

Implementasi Pix2Pix Conditional GAN dan LMS Color Space untuk Koreksi Warna pada Penderita Buta Warna

Milen Juventus Dappa Deke¹, Faisal Muttaqin^{2*}, Fetty Tri Anggraeny³

^{1,2,3} Informatika, Universitas Pembangunan Nasional Veteran Jawa Timur

¹22081010259@student.upnjatim.ac.id

³fettyanggraeny.if@upnjatim.ac.id

*Corresponding author email: faisalmuttaqin.if@upnjatim.ac.id

Abstrak— Gangguan persepsi warna pada individu dengan *Color Vision Deficiency* (CVD) menyebabkan kesulitan dalam membedakan informasi visual berbasis warna, sehingga diperlukan metode untuk meningkatkan kualitas representasi citra. Penelitian ini mengusulkan pendekatan koreksi warna dengan menggabungkan transformasi LMS *color space* dan model Pix2Pix. LMS digunakan untuk merepresentasikan respons fisiologis sel kerucut mata sekaligus menstimulasikan berbagai jenis buta warna, sedangkan Pix2Pix mempelajari pemetaan antara citra simulasi dan citra referensi untuk menghasilkan rekonstruksi warna yang lebih akurat. Data set terdiri dari 2.574 citra dengan tiga jenis CVD, yaitu protanopia, deutanopia, dan tritanopia. Tahap *preprocessing* meliputi validasi pasangan citra, *resizing* 256×256 piksel, serta pembagian data 70% pelatihan dan 30% pengujian. Evaluasi dilakukan menggunakan PSNR, Delta E, SSIM, serta uji pengguna terhadap 15 responden CVD. Hasil menunjukkan performa terbaik pada *learning rate* 0.0003 dengan PSNR 22.71 dB (protanopia), 37.45 dB (deutanopia), dan 35.90 dB (tritanopia). Delta E terendah masing-masing 2.01, 1.89, dan 2.15, sedangkan SSIM mencapai 0.46, 0.83, dan 0.84. Pada uji responden, metode RGB menghasilkan akurasi 83.81% (protanopia), 81.27% (deutanopia), dan 82.86% (tritanopia), sedangkan LMS masing-masing 37.14%, 71.75%, dan 62.54%. Secara keseluruhan, kombinasi LMS *color space* dan Pix2Pix terbukti efektif dalam meningkatkan kualitas koreksi warna citra bagi penderita CVD, meskipun masih diperlukan pengembangan lebih lanjut untuk optimalisasi hasil.

Kata Kunci— Koreksi Warna, Buta Warna, LMS, Pix2Pix, Peak Signal-to-Noise, Delta E.

I. PENDAHULUAN

Perkembangan teknologi pada era digital telah membawa perubahan besar dalam berbagai aspek kehidupan manusia, terutama dalam cara memperoleh, mengolah, dan memahami informasi. Informasi visual menjadi salah satu media komunikasi yang paling dominan karena banyak aktivitas sehari-hari bergantung pada kemampuan individu dalam mengenali warna dan bentuk. Dalam dunia pendidikan modern, visualisasi berwarna banyak digunakan pada berbagai media digital seperti platform *e-learning*, materi presentasi, aplikasi interaktif, hingga simulasi berbasis komputer [1]. Oleh karena itu, kemampuan persepsi warna yang baik menjadi faktor penting untuk mendukung efektivitas proses pembelajaran serta mempermudah akses terhadap informasi visual [2].

Namun, tidak semua individu memiliki kemampuan penglihatan warna yang normal. Sebagian orang mengalami *Color Vision Deficiency* (CVD), yaitu gangguan penglihatan yang menyebabkan kesulitan dalam membedakan warna tertentu, terutama pada spektrum merah dan hijau. Kondisi ini umumnya bersifat genetik dan berkaitan dengan kelainan pada sel kerucut di retina yang berperan dalam mendeteksi warna [3]. Akibatnya, individu dengan CVD dapat mengalami kesulitan dalam memahami informasi visual, baik dalam konteks pendidikan maupun aktivitas digital lainnya, seperti membaca grafik, mengenali tanda peringatan, atau membedakan elemen antarmuka pada perangkat teknologi. Dalam konteks tersebut, perkembangan teknologi digital membuka peluang besar untuk mengatasi permasalahan persepsi warna pada penderita buta warna. Penelitian yang dilakukan oleh Elrefaei [4], memanfaatkan LMS (*Long, Medium, Short*) *color Space* untuk melakukan koreksi warna pada penderita buta warna. LMS digunakan karena mampu merepresentasikan respons fisiologis sel kerucut manusia terhadap panjang gelombang cahaya sehingga lebih sesuai dengan mekanisme penglihatan manusia dibandingkan ruang warna RGB. Hasil penelitian menunjukkan bahwa pendekatan tersebut mampu meningkatkan representasi warna pada citra. Namun, penelitian tersebut masih berfokus pada transformasi warna secara langsung dan belum memanfaatkan LMS sebagai representasi warna dalam pendekatan *deep learning* untuk proses koreksi warna.

Di sisi lain, perkembangan *deep learning* telah menghadirkan berbagai metode berbasis *Generative Adversarial Network* (GAN). Penelitian yang dilakukan oleh Lin [5], menunjukkan bahwa Pix2Pix merupakan metode yang efektif untuk proses *image-to-image translation* karena mampu mempelajari hubungan antara citra masukan dan citra target secara berpasangan. Selain itu, Zhao dkk. [6], menunjukkan bahwa Pix2Pix mampu menghasilkan rekonstruksi citra dengan kualitas visual yang baik melalui proses pembelajaran hubungan antar citra. Meskipun demikian, penelitian yang mengintegrasikan LMS *Color Space* dengan model Pix2Pix untuk koreksi warna pada penderita buta warna masih terbatas. Oleh karena itu, penelitian ini mengintegrasikan LMS *Color Space* dengan Pix2Pix untuk menghasilkan koreksi warna yang lebih optimal.

Berdasarkan permasalahan tersebut, penelitian ini bertujuan untuk mengimplementasikan metode LMS dan Pix2Pix dalam upaya meningkatkan persepsi warna pada individu dengan buta

warna. Melalui integrasi antara pendekatan yang merepresentasikan sistem penglihatan manusia dan teknologi *deep learning*, diharapkan model yang dikembangkan mampu menghasilkan citra dengan kontras warna yang lebih jelas sehingga informasi visual dapat dipahami dengan lebih mudah. Selain itu, penelitian ini diharapkan dapat memberikan kontribusi dalam pengembangan teknologi yang lebih inklusif serta mendukung pemanfaatan inovasi digital untuk menyediakan akses informasi yang berkelanjutan bagi seluruh pengguna.

II. LANDASAN TEORI DAN TINJAUAN PUSTAKA

A. Color Vision Devisiensi

Buta warna adalah kondisi ketika seseorang mengalami kesulitan membedakan warna tertentu yang biasanya masih dapat dikenali oleh individu dengan penglihatan normal. Gangguan ini umumnya dibagi menjadi tiga jenis, yaitu *monokromasi* (buta warna total), *dikromasi* (hanya dua sel kerucut yang berfungsi), dan *anomalous trikromasi*, yaitu ketika ketiga sel kerucut masih berfungsi tetapi salah satunya tidak bekerja secara optimal. Dari ketiga jenis tersebut, *anomalous trikromasi* atau buta warna parsial merupakan yang paling sering terjadi, terutama deutanomali yang menyebabkan kesulitan dalam membedakan warna merah dan hijau [7]. Berdasarkan penyebabnya, buta warna dapat bersifat bawaan (genetik) maupun diperoleh akibat faktor lain seperti *Shaken Baby Syndrome*, cedera atau trauma pada otak dan retina, serta paparan sinar ultraviolet. Buta warna genetik berkaitan dengan kromosom X yang dibawa oleh perempuan dan dapat diturunkan kepada anak-anaknya, sehingga kondisi ini lebih sering dialami oleh laki-laki [8]. Pada penderita buta warna, mata tidak mampu menghasilkan atau merespons pigmen warna secara optimal sehingga proses pembedaan warna tidak berlangsung secara normal.

B. Koreksi Warna

Koreksi warna pada citra digital bertujuan untuk menyesuaikan nilai *piksel* sehingga warna yang dihasilkan menjadi lebih akurat dan sesuai dengan referensi atau kondisi aslinya. Pendekatan tradisional umumnya memanfaatkan pemetaan matematis, seperti regresi linear atau transformasi *polinomial*, untuk menyesuaikan kombinasi nilai RGB ke dalam ruang warna yang menjadi target. Metode ini bekerja dengan memodelkan hubungan antar komponen warna sehingga perbedaan warna pada citra dapat dikurangi dan tampilan visual menjadi lebih konsisten dengan kondisi sebenarnya [9]. Selain itu, proses koreksi warna juga berperan dalam meningkatkan kualitas citra dengan memperbaiki distribusi warna, meningkatkan kontras visual, serta membuat objek pada citra lebih mudah dikenali dan dianalisis [10].

C. Ruang Warna LMS

Ruang warna LMS *color space* merupakan representasi warna yang didasarkan pada respons tiga jenis sel kerucut pada retina manusia, yaitu L (*Long*), M (*Medium*), dan S (*Short*). Sel L

peka terhadap panjang gelombang yang berkaitan dengan warna merah, sel M terhadap warna hijau, dan sel S terhadap warna biru [11]. Berbeda dengan RGB *color model* yang digunakan pada perangkat digital, ruang warna LMS menggambarkan bagaimana mata manusia merespons cahaya secara biologis. Oleh karena itu, ruang warna ini sering digunakan dalam penelitian penglihatan, simulasi buta warna, dan koreksi warna karena lebih sesuai dengan cara kerja sistem visual manusia [12]. Berikut adalah persamaan konversi ruang RGB ke ruang warna.

$$\begin{bmatrix} L \\ M \\ S \end{bmatrix} = \begin{bmatrix} 0,31399022 & 0,63951294 & 0,04649755 \\ 0,15537241 & 0,75789446 & 0,08670142 \\ 0,01775239 & 0,10944209 & 0,87256922 \end{bmatrix} \begin{bmatrix} R \\ G \\ B \end{bmatrix} \quad (1)$$

Keterangan :

[R, G, B] : Nilai piksel kanal *Red, Green, Blue*

[L, M, S] : Nilai piksel kanal *Long, Medium, Short*

D. Pix2Pix

Pix2Pix merupakan metode *image-to-image translation* berbasis *Generative Adversarial Network* yang digunakan untuk mengubah suatu citra menjadi citra lain dengan mempelajari hubungan pasangan data [13]. Model ini terdiri dari dua komponen utama, yaitu *generator* yang bertugas menghasilkan citra baru dari citra masukan, dan *discriminator* yang berfungsi membedakan antara citra asli dan citra hasil generasi model. Selama proses pelatihan, kedua komponen tersebut saling berkompetisi sehingga generator dapat menghasilkan citra yang semakin mendekati citra target [14]. Karena mampu mempelajari hubungan langsung antara citra input dan output, Pix2Pix banyak digunakan dalam berbagai aplikasi seperti koreksi warna, peningkatan kualitas citra, segmentasi, serta transformasi gaya gambar [15].

E. Peak Signal-to-Noise Ratio

Peak Signal-to-Noise Ratio (PSNR) merupakan metrik yang digunakan untuk mengukur kualitas suatu citra hasil rekonstruksi dibandingkan dengan citra asli. Nilai PSNR dihitung berdasarkan perbedaan antara piksel citra asli dan citra hasil pemrosesan menggunakan nilai *Mean Squared Error* (MSE) [16]. Semakin tinggi nilai PSNR, maka semakin kecil perbedaan antara kedua citra tersebut sehingga kualitas citra hasil rekonstruksi dianggap semakin baik [17]. Berikut persamaan matriks PNSR.

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

Keterangan :

MAX : Nilai maksimum Piksel

MSE : *Mean Squared Error* antara citra asli dan citra hasil

F. SSIM

Structural Similarity Index Measure (SSIM) merupakan metrik yang digunakan untuk menilai kemiripan antara dua citra dengan memperhatikan karakteristik *luminance*, *contrast*, dan *structure* [18]. Metrik ini mampu menggambarkan kualitas visual citra berdasarkan persepsi manusia terhadap kesamaan struktur gambar.

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (3)$$

Keterangan :

μ_x, μ_y : Nilai rata rata x dan y

σ_x^2, σ_y^2 : Variasi citra x dan y

σ_{xy} : Kovarians antara x dan y

C_1, C_2 : konstanta kecil untuk stabilisasi pembagian

G. Delta E

Delta E merupakan ukuran yang digunakan untuk mengetahui tingkat perbedaan warna antara dua warna dalam ruang warna *CIELAB color space*. Nilai Delta E menunjukkan seberapa besar perbedaan persepsi warna yang dapat dilihat oleh mata manusia. Semakin kecil nilai Delta E, maka semakin kecil perbedaan warna antara citra hasil dan citra referensi, sehingga warna yang dihasilkan dianggap semakin mendekati warna asli [9]. Berikut persamaan matriks Delta E.


$$\Delta E_{76} = \sqrt{(L_1 - L_2)^2 + (a_1 - a_2)^2 + (b_1 - b_2)^2} \quad (4)$$

Keterangan :

L,a,b : Komponen warna ruang LAB

III. METODE

Penelitian ini dilakukan melalui tahapan yang sistematis dan terstruktur untuk memastikan setiap proses berjalan dengan baik. Dengan demikian, hasil penelitian yang diperoleh diharapkan mampu menjawab permasalahan yang dikaji.



Gbr 1. Alur Penelitian

A. Studi Literatur

Alur penelitian dimulai dengan dilakukan studi literatur untuk mengumpulkan berbagai referensi ilmiah yang berkaitan

dengan CVD, ruang warna LMS, serta metode *deep learning* Pix2Pix. Tahap ini bertujuan membangun landasan teori yang kuat serta memahami metode yang relevan untuk diterapkan dalam penelitian.

B. Pengumpulan Data

Pada tahap pengumpulan data, penelitian ini menggunakan dataset "*Color Blindness Simulation & Correction*" dari Kaggle yang dikembangkan oleh sakshivayavahare20 [19]. Dataset tersebut menyediakan pasangan citra yang terdiri dari citra *original*, citra *simulated*, dan citra *corrected* untuk berbagai tipe buta warna, seperti *protanopia*, *deutanopia*, dan *tritanopia*, sehingga relevan sebagai dasar pembelajaran model dalam memahami perbedaan kondisi warna. Namun, penelitian ini hanya memanfaatkan citra *original* dan *corrected*, karena proses simulasi buta warna dilakukan secara mandiri oleh peneliti.

C. Pemrosesan Data

Setelah data terkumpul, dilakukan tahap *preprocessing* untuk menyiapkan data sebelum masuk ke proses utama. Tahap ini diawali dengan validasi data set untuk memastikan setiap citra *original* memiliki pasangan citra *corrected* yang sesuai dengan jenis buta warna yang digunakan, yaitu *protanopia*, *deutanopia*, dan *tritanopia*. Selanjutnya, seluruh citra diubah ukurannya menjadi 256×256 piksel guna menyeragamkan dimensi data dan menyesuaikan kebutuhan model Pix2Pix. Setelah itu, dataset dibagi menjadi 70% data training dan 30% data testing. Pada tahap pembentukan data, citra original ditransformasikan ke ruang warna LMS dan disimulasikan sesuai jenis buta warna yang diuji untuk menghasilkan citra masukan, sedangkan citra *corrected* digunakan sebagai citra target. Pembagian data set dilakukan agar model dapat dilatih dan dievaluasi secara objektif. Distribusi data yang digunakan pada penelitian ini ditunjukkan pada Tabel 1.

Tabel 1. Pembagian data set


Kategori	Presentasi	Jumlah Data
Training	70%	1801
Testing	30%	773

Pada tahap berikutnya, citra dikonversi ke dalam ruang warna LMS (*Long, Medium, Short*), yang merepresentasikan respons fisiologis sel kerucut manusia terhadap panjang gelombang cahaya menggunakan matriks konversi. Setelah konversi, dilakukan simulasi buta warna dengan mengurangi nilai pada kanal LMS tertentu untuk merepresentasikan keterbatasan persepsi warna yang dialami penderita CVD.

D. Koreksi Warna Pix2Pix


Tahap selanjutnya adalah proses koreksi warna menggunakan model Pix2Pix, yaitu salah satu metode berbasis *Generative Adversarial Network* (GAN) yang dirancang untuk tugas *paired image-to-image translation*. Pada penelitian ini, citra

hasil simulasi buta warna pada ruang warna LMS digunakan sebagai citra masukan, sedangkan citra *corrected* digunakan sebagai citra *ground truth*. Melalui proses pembelajaran pasangan citra tersebut, model Pix2Pix diharapkan mampu mempelajari hubungan antara citra masukan dan citra target sehingga menghasilkan citra hasil koreksi dengan representasi warna yang lebih baik. Dengan arsitektur seperti gbr 2 dan gbr 3.



Gbr 2. Generator Pix2Pix

Gbr 2. merupakan generator Pix2Pix menggunakan arsitektur U-Net dengan struktur *encoder-decoder* yang dilengkapi *skip connection*. Bagian *encoder* terdiri atas beberapa lapisan convolution yang berfungsi mengekstraksi fitur citra, sedangkan *decoder* melakukan rekonstruksi citra hasil koreksi warna. *Skip connection* digunakan untuk mempertahankan informasi spasial dan detail citra dari *encoder* ke *decoder* sehingga kualitas hasil rekonstruksi tetap terjaga.



Gbr 3. Discriminator Pix2Pix

Gbr 3. *discriminator* menggunakan pendekatan *PatchGAN* yang mengevaluasi keaslian citra berdasarkan patch berukuran 70×70 . *Input discriminator* berupa pasangan citra input dengan citra target maupun pasangan citra input dengan citra hasil generator. Arsitektur *discriminator* terdiri atas beberapa lapisan convolution 4×4 dengan *stride* 2 yang diikuti *Batch Normalization* dan fungsi aktivasi *LeakyReLU*. Pendekatan ini memungkinkan *discriminator* mempelajari pola tekstur lokal dan perbedaan detail *piksel* secara lebih efektif.

Proses pelatihan menggunakan *Adam Optimizer* dengan parameter $\beta_1 = 0,5$ dan $\beta_2 = 0,999$. Model dilatih selama 80

epoch dengan *batch size* 16 menggunakan tiga skenario *learning rate*, yaitu 0,0002, 0,0003, dan 0,0004 untuk mengevaluasi pengaruh nilai *learning rate* terhadap kinerja model. Fungsi objektif generator merupakan kombinasi *Adversarial Loss* dan *L1 Loss*. *Adversarial Loss* digunakan untuk menghasilkan citra yang realistis dan sulit dibedakan oleh *discriminator*, sedangkan *L1 Loss* digunakan untuk meminimalkan perbedaan antara citra hasil generator dan citra target. Pada penelitian ini, *L1 Loss* diberikan bobot sebesar 100 sehingga model tidak hanya menghasilkan citra yang realistis tetapi juga mempertahankan kesesuaian warna terhadap citra referensi..

E. Evaluasi

Proses penelitian kemudian diakhiri dengan tahap evaluasi yang bertujuan mengukur kualitas hasil koreksi warna. Evaluasi dilakukan menggunakan PSNR untuk menilai tingkat kemiripan antara citra hasil koreksi dan citra referensi, SSIM untuk mengukur kesamaan struktur citra, serta Delta E untuk mengukur perbedaan warna secara perseptual. Hasil dari ketiga metrik ini menjadi indikator keberhasilan metode yang diterapkan.

IV. HASIL DAN PEMBAHASAN

Proses penelitian diawali dengan validasi data set, kemudian dilanjutkan dengan tahap *preprocessing* berupa resize citra menjadi 256×256 *piksel* agar memiliki dimensi yang seragam sebelum dimasukkan ke dalam model.

Tabel 2. Hasil Validasi Data set


Tipe CVD	Jumlah Data
<i>Deutanopia</i>	858
<i>Protanopia</i>	858
<i>Tritanopia</i>	858

Tabel 2 menyajikan ringkasan dataset setelah proses validasi data. Data set terdiri atas tiga kategori buta warna, yaitu *deutanopia*, *protanopia*, dan *tritanopia*, yang masing-masing berjumlah 858 pasangan citra sehingga total data set yang digunakan mencapai 2.574 pasangan citra. Hasil validasi menunjukkan bahwa setiap citra original memiliki pasangan citra *corrected* yang sesuai pada masing-masing kategori, sehingga data set dapat digunakan dalam proses pelatihan dan pengujian model secara konsisten. Selain itu, jumlah data yang seimbang pada setiap kategori diharapkan dapat mengurangi potensi bias selama proses pembelajaran model.



Gbr 4. Hasil Pemrosesan Data

Gbr 4 menunjukkan hasil pemrosesan data setelah citra diubah ukurannya menjadi 256×256 piksel. Selanjutnya, citra dikonversi dari ruang warna RGB ke ruang warna LMS.



Gbr 5. (a) Simulasi Protanopia, (b) Simulasi Deutanopia, (c) Simulasi Tritanopia

Gbr 5 menampilkan hasil simulasi buta warna yang terdiri dari beberapa jenis gangguan penglihatan warna, yaitu (a) simulasi *protanopia*, (b) simulasi *deutanopia*, dan (c) simulasi *tritanopia*. Proses simulasi ini bertujuan untuk merepresentasikan bagaimana penderita buta warna melihat suatu citra, sehingga perbedaan persepsi warna dapat dianalisis secara lebih mendalam. simulasi dilakukan dengan cara mengurangi salah satu kanal pada ruang warna LMS untuk menyesuaikan karakteristik masing-masing jenis buta warna. Pengurangan kanal L digunakan untuk mensimulasikan *protanopia* yang berkaitan dengan rendahnya sensitivitas terhadap warna merah, sedangkan pengurangan kanal M menggambarkan *deutanopia* yang memengaruhi persepsi warna hijau. Adapun pengurangan kanal S digunakan untuk merepresentasikan *tritanopia* yang berkaitan dengan gangguan dalam membedakan warna biru dan kuning.

Berdasarkan hasil evaluasi kinerja model Pix2Pix pada tiga jenis buta warna, peningkatan *learning rate* memberikan pengaruh positif terhadap kualitas citra hasil koreksi. Hal ini ditunjukkan oleh tren kenaikan nilai PSNR dan SSIM yang diikuti dengan penurunan nilai Delta E pada seluruh skenario pengujian..



Gbr 6. Hasil Kinerja Model Pix2Pix Pada Protanopia



Gbr 7. Hasil Kinerja Model Pix2Pix Pada Deutanopia



Gbr 8. Hasil Kinerja Model Pix2Pix Pada Tritanopia

Gbr 6, 7, dan 8 menunjukkan kinerja model Pix2Pix dalam proses koreksi warna yang ditunjukkan melalui kemampuannya dalam mempelajari hubungan antara citra masukan dan citra referensi dari pasangan data yang tersedia. Melalui proses pelatihan tersebut, model mampu menghasilkan citra dengan distribusi warna yang lebih seimbang sekaligus mempertahankan struktur visual, sehingga hasil rekonstruksi menjadi lebih mendekati citra asli. Secara keseluruhan, hasil matriks citra pada setiap kondisi dan variasi buta warna menunjukkan karakteristik visual yang konsisten untuk masing-masing jenis gangguan penglihatan warna. Detail lengkap matriks citra pada setiap *learning rate* disajikan pada Gbr 9, 10, dan 11.

--- TABEL KINERJA EVALUASI ---			
Jenis Buta Warna	Avg PSNR (dB)	Avg SSIM	Avg Delta E
Protanopia	13.482770	0.460623	39.379785
Deutanopia	24.063384	0.843992	11.154336
Tritanopia	22.383553	0.831991	12.907872

Gbr 9. Hasil Kinerja Model Pada Skenario Pertama

Gbr 9. skenario pertama menggunakan *learning rate* sebesar 0.0002. Pada skenario ini, performa model menunjukkan variasi tergantung jenis buta warna yang diuji. Rata-rata PSNR berada pada kisaran 13.48 dB hingga 24.06 dB, sedangkan nilai Delta E berkisar antara 11.15 hingga 39.38. Dari aspek kesamaan struktur, nilai Avg SSIM mencapai 0.84 pada Deutanopia dan 0.83 pada Tritanopia, namun menurun signifikan hingga 0.46 pada Protanopia. Hasil ini menunjukkan bahwa kualitas koreksi citra belum konsisten di semua jenis kondisi. Model mampu memberikan performa yang cukup baik pada Deutanopia dan Tritanopia, tetapi kurang optimal pada Protanopia yang ditandai dengan distorsi visual yang tinggi serta nilai Delta E yang besar. *Learning rate* yang kecil menyebabkan proses pembelajaran berjalan lebih lambat sehingga penyesuaian warna dan struktur pada model belum sepenuhnya maksimal.

--- TABEL KINERJA EVALUASI ---

Jenis Buta Warna	Avg PSNR (dB)	Avg SSIM	Avg Delta E
Protanopia	13.152439	0.458439	40.505669
Deuteranopia	22.707712	0.832481	14.149362
Tritanopia	22.405706	0.839002	13.039294

Gbr 10. Hasil Kinerja Model Pada Skenario Kedua

Skenario kedua menggunakan *learning rate* 0.0003. Pada konfigurasi ini, performa model masih menunjukkan variasi yang signifikan berdasarkan jenis buta warna yang diuji. Rata-rata PSNR berada pada kisaran 13.15 dB hingga 22.71 dB, sedangkan nilai Delta E berkisar antara 13.04 hingga 40.51. Dari aspek kesamaan struktur, nilai Avg SSIM berada di angka 0.83 pada Deuteranopia dan 0.84 pada Tritanopia, namun tetap rendah di angka 0.46 pada Protanopia. Hasil ini mengindikasikan bahwa peningkatan *learning rate* menjadi 0.0003 belum memberikan perubahan performa yang signifikan secara menyeluruh. Model masih menghadapi kesulitan optimalisasi pada jenis Protanopia yang ditandai dengan distorsi visual yang tinggi (SSIM = 0.46) serta deviasi warna yang besar (Delta E = 40.51), sementara hasil pada Deuteranopia dan Tritanopia relatif lebih stabil dan mampu mempertahankan struktur visual dengan cukup baik.

--- TABEL KINERJA EVALUASI ---

Jenis Buta Warna	Avg PSNR (dB)	Avg SSIM	Avg Delta E
Protanopia	13.300913	0.470150	39.712191
Deuteranopia	22.747867	0.829837	13.779517
Tritanopia	21.282038	0.828629	14.783490

Gbr 11. Hasil Kinerja Model Pada Skenario Ketiga

Skenario ketiga menggunakan *learning rate* sebesar 0.0004. Pada skenario ini, performa model tetap bervariasi tergantung jenis buta warna yang diuji. Rata-rata PSNR berada pada rentang 13.30 dB hingga 22.75 dB, sedangkan Delta E berkisar antara 13.78 hingga 39.71. Dari aspek struktur, Avg SSIM mencapai 0.83 pada Deuteranopia dan Tritanopia, namun turun menjadi 0.47 pada Protanopia. Hasil ini menunjukkan bahwa kualitas koreksi citra masih belum stabil. Model cukup baik dalam menjaga struktur visual pada Deuteranopia dan Tritanopia, tetapi kurang optimal pada Protanopia yang ditandai distorsi visual dan nilai Delta E yang tinggi. *Learning rate* 0.0004 membuat proses pembelajaran lebih lambat sehingga peningkatan kualitas warna dan struktur citra belum maksimal.

Untuk melengkapi evaluasi numerik, validasi model juga dilakukan melalui formulir berbasis GUI interaktif yang berisi sejumlah pertanyaan pilihan ganda. Pengujian ini melibatkan 15 responden dengan berbagai jenis CVD. Partisipan diminta membandingkan citra RGB asli dengan citra hasil koreksi warna, kemudian memilih jawaban yang paling sesuai untuk menilai efektivitas model dalam meningkatkan persepsi warna pengguna. Berdasarkan hasil evaluasi sebelumnya, skenario kedua dengan *learning rate* 0.0003 dipilih sebagai model terbaik, kemudian diuji langsung kepada pengguna dengan buta warna. Hasil jawaban responden ditampilkan pada Tabel 3.

Tabel 3. Hasil Pengujian Responden

Jenis Buta Warna	RGB	Akurasi	LM S	Akurasi	Total Akurasi
Protanopia	264	83.81%	117	37.14%	60.48%
Deuteranopia	256	81.27%	226	71.75%	76.51%
Tritanopia	261	82.86%	197	62.54%	72.70%

Tabel 3 menunjukkan hasil pengujian terhadap pengguna dengan buta warna menunjukkan bahwa tingkat akurasi model berbeda pada setiap jenis CVD. Pada Protanopia, metode RGB menghasilkan 264 respons dengan akurasi 83.81%, sedangkan LMS hanya mencapai 37.14% dengan total akurasi 60.48%. Pada Deuteranopia, RGB memperoleh 256 respons dengan akurasi 81.27% dan LMS 71.75%, sehingga total akurasi mencapai 76.51%. Sementara itu, pada Tritanopia, RGB menghasilkan 261 respons dengan akurasi 82.86% dan LMS 62.54%, dengan total akurasi 72.70%. Secara keseluruhan, hasil ini menunjukkan bahwa metode RGB memberikan performa yang lebih stabil dibandingkan LMS, terutama pada Protanopia yang memiliki penurunan akurasi paling signifikan.

V. KESIMPULAN

Penelitian ini bertujuan meningkatkan persepsi warna pada citra bagi penderita buta warna menggunakan transformasi ruang warna LMS dan model Pix2Pix. Hasil menunjukkan bahwa model mampu mempelajari hubungan antara citra masukan dan referensi sehingga menghasilkan koreksi warna yang lebih baik sekaligus mempertahankan struktur visual. Evaluasi menggunakan metrik PSNR, Delta E, dan SSIM pada tiga variasi *learning rate* (0.0002, 0.0003, dan 0.0004) menunjukkan bahwa performa model belum mengalami peningkatan yang signifikan dan konsisten pada seluruh skenario. Berdasarkan hasil pengujian, skenario terbaik diperoleh pada *learning rate* 0.0003 karena memberikan performa paling stabil dibandingkan konfigurasi lainnya, dengan nilai PSNR berada pada kisaran 13.15–22.71 dB, Delta E 13.04–40.51, serta SSIM mencapai 0.83 pada Deuteranopia, 0.84 pada Tritanopia, dan 0.46 pada Protanopia. Hasil pengujian juga didukung oleh validasi pengguna CVD, yang menunjukkan bahwa tingkat akurasi berbeda pada setiap jenis buta warna, dengan performa terbaik pada Deuteranopia dengan 76.51%, diikuti Tritanopia dengan 72.70%, dan terendah pada Protanopia dengan 60.48%. Secara keseluruhan, integrasi LMS *color space* dengan Pix2Pix terbukti efektif dalam meningkatkan kualitas koreksi warna citra, namun masih memerlukan pengembangan lebih lanjut terutama untuk meningkatkan performa pada kasus Protanopia.

UCAPAN TERIMA KASIH

Ucapan terima kasih disampaikan kepada seluruh pihak yang telah memberikan dukungan, bantuan, dan kontribusi sehingga penelitian ini dapat terlaksana dengan baik hingga selesai.

Penulis menyadari bahwa tanpa dukungan tersebut, penelitian ini tidak akan berjalan dengan lancar.

REFERENSI

- [1] D. Studi, U. X. Ui, S. Prihatmoko, and D. Susatyono, "Jurnal Publikasi Ilmu Komputer dan Multimedia Eksplorasi Efek Warna terhadap Keterlibatan Pengguna dalam Animasi".
- [2] M. Elfalah *et al.*, "The Impact of Color Vision Deficiency on the Capability of Ophthalmologists to Diagnose Benign and Malignant Choroidal Tumors," 2023.
- [3] A. Almustanyir, "A Global Perspective of Color Vision Deficiency : Awareness , Diagnosis , and Lived Experiences," pp. 1–16, 2025.
- [4] L. A. Elrefaei, "Smartphone Based Image Color Correction for Color Blindness," pp. 104–119.
- [5] E. Lin, "Comparative Analysis of Pix2Pix and CycleGAN for Image-to- Image Translation," vol. 39, pp. 915–925, 2023.
- [6] X. Zhao, H. Yu, and H. Bian, "Image to Image Translation Based on Differential Image Pix2Pix Model," 2023, doi: 10.32604/cmc.2023.041479.
- [7] S. Saini, E. F. Dungga, and I. Sulistiani, "Evaluasi Pemeriksaan Tes Buta Warna Menggunakan Metode Ishihara Berbasis Google Form Menggunakan Buku Ishihara," vol. 2, pp. 42–51, 2022, doi: 10.37311/ijpe.v2i1.15855.
- [8] M. Nainggolan and J. E. Candra, "Rancang Bangun Alat Bantu Deteksi Warna Bagi Penderita Buta Warna Dengan Output Suara Berbasis Internet Of Things (IoT)," vol. 1, no. 2, 2023.
- [9] A. Kucuk, G. D. Finlayson, R. Mantiuk, and M. Ashraf, "Performance Comparison of Classical Methods and Neural Networks for Colour Correction," 2023.
- [10] F. Muttaqin *et al.*, "A Combination Method of ROI , CLAHE , and DenseNet-169 for Hip Osteoarthritis Detection," vol. 15, no. 3, pp. 22690–22697, 2025.
- [11] A. P. Adyani, F. T. Anggraeny, and E. Y. Puspaningrum, "Image Color Correction for Color Vision Deficiency Using ResNet and CycleGAN," vol. 8, no. 1, 2025, doi: 10.32877/bt.v8i1.2506.
- [12] A. Stockman and A. T. Rider, "Formulae for generating standard and individual human cone spectral sensitivities," no. June, pp. 818–840, 2023, doi: 10.1002/col.22879.
- [13] S. Zhou *et al.*, "A CycleGAN-Pix2pix framework for multi-objective 3D urban morphology optimization : enhancing thermal performance in high-density areas," *Sustain. Cities Soc.*, vol. 126, no. February, p. 106400, 2025, doi: 10.1016/j.scs.2025.106400.
- [14] P. Gan, "Generating Synthetic Images for Healthcare with Novel Deep," 2022.
- [15] J. Sun, Y. Du, C. Y. Li, T. Wu, B. H. Yang, and G. S. P. Mok, "Pix2Pix generative adversarial network for low dose myocardial perfusion SPECT denoising," vol. 12, no. 7, pp. 3539–3555, 2022, doi: 10.21037/qims-21-1042.
- [16] M. Yaqub *et al.*, "Review Article Deep Learning-Based Image Reconstruction for Different Medical Imaging Modalities," vol. 2022, 2022.
- [17] F. Hasan, Y. W. Sani, S. Nicholas, and F. T. Anggraeny, "Evaluasi Kualitas Citra Rontgen Dada Menggunakan PSNR dan MSE Setelah Penerapan Teknik Peningkatan Citra," pp. 203–214.
- [18] F. Muttaqin, L. Rahmadi, and D. Januarita, "Implementation of CLAHE and CLAGAMTWO in Medical Images," vol. 8106, pp. 22–27, 2025.
- [19] sakshivyavahare20, "Color Blindness Simulation & Correction," kaggle. [Online]. Available: <https://www.kaggle.com/datasets/sakshivyavahare20/color-blindness-simulation-and-correction?>