* (MSE) anatara dua gambar. Semakin tinggi nilai PSNR, maka semakin baik kualitas hasil gambar terhadap gambar referensinya[17].

Rumus PNSR adalah:

$$PSNR = 10 \cdot \log_{10} \left(\frac{MAX_I^2}{MSE} \right) \quad (26)$$

dengan MSE dapat dihitung sebagai:

$$MSE = \frac{1}{mn} \sum_{i=1}^m \sum_{j=1}^n [I(i, j) - K(i, j)]^2 \quad (27)$$

Dimana:

$I(i, j)$ = Piksel pada gambar hasil konversi.

$K(i, j)$ = Piksel pada gambar referensi.

m dan n = Dimensi gambar.

$MAX1$ = Nilai maksimum piksel (biasanya 255 untuk gambar 8-bit).

Penggunaan PSNR dalam penelitian ini membantu menilai kualitas reproduksi warna secara numerik meskipun tidak secara langsung menangkap persepsi visual[17].

E. Penelitian Terdahulu dan Alasan Pemilihan Teori

Berbagai penelitian terdahulu telah mengembangkan teknik recoloring berbasis optimasi warna dan deep learning untuk penderita CVD. Studi oleh [5] dan [18] menekankan preservasi naturalness dan kontras, sementara penelitian terbaru mengintegrasikan personalisasi dan arsitektur neural network modern seperti transformer [19] [20]. Namun, sebagian besar pendekatan masih berfokus pada manipulasi warna tanpa mempertimbangkan struktur visual atau bentuk simbolik.

Berdasarkan kajian tersebut, dapat disimpulkan bahwa belum terdapat penelitian yang mengintegrasikan struktur monogram sebagai bagian dari proses identifikasi dan konversi warna, khususnya untuk penderita buta warna parsial. Oleh karena itu, penelitian ini mengusulkan pendekatan baru dengan memadukan monogram image processing dan deep learning guna meningkatkan aksesibilitas warna secara lebih adaptif dan inklusif.

III. METODE

A. Alur Penelitian

Penelitian ini dilakukan melalui beberapa tahapan utama. Tahap awal dimulai dengan studi pustaka terkait buta warna parsial, ruang warna (RGB dan LMS), *monogram image processing*, arsitektur CNN ringan, serta metode *image-to-image translation*. Selanjutnya, dataset citra RGB dikumpulkan dari sumber publik dan dataset buatan sendiri, kemudian dilakukan simulasi buta warna parsial (*protanomaly* dan *deuteranomaly*) menggunakan transformasi RGB-LMS-RGB.

Pada tahap *preprocessing*, citra hasil simulasi diproses menggunakan *monogram image processing* untuk meningkatkan segmentasi dan representasi warna. Model CNN (MobileNetV2, EfficientNet-B0, dan SqueezeNet) kemudian dilatih untuk mendeteksi jenis buta warna. Berdasarkan hasil deteksi, dilakukan konversi warna menggunakan model *image-to-image translation* berbasis U-Net dan Autoencoder. Tahap akhir mencakup evaluasi performa klasifikasi, kualitas konversi warna, serta analisis visual dan uji validitas sistem.

B. Alat dan Bahan


Dataset yang digunakan terdiri dari citra RGB dengan variasi objek dan warna yang diambil dari ImageNet (5.000 gambar), COCO Imagenet (5.000 gambar), serta dataset diambil sendiri (10.000 gambar). Dataset normal kemudian disimulasikan menjadi citra *protanomaly* dan *deuteranomaly* untuk membentuk pasangan data *input-target*.

Penelitian ini diimplementasikan menggunakan bahasa pemrograman Python dengan dukungan pustaka OpenCV, NumPy, TensorFlow, Keras, dan Scikit-learn. Proses pelatihan dilakukan pada perangkat laptop dengan spesifikasi komputasi menengah untuk memastikan efisiensi sistem.

C. Perancangan Sistem


Definisikan Secara umum, sistem terdiri dari tiga komponen utama: preprocessing, deteksi jenis buta warna, dan konversi warna. *Preprocessing* mencakup penyesuaian ukuran citra, normalisasi nilai piksel, simulasi buta warna parsial, serta ekstraksi fitur tambahan melalui monogram image processing.

Deteksi jenis buta warna dilakukan menggunakan CNN untuk mengklasifikasikan citra ke dalam tiga kelas, yaitu normal, *protanomaly*, dan *deutanomaly*. Model CNN dipilih berdasarkan perbandingan performa akurasi dan efisiensi komputasi, dapat dilihat pada Gambar 2.



GAMBAR 2
(FLOWCHART TAHAPAN KLASIFIKASI)

Tahap konversi warna menggunakan kombinasi transformasi ruang warna LMS dan *image-to-image translation* berbasis U-Net atau Autoencoder. Model ini mempelajari pemetaan dari citra hasil simulasi menuju citra hasil kompensasi warna yang lebih mudah dibedakan oleh penderita CVD, tanpa menghilangkan struktur visual penting. Berikut pada Gambar 3 terdapat alur tahapan pengujian transformasi warna.



GAMBAR 3
(FLOWCHART TAHAPAN TRANSFORMASI WARNA)

Untuk melihat alur sistem secara umum, dibuatkannya diagram sistem yang dapat dilihat pada Gambar



GAMBAR 4
(DIAGRAM ARISTEKTUR SECARA UMUM)

D. Pengujian dan Evaluasi

Evaluasi sistem dilakukan pada dua aspek utama. Performa klasifikasi CNN dinilai menggunakan metrik akurasi, *precision*, *recall* dan *F1-score*. Kualitas hasil konversi warna dievaluasi menggunakan Delta E2000 untuk perbedaan warna perseptual, *Structural Similarity Index* (SSIM) untuk kesamaan struktur visual dan *Peak Signal-to-Noise Ratio* (PSNR) untuk kualitas rekonstruksi citra. Selain evaluasi numerik, dilakukan distribusi spektrum warna untuk melihat peningkatan keterpisahan warna dominan sebelum dan sesudah konversi, sistem juga divalidasi melalui uji visual dengan pengguna penderita buta warna parsial

IV. HASIL DAN PEMBAHASAN

A. Hasil Pengujian

1. Hasil Pengujian Model CNN

Pengujian dilakukan untuk mengevaluasi performa tiga model CNN, yaitu EfficientNet-B0, MobileNetV2, dan SqueezeNet dalam mengklasifikasikan tiga jenis kondisi penglihatan warna. Evaluasi dilakukan menggunakan metrik *accuracy*, *precision*, *recall*, *F1-score*, *confusion matrix*, serta analisis terhadap stabilitas pelatihan melalui grafik *training* dan *validation*.

a. Evaluasi Model SqueezeNet

SqueezeNet memberikan performa terbaik dengan akurasi 96% jauh lebih tinggi dibandingkan dua model lainnya. Arsitektur yang sangat ringan namun fokus pada fitur *low-level* menjadi alasan utama tingginya performa. Keunggulan utama pada *fire module* yang sensitif terhadap warna dengan menggabungkan 1×1 *convolution* (*squeeze*) dan 3×3 *convolution* (*expand*). Struktur ini menjadi efektif menangkap perbedaan intensitas warna, responsif terhadap pola piksel kecil, dan optimal untuk dataset berbasis warna.

TABEL 1
(CONFUSION MATRIX SQUEEZENET)


Prediksi	Deuteranomaly	Normal	Protanomaly
Deuteranomaly	2856	58	86
Normal	99	2851	50
Protanomaly	27	9	2964

TABEL 2
(AKURASI DAN F1-SCORE SQUEEZENET)

MODEL	PRECISIO N	RECAL L	F1- SCOR E	AKURA SI
Normal	0.98	0.95	0.96	0.96
Protanomaly	0.96	0.99	0.97	0.96
Deuteranoma ly	0.96	0.95	0.95	0.96

Selain itu, SqueezeNet memiliki jumlah parameter paling sedikit di antara ketiga model. Model yang kecil

cenderung memiliki generalisasi lebih baik pada dataset terbatas, sekaligus menjaga stabilitas selama pelatihan. Hal ini terlihat dari grafik pelatihan yang relatif stabil dan tidak menunjukkan indikasi *overfitting* pada gambar 4.2. Dengan keunggulan SqueezeNet dalam mengekstraksi fitur warna dan pola titik secara presisi menjadikannya sangat cocok untuk klasifikasi jenis buta warna pada dataset buta warna parsial yang bergantung pada perbedaan warna, saturasi, dan distribusi warna antar piksel.



GAMBAR 5
(GRAFIK HASIL TRAINING SQUEEZENET)

b. Evaluasi Model MobileNetV2

MobileNetV2 menunjukkan performa menengah dengan akurasi 72%. Model ini relatif seimbang antara kompleksitas dan kemampuan generalisasi. Hal ini tidak lepas dari penggunaan arsitektur *inverted residual* dan *linear bottleneck*, yang terbukti efisien dalam mengekstraksi fitur visual berukuran kecil.

TABEL 3
(CONFUSION MATRIX MOBILENETV2)

Prediksi	Deuteranomaly	Normal	Protanomaly
Deuteranomaly	2067	506	427
Normal	619	1980	401
Protanomaly	304	256	2440


TABEL 4
(Akurasi dan F1-Score MobileNetV2)

Model	Precision	Recall	F1-Score	Akurasi
Normal	0.72	0.66	0.69	0.72
Protanomaly	0.75	0.81	0.78	0.72
Deuteranomaly	0.69	0.69	0.69	0.72

Meskipun MobileNetV2 mampu memberikan performa klasifikasi yang cukup baik, penggunaan seluruh lapisan *pretrained* yang dibekukan menyebabkan kemampuan adaptasi model terhadap karakteristik spesifik dataset menjadi terbatas.

Selain itu, penggunaan *depthwise separable convolution* memungkinkan pemrosesan lebih ringan dan stabil, namun dengan konsekuensi bahwa informasi fitur

global tidak tertangkap sekuat model. Hal ini terlihat kesalahan klasifikasi antara kelas normal dan *deuteranomaly*, yang memiliki pola warna yang sangat berdekatan. MobileNetV2 mampu menghasilkan performa cukup baik tanpa mengalami *overfitting* yang signifikan dapat dilihat pada Gambar 5. Namun masih mengalami kesalahan pada kelas dengan intensitas warna yang mirip dan sensitivitasnya terhadap perbedaan gradasi warna yang sangat halus masih lebih rendah dibandingkan SqueezeNet.



GAMBAR 6
(GRAFIK HASIL TRAINING MOBILENETV2)

c. Evaluasi Model EfficientNet-B0

EfficientNet-B0 menghasilkan akurasi terendah, yaitu 35% meskipun telah dilatih menggunakan dataset berjumlah besar. Hasil ini tetap menunjukkan bahwa arsitektur EfficientNet-B0 kurang sesuai dengan karakteristik dataset yang berbasis perbedaan warna dan intensitas piksel.

TABEL 5
(CONFUSION MATRIX EFFICIENTNET-B0)


Prediksi	Deuteranomaly	Normal	Protanomaly
Deuteranomaly	910	1698	392
Normal	864	1792	344
Protanomaly	829	1723	448

TABEL 6
(Akurasi dan F1-Score EfficientNet-B0)

Model	Precision	Recall	F1-Score	Akurasi
Normal	0.34	0.60	0.44	0.35
Protanomaly	0.38	0.15	0.21	0.35
Deuteranomaly	0.35	0.30	0.32	0.35

Faktor penyebab performa rendah ada pada kompleksitas arsitektur terlalu tinggi yang menggabungkan MBConv (*Mobile Inverted Bottleneck Convolution*) dan SE Layer (*Squeeze-and-Excitation*). Kedua komponen ini meningkatkan kompleksitas representasi fitur. Pada dataset berbasis warna, sehingga model terlalu fokus pada fitur global yang dapat menghilangkan sensitivitas terhadap perbedaan warna

mikro, sulit mengekstrak pola intensitas sederhana antar kelas. Lalu *overfitting* struktural terjadi karena arsitektur terlalu kompleks untuk tugas yang lebih mengandalkan perbedaan warna dibandingkan bentuk. SE Layer juga berpotensi memperkuat *channel* warna yang tidak relevan sehingga menimbulkan bias prediksi. Serta EfficientNet-B0 dirancang untuk objek visual kompleks. Namun dataset citra justru bergantung pada perbedaan intensitas warna, detail piksel kecil, dan fitur *low-level* yang dimana membuat *receptive field* kurang peka terhadap variasi warna mikro. Sehingga model ini tidak optimal untuk dataset berbasis warna karena fitur penting tidak teridentifikasi, salah mengklasifikasikan antar kelas sangat tinggi, dan *confusion matrix* tersebar acak yang sudah divisualisasikan pada Gambar 7.



GAMBAR 7
(GRAFIK HASIL TRAINING EFFICIENTNET-B0)

Hasil pengujian menunjukkan adanya perbedaan performa yang cukup signifikan antar model, yang dipengaruhi oleh struktur jaringan dan kemampuan masing-masing model dalam mengenali variasi warna, yang dapat dilihat pada Tabel 7.

TABEL 7
(PERBANDINGAN PERFORMA MODEL CNN)

Model	Precision	Recall	F1-Score	Akurasi
Normal	0.96	0.96	0.96	0.96
Protanomaly	0.72	0.72	0.72	0.72
Deutanomaly	0.36	0.35	0.33	0.35

2. Hasil Pengujian Model Transformasi Warna

Pengujian dilakukan untuk mengetahui sejauh mana arsitektur U-Net dan Autoencoder mampu melakukan warna daltonisasi *protanomaly* dan *deutanomaly* secara akurat. Pengujian dilakukan menggunakan tiga metrik utama yaitu:

- a) PSNR (*Peak Signal-to-Noise Ratio*): mengukur tingkat distorsi transformasi. Semakin tinggi semakin baik.

- b) SSIM (*Structural Similarity Indeks*): mengukur kesamaan struktural visual. Semakin mendekati 1 semakin baik.
- c) Delta E2000: mengukur perbedaan warna secara perseptual. Semakin rendah semakin baik.

Pengujian dilakukan pada data validasi selama pelatihan dan data uji akhir. Ringkasan performa kedua model pada kedua jenis daltonisasi dirangkum pada Tabel 8.

TABEL 8
(PERBANDINGAN HASIL UJI TRANSFORMASI WARNA)

Jenis CVD	Model	PSNR	SSIM	Delta E2000
Protanomaly	U-Net	36.9082	0.9748	1.8903
	Autoencoder	25.5206	0.7859	4.3976
Deutanomaly	U-Net	36.0924	0.9710	2.0198
	Autoencoder	11.2230	0.2904	25.3596

Berdasarkan hasil pengujian pada tabel di atas, menunjukkan bahwa U-Net secara konsisten menjadi model terbaik untuk kedua jenis daltonisasi. Pada protanomaly, U-Net menghasilkan PSNR 36.908 dan SSIM 0.9748, menandakan transformasi warna yang sangat mendekati target dengan distorsi minimal. Nilai Delta E2000 sebesar 18903 menunjukkan bahwa perbedaan warna hampir terlihat secara perseptual.

Hal yang sama juga terlihat pada *deutanomaly*, dimana U-Net tetap unggul dengan PSNR 36.0924 dan SSIM 0.9710. Delta E2000 hanya 2.0198 yang kembali mengonfirmasi bahwa hasil warna tetap sangat dekat dengan target daltonisasi.

Sebaliknya, Autoencoder menunjukkan performa jauh lebih rendah terutama pada *deutanomaly* di mana nilai SSIM turun 0.2904 dan Delta E2000 meningkat tajam 25.3596. hal ini menandakan bahwa Autoencoder sulit mempertahankan struktur citra dan gagal meniru pola perubahan warna secara stabil.

Konsistensi performa U-Net juga terlihat pada metrik validasi selama proses pelatihan, yang menunjukkan nilai *validation loss* yang lebih rendah serta PSNR dan SSIM yang jauh lebih tinggi, yang tertera pada tabel 9.

TABEL 9
(PERFORMA VALIDASI SELAMA PELATIHAN)


Jenis CVD	Model	Val Loss	Val PSNR	Val SSIM
Protanomaly	U-Net	0.000241	36.9721	0.9757
	Autoencoder	0.003770	25.5036	0.7851
Deutanomaly	U-Net	0.000292	36.2149	0.9715
	Autoencoder	0.004122	25.1812	0.7677

Nilai validasi memperkuat temuan pada data uji, U-Net menunjukkan loss yang lebih rendah, serta PSNR dan SSIM yang lebih tinggi baik *protanomaly* dan *deutanomaly*. Sedangkan Autoencoder mencatat *loss* 10 kali lebih besar dan SSIM jauh lebih rendah, menandakan kesulitan dalam mempelajari struktur citra dan pola transformasi warna.

Visualisasi perbandingan hasil transformasi antara citra *input*, target daltonisasi, serta keluaran dari U-Net dan Autoencoder, sebagai berikut.

Protanomaly

Deutanomaly



GAMBAR 8
(VISUALISASI PERBANDINGAN HASIL TRANSFORMASI WARNA)

Dari visualisasi terlihat pada Gambar 8, bahwa U-Net menghasilkan warna yang stabil, akurat dan mempertahankan detail tekstur berkat mekanisme *skip-connection*. Autoencoder cenderung menghasilkan warna yang pudar, tidak konsisten, serta blur dan kurang konsisten.

Secara keseluruhan, baik pada *protanomaly* maupun *deutanomaly*, U-Net terbukti mampu menjadi model paling optimal untuk tugas transformasi warna. Arsitektur ini mampu mempertahankan struktur citra menghasilkan warna yang lebih akurat, serta memberikan perbedaan warna secara perseptual. Sementara itu, Autoencoder kurang mampu metransformasikan detail dan warna dengan baik, terutama pada *deutanomaly*.

3. Perbandingan Transformasi Warna Tanpa dan Dengan *Monogram Image*

Untuk mengetahui pengaruh penggunaan *Monogram Image Processing*, dilakukan perbandingan performa transformasi warna antara dua pendekatan, yaitu:

- Transformasi warna tanpa *monogram image*, yang menggunakan input citra RGB standar (3 channel).
- Transformasi warna dengan *monogram image*, yang menggunakan input citra RGB + *Brightness* + *Edge* + *Contrast* (6 channel).

Perbandingan ini bertujuan untuk mengevaluasi apakah penambahan fitur struktural dan intensitas melalui

monogram image mampu meningkatkan kualitas hasil koreksi warna secara kuantitatif maupun visual.

a) Hasil Transformasi Tanpa *Monogram Image* (3 channel)

Pada pendekatan tanpa *monogram image*, model U-Net menerima input citra RGB (3 channel) hasil daltonisasi dan langsung memetakan citra tersebut ke citra target warna normal. Proses pelatihan dan evaluasi dilakukan menggunakan konfigurasi data yang sama, dengan pembagian 80% data latih, 10% data validasi, dan 10% data uji. Hasil evaluasi transformasi warna tanpa *monogram image* pada kasus *protanomaly* dan *deutanomaly* ditunjukkan pada Tabel 10.

TABEL 10
(HASIL EVALUASI TRANSFORMASI WARNA TANPA *MONOGRAM IMAGE*)

Prediksi	<i>Deutanomaly</i>	Normal	<i>Protanomaly</i>
<i>Protanomaly</i>	37.3562	0.9760	1.8211
<i>Deutanomaly</i>	36.2319	0.9718	1.9823

Berdasarkan hasil tersebut, U-Net berbasis RGB mampu menghasilkan kualitas transformasi warna yang sangat baik, ditunjukkan oleh PSNR dan SSIM yang tinggi serta nilai Delta E2000 yang rendah. Hal ini menunjukkan bahwa U-Net telah mampu mempelajari pemetaan warna dari citra daltonisasi ke citra normal secara efektif meskipun hanya menggunakan informasi warna RGB.

b) Hasil Transformasi Warna Dengan *Monogram Image* (6 channel)

Pada pendekatan kedua, input citra tidak hanya terdiri dari RGB, tetapi diperluas menjadi 6 channel melalui proses *monogram image processing*, yaitu menambahkan informasi *brightness* (intensitas), *edge* (tepi), dan *contrast* (tekstur). Penambahan channel ini bertujuan untuk memperkaya representasi fitur spasial dan struktural. Hasil evaluasi transformasi warna *monogram image* pada kasus *protanomaly* dan *deutanomaly* disajikan pada Tabel 11.


TABEL 11
(HASIL EVALUASI TRANSFORMASI WARNA DENGAN *MONOGRAM IMAGE*)

Prediksi	<i>Deutanomaly</i>	Normal	<i>Protanomaly</i>
<i>Protanomaly</i>	36.9082	0.9748	1.8903
<i>Deutanomaly</i>	36.0924	0.9710	2.0198

Secara numerik, hasil pengujian menunjukkan bahwa U-Net tanpa *monogram image* (RGB) memiliki PSNR dan SSIM yang sedikit lebih tinggi dibandingkan U-Net dengan *monogram image*. Namun, perbedaan nilai tersebut relatif kecil dan masih berada dalam rentang performa yang sangat baik pada kedua pendekatan.

Meskipun demikian, keunggulan *monogram image* lebih terlihat pada aspek struktur dan konsisten visual, terutama pada area dengan perubahan warna yang kompleks. Informasi tambahan berupa *edge* dan *contrast* membantu model mempertahankan detail spasial sehingga hasil transformasi warna terlihat lebih stabil dan tidak mudah mengalami perubahan warna.

Sebaliknya, pendekatan tanpa *monogram image* lebih bergantung pada informasi warna RGB, sehingga performanya sangat dipengaruhi oleh kualitas warna *input*. Pada beberapa kasus, model cenderung menghasilkan warna yang kurang konsisten ketika perbedaan spektrum warna *input* terlalu ekstrem. Dapat dilihat pada Gambar 9.




GAMBAR 9
(VISUALISASI PERBANDINGAN PENGGUNAAN *MONOGRAM* DAN TANPA *MONOGRAM*)

Berdasarkan visualisasi hasil transformasi, perbedaan antara kedua pendekatan dapat diamati pada visualisasi tanpa *monogram image* (RGB), warna hasil transformasi terlihat tajam dan mendekati target, namun pada beberapa area tekstur halus masih terdapat ketidakkonsistenan warna. Sedangkan, dengan *monogram image* (6 channel), warna hasil transformasi lebih stabil dan struktur citra lebih terjaga, terutama pada tepi objek dan area dengan kontras tinggi. Hal ini menunjukkan bahwa informasi tambahan dari *monogram image* membantu model dalam mempertahankan detail visual.

Dengan demikian, penggunaan *monogram image* terbukti memberikan kontribusi positif dalam memperkaya representasi fitur citra, terutama untuk menjaga detail spasial, meskipun peningkatan performa numerik tidak selalu signifikan.

4. Analisis Hasil Validasi Pengguna Sistem

Berdasarkan hasil validasi pengguna yang diperoleh melalui penyebaran kuesioner. Validasi ini bertujuan untuk menilai tingkat kenyamanan visual, kealamian warna, serta kebermanfaatan hasil transformasi warna yang dihasilkan oleh sistem bagi pengguna dengan kondisi buta warna parsial.




GAMBAR 10
(GRAFIK JUMLAH RESPONDEN)

Karakteristik responden penelitian pada Gambar 10, menunjukkan komposisi responden yang terlibat dalam penelitian ini. Total responden berjumlah 30 orang, yang terdiri atas 16 responden dengan buta warna parsial dan 14 responden dengan penglihatan normal. Pembagian responden bertujuan untuk membandingkan persepsi

responden ini bertujuan untuk membandingkan persepsi visual antara pengguna dengan keterbatasan persepsi warna dan pengguna dengan penglihatan normal terhadap citra sebelum dan sesudah transformasi warna yang diterapkan.


a. Persepsi Responden Terhadap Citra Sebelum Transformasi Warna



GAMBAR 11
(GRAFIK SEBELUM TRANSFORMASI (KEMAMPUAN MENGENALI ANGKA))

Berdasarkan Gambar 11, mayoritas responden dengan buta warna parsial menyatakan tidak dapat mengenali angka pada citra Ishihara sebelum dilakukan transformasi warna. Responden melaporkan bahwa angka tidak terlihat jelas atau menyatu dengan latar belakang akibat kemiripan spektrum warna. Sebaliknya, hampir seluruh responden dengan penglihatan normal mampu mengenali angka pada citra dengan baik.

b. Persepsi Kejelasan Citra Setelah Transformasi Warna




GAMBAR 12
(GRAFIK SETELAH TRANSFORMASI WARNA)

Setelah transformasi warna diterapkan, terjadi peningkatan signifikan pada tingkat kejelasan angka yang dirasakan oleh responden buta warna parsial. Sebagian besar responden menyatakan bahwa angka pada citra menjadi lebih jelas dibandingkan kondisi sebelum transformasi.

Sementara itu, responden dengan penglihatan normal cenderung menyatakan perubahan warna tidak memberikan perbedaan yang signifikan, atau bahkan terasa sama saja. Hal ini menunjukkan bahwa sistem transformasi warna yang dikembangkan lebih berfokus pada peningkatan aksesibilitas bagi pengguna dengan keterbatasan penglihatan warna, tanpa secara khusus

dioptimalkan untuk pengguna dengan penglihatan normal.


c. Faktor Visual yang Paling Membantu Pengenalan Angka



GAMBAR 13
(GRAFIK FAKTOR YANG PALING MEMBANTU)

Berdasarkan Gambar 13, faktor visual yang paling membantu responden dalam membedakan angka pada citra adalah perubahan warna angka, diikuti oleh perubahan warna latar belakang dan peningkatan kontras. Temuan ini menunjukkan bahwa keberhasilan transformasi warna tidak hanya ditentukan oleh peningkatan kontras semata, tetapi juga oleh pemilihan spektrum warna angka yang lebih mudah dibedakan oleh penderita buta warna parsial.

d. Persepsi Manfaat Transformasi Warna bagi Responden Buta Warna Parsial




GAMBAR 14
(GRAFIK TINGKAT MANFAAT SISTEM)

Gambar menunjukkan hasil evaluasi subjektif menunjukkan bahwa sebagian besar responden dengan buta warna parsial menilai sistem transformasi warna yang diusulkan bermanfaat hingga sangat bermanfaat dalam membantu mengenali angka pada citra Ishihara.

Beberapa responden menyatakan bahwa meskipun tampilan warna terasa sedikit berbeda atau tidak natural, peningkatan kejelasan angka memberikan manfaat yang signifikan dibandingkan citra asli.

e. Persepsi Naturalis Tampilan Hasil Transformasi Sistem



GAMBAR 15
(GRAFIK PERSEPSI NATURALISTIS SISTEM)

Berdasarkan Gambar menunjukkan persepsi responden terhadap naturalis tampilan citra hasil transformasi warna menunjukkan variasi yang cukup signifikan. Sebanyak 10 responden menyatakan bahwa tampilan citra masih terlihat natural, sementara 6 responden menilai tampilan citra terasa sedikit aneh namun tidak mengganggu proses pengenalan angka. Sebaliknya, 14 responden menyatakan bahwa tampilan citra terasa aneh, yang umumnya berasal dari responden dengan penglihatan normal.

Responden dengan buta warna parsial cenderung menerima perubahan warna sebagai sesuatu yang positif karena memungkinkan mereka melihat angka yang sebelumnya tidak dapat dikenali pada *test* Ishihara. Sebaliknya, responden dengan penglihatan normal menilai perubahan spektrum warna terasa tidak natural karena berbeda dari persepsi warna yang biasa mereka alami. Hal ini menunjukkan bahwa transformasi warna yang diusulkan lebih berfokus pada peningkatan aksesibilitas visual bagi pengguna buta warna parsial dibandingkan mempertahankan kesan visual alami bagi pengguna normal.

Secara keseluruhan, hasil visualisasi dan kuesioner menunjukkan bahwa transformasi warna berbasis *deep learning* mampu meningkatkan aksesibilitas visual bagi pengguna dengan buta warna parsial. Peningkatan kejelasan angka pada citra Ishihara membuktikan bahwa pendekatan transformasi spektrum warna dapat menjadi solusi pendukung dalam sistem aksesibilitas visual.

B. Pembahasan

Berdasarkan hasil pengujian dan implementasi sistem secara menyeluruh, sistem yang dibangun berhasil memenuhi dua tujuan utama penelitian, yaitu mendeteksi jenis buta warna parsial dan melakukan transformasi warna untuk meningkatkan keterlihatan visual pengguna dengan gangguan penglihatan warna.

Pada tahap deteksi jenis buta warna, model SqueezeNet menunjukkan performa terbaik dengan akurasi sebesar 96%, jauh melampaui MobileNetV2 (72%) dan EfficientNet-B0

(35%). Hasil ini mengindikasikan bahwa arsitektur CNN yang ringan dengan *fire module* lebih sesuai untuk tugas klasifikasi berbasis pola warna mikro hasil simulasi buta warna. Kompleksitas arsitektur yang tinggi seperti pada EfficientNet-B0 tidak selalu memberikan keuntungan, karena penelitian ini tidak menuntut ekstraksi bentuk objek tingkat tinggi, melainkan sensitivitas terhadap perbedaan distribusi warna.

Pada tahap transformasi warna, U-Net secara konsisten mengungguli Autoencoder pada kedua jenis CVD, yaitu *protanomaly* dan *deutanomaly*. Nilai PSNR diatas 36 dan SSIM mendekati 0.97 menunjukkan bahwa U-Net mampu menghasilkan citra hasil transformasi yang sangat mendekati target secara struktural dan visual. Keunggulan ini terutama disebabkan oleh mekanisme *skip connection* yang memungkinkan informasi spasial dari *encoder* dipertahankan hingga *decoder*, sehingga detail tekstur dan tepi citra tetap terjaga. Sebaliknya, Autoencoder menunjukkan keterbatasan signifikan, khususnya pada *deutanomaly*, dengan nilai SSIM hanya 0.29, yang menandakan kegagalan dalam mempertahankan struktural citra dan mempelajari pemetaan warna kompleks tanpa jalur penghubung antar layer.

Penelitian ini juga mengevaluasi pengaruh *penggunaan monogram image processing* dibandingkan dengan pendekatan RGB. Hasil menunjukkan bahwa transformasi warna tanpa *monogram* (RGB) mengasilkan nilai PSNR dan SSIM yang sedikit lebih tinggi. Namun demikian, perbedaan tersebut relatif kecil dan tidak signifikan secara visual. Penggunaan *monogram image* tidak dimaksudkan untuk meningkatkan nilai metrik numerik secara mutlak, melainkan untuk memperkaya representasi fitur visual melalui penambahan informasi *brightness*, *edge* dan *contrast*.

Selain itu, *monogram image* terbukti membantu model mempertahankan stabilitas struktur dan konsistensi warna, terutama pada area dengan kontra tinggi dan tepi objek yang kompleks. Dengan demikian, *monogram image* berperan sebagai *feature enrichment* dan regularisasi representasi, bukan sebagai pendukung peningkatan metrik numerik semata. Hal ini menunjukkan adanya *trade-off* antara kompleksitas *input* dan peningkatan kualitas struktural visual.

Ketika dibandingkan dengan penelitian sebelumnya, penelitian ini mengisi beberapa celah penting. Studi-studi terdahulu dari Zhu et al. (2022) dan [NO_PRINTED FORM] [18], cenderung berfokus pada optimasi di ruang warna untuk kasus dikromasi (buta warna total) dan sering membutuhkan sumber daya komputasi tinggi. Penelitian ini justru menyoroti buta warna parsial yang lebih umum terjadi serta mengintegrasikan *monogram image processing* sebagai tahap praproses sebuah pendekatan baru yang memperkaya representasi visual dengan informasi *brightness*, *edge*, dan *contrast*. Integrasi ini terbukti meningkatkan akurasi deteksi CNN dan membantu model transformasi dalam mempertahankan struktur citra, menawarkan keunggulan dibandingkan pendekatan sebelumnya yang hanya berfokus pada manipulasi warna piksel.

Kelebihan utama sistem ini tidak hanya pada akurasi dan kualitas hasil, tetapi juga pada efisiensi komputasi dan

implementasi *real-time*. Kombinasi SqueezeNet dan U-Net menjadikan sistem dapat diterapkan pada perangkat berkinerja rendah seperti *smartphone*, yang menjadi tantangan dalam banyak penelitian terdahulu. Selain itu, rancangan sistem yang bersifat *end-to-end*, mulai dari diagnosis dengan tes Ishihara hingga transformasi warna otomatis, memberikan pengalaman pengguna yang komprehensif dan mudah digunakan.

Terdapat evaluasi dari uji sistem integrasi, untuk mengetahui apakah hasil transformasi warna yang dihasilkan sistem benar-benar memberikan peningkatan penglihatan angka pada plate Ishihara dibandingkan dengan gambar aslinya. Hasil uji wawancara dengan responden penderita gangguan penglihatan warna menunjukkan bahwa gambar Ishihara asli sulit dibedakan dan sebagian besar angka tidak dapat dikenali. Pada tiga *plate* yang diberikan, responden hanya melihat campuran warna atau angka yang salah, sehingga menegaskan bahwa citra asli tidak memberikan informasi visual yang dapat dipersepsi dengan baik oleh pengguna CVD. Kondisi ini sejalan dengan karakteristik *protanomaly* dan *deutanomaly* yang umumnya kesulitan dalam membedakan rentang warna.

Setelah diberikan gambar hasil transformasi warna, responden mampu mengenali seluruh angka dengan jelas, yaitu “74”, “35”, dan “29”. Responden menyatakan bahwa transformasi warna membantu meningkatkan keterlihatan angka, terutama karena warna angka menjadi lebih menonjol dibandingkan latar belakangnya. Meskipun tampilan gambar dinilai “aneh”. Hal ini dikarenakan responden baru pertama kali dapat melihat angka pada tes Ishihara dengan jelas, sehingga pemetaan warna yang baru terasa tidak natural dari sudut pandang persepsi warna mereka. Hasil transformasi dinilai bermanfaat secara fungsional dengan menunjukkan pendekatan transformasi warna yang dikembangkan efektif meningkatkan *color separability* dan memberikan dampak positif pada aksesibilitas visual bagi pengguna CVD.

Berdasarkan analisis mendalam, dapat disimpulkan bahwa sistem ini memiliki beberapa keunggulan utama pada akurasi klasifikasi yang tinggi dengan model yang ringan, kualitas transformasi warna yang unggul dengan preservasi struktur, antar muka yang mudah digunakan dan inovasi *monogram* yang efektif. Namun, penelitian ini juga memiliki beberapa keterbatasan. Jangkauan jenis CVD masih terbatas pada *protanomaly* dan *deutanomaly*, yang belum mencakup *tritanomaly* atau buta warna total. Evaluasi subjektif terhadap pengguna CVD di dunia nyata juga masih terbatas, sehingga persepsi pemanfaatan sistem oleh pengguna langsung belum dievaluasi secara mendalam. Selain itu, penggunaan dataset berbasis simulasi daltonisasi berpotensi tidak sepenuhnya menggambarkan variasi persepsi warna antar individu.

Secara keseluruhan, integrasi antara deteksi berbasis CNN. Transformasi warna menggunakan U-Net, dan implementasi fitur *monogram image processing* terbukti pendekatan yang efektif dan menjanjikan. Sistem ini tidak hanya mencapai performa tinggi, tetapi juga memberikan kontribusi signifikan dalam penelitian aksesibilitas visual, khususnya dalam upaya mengembangkan solusi yang praktis, efisien, dan lebih sesuai dengan kebutuhan pengguna buta warna parsial.

V. KESIMPULAN

Penelitian ini berhasil mengembangkan sistem berbasis deep learning untuk mendeteksi dan mengonversi warna pada kasus buta warna parsial secara efektif. Model deteksi yang dibangun menggunakan pendekatan *Convolutional Neural Network* (CNN) mampu mengenali pola warna yang sulit dibedakan oleh penderita *Color Vision Deficiency* (CVD) secara otomatis. Dari beberapa arsitektur yang diuji, SqueezeNet menunjukkan performa paling optimal dengan tingkat akurasi mencapai 96%, secara signifikan melampaui MobileNetV2 dan EfficientNet-B0. Hasil ini menunjukkan bahwa arsitektur ringan dengan fokus pada ekstraksi fitur warna mikro lebih sesuai untuk tugas deteksi jenis buta warna dibandingkan model yang lebih kompleks.

Selain itu, integrasi *monogram image processing* terbukti berkontribusi dalam mengoptimalkan proses identifikasi dan transformasi warna. Penambahan informasi brightness, edge, dan contrast menghasilkan representasi citra multi-channel yang memperkaya konteks visual bagi model. Meskipun transformasi berbasis RGB standar menghasilkan nilai PSNR dan SSIM yang sedikit lebih tinggi, penggunaan *monogram image* memberikan stabilitas struktur dan konsistensi perseptual yang lebih baik, khususnya pada area tepi dan detail tekstur. Temuan ini menegaskan bahwa *monogram image* berperan penting dalam meningkatkan *robustness* dan kualitas visual hasil konversi warna, bukan sekadar meningkatkan metrik numerik.

Secara keseluruhan, sistem yang diusulkan mampu menjawab permasalahan deteksi dan konversi warna bagi penderita buta warna parsial dengan pendekatan yang adaptif dan efisien, serta berpotensi dikembangkan lebih lanjut sebagai solusi aksesibilitas visual berbasis real-time pada berbagai aplikasi digital.

REFERENSI

- [1] "Blindness and vision impairment," World Health Organization. Accessed: May 09, 2025. [Online]. Available: <https://www.who.int/news-room/fact-sheets/detail/blindness-and-visual-impairment>
- [2] B. Penelitian and P. Kesehatan, "Riset Kesehatan Dasar Laporan Nasional 2007," 2007.
- [3] "Interaction Design Foundation," Interaction Design Foundation. Accessed: May 14, 2025. [Online]. Available: <https://www.interaction-design.org/>
- [4] Z. Zhu and X. Mao, "Image recoloring for color vision deficiency compensation: a survey," Dec. 01, 2021, *Springer Science and Business Media Deutschland GmbH*. doi: 10.1007/s00371-021-02240-0.
- [5] Z. Zhu, M. Toyoura, K. Go, I. Fujishiro, K. Kashiwagi, and X. Mao, "Naturalness- and information-preserving image recoloring for red-green dichromats," *Signal Process Image Commun*, vol. 76, pp. 68–80, Aug. 2019, doi: 10.1016/j.image.2019.04.004.
- [6] Y. Lecun, Y. Bengio, and G. Hinton, "Deep learning," May 27, 2015, *Nature Publishing Group*. doi: 10.1038/nature14539.
- [7] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, and L.-C. Chen, "MobileNetV2: Inverted Residuals and Linear Bottlenecks," Jan. 2018, [Online]. Available: <http://arxiv.org/abs/1801.04381>
- [8] M. Tan and Q. V. Le, "EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks," May 2019, [Online]. Available: <http://arxiv.org/abs/1905.11946>
- [9] F. N. Iandola, S. Han, M. W. Moskewicz, K. Ashraf, W. J. Dally, and K. Keutzer, "SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and <0.5MB model size," Feb. 2016, [Online]. Available: <http://arxiv.org/abs/1602.07360>
- [10] O. Ronneberger, P. Fischer, and T. Brox, "U-Net: Convolutional Networks for Biomedical Image Segmentation," May 2015, [Online]. Available: <http://arxiv.org/abs/1505.04597>
- [11] M. Sokolova and G. Lapalme, "A systematic analysis of performance measures for classification tasks," *Inf Process Manag*, vol. 45, no. 4, pp. 427–437, Jul. 2009, doi: 10.1016/j.ipm.2009.03.002.
- [12] G. Sharma, W. Wu, and E. N. Dalal, "The CIEDE2000 Color-Difference Formula: Implementation Notes, Supplementary Test Data, and Mathematical Observations," *Col Res Appl*, vol. 30, pp. 21–30, 2005, doi: 10.1002/col.
- [13] A. Horé and D. Ziou, "Image quality metrics: PSNR vs. SSIM," in *Proceedings - International Conference on Pattern Recognition*, 2010, pp. 2366–2369. doi: 10.1109/ICPR.2010.579.
- [14] R. C. . Gonzalez and R. E. . Woods, *Digital image processing*. Prentice Hall, 2002.
- [15] A. P. Putra, F. A. Fiolana, and D. A. W. Kusumastutie, "Penerapan Koreksi Warna Pada Citra Bagi Penyandang Buta Warna Parsial," *Jurnal Teknik Elektro dan Komputer TRIAC*, vol. 8, no. 1, pp. 26–29, May 2021, doi: 10.21107/triac.v8i1.10246.
- [16] J. Heaton, "Ian Goodfellow, Yoshua Bengio, and Aaron Courville: Deep learning," *Genet Program Evolvable Mach*, vol. 19, no. 1–2, pp. 305–307, Jun. 2018, doi: 10.1007/s10710-017-9314-z.
- [17] R. C. . Gonzalez and R. E. . Woods, *Digital image processing*. Pearson, 2018.
- [18] X. Wang, Z. Zhu, X. Chen, K. Go, M. Toyoura, and X. Mao, "Fast contrast and naturalness preserving image recolouring for dichromats," *Computers and Graphics (Pergamon)*, vol. 98, pp. 19–28, Aug. 2021, doi: 10.1016/j.cag.2021.04.027.
- [19] L. Chen, Z. Zhu, W. Huang, K. Go, X. Chen, and X. Mao, "Image recoloring for color vision deficiency compensation using Swin transformer," *Neural Comput Appl*, vol. 36, no. 11, pp. 6051–6066, Apr. 2024, doi: 10.1007/s00521-023-09367-2.
- [20] S. Seo and J. Park, "Color Universal Design Neural Network for the Color Vision Deficiencies," Feb. 2025, [Online]. Available: <http://arxiv.org/abs/2502.08671>