

# Pewarnaan Otomatis Citra *Grayscale* Berbasis Model *Deep Learning* Untuk Peningkatan Interpretasi Visual

<sup>1\*</sup> Alindro Septo Nugroho, <sup>2</sup> Julian Sahertian, <sup>3</sup> Rony Heri Irawan

<sup>1 2 3</sup> Teknik Informatika, Universitas Nusantara PGRI Kediri

E-mail: <sup>1</sup> [alindrosepto9@gmail.com](mailto:alindrosepto9@gmail.com), <sup>2</sup> [juliansahertian@unpkediri.ac.id](mailto:juliansahertian@unpkediri.ac.id), <sup>3</sup> [Rony@unpkediri.ac.id](mailto:Rony@unpkediri.ac.id)

Penulis Korespondens : Alindro Septo Nugroho

**Abstrak**—Pewarnaan otomatis citra *grayscale* menggambarkan tantangan besar dalam bidang pengolahan citra digital. Citra *grayscale*, meskipun mengandung informasi spasial yang melimpah, mengalami hilangnya dimensi warna yang penting, yang mungkin membatasi kemampuan interpretasi visualnya. Studi ini berorientasi pada pengembangan dan penilaian model *deep learning* yang ditujukan untuk mengotomatisasi proses pewarnaan gambar *grayscale*. Metodologi yang diterapkan mencakup pelatihan jaringan saraf tiruan konvolusional (CNN) pada dataset gambar berwarna, dengan gambar *grayscale* sebagai input dan gambar berwarna sebagai output yang diinginkan. Pelatihan difokuskan pada pembelajaran pemetaan yang rumit dari intensitas piksel *grayscale* menuju saluran warna a dan b dalam ruang warna LAB. Hasil pengujian yang melibatkan lima gambar sampel menunjukkan bahwa model dapat menghasilkan pewarnaan yang secara visual mirip dengan citra sumber aslinya. Evaluasi kuantitatif dengan metrik *Mean Absolute Error (MAE)*, *Peak Signal-to-Noise Ratio (PSNR)*, dan *Structural Similarity Index (SSIM)* menunjukkan performa yang unggul, dengan nilai rata-rata SSIM sebesar 0.9963, menandakan kualitas pewarnaan yang *Sangat Baik*. Penemuan ini menekankan potensi *besar* *deep learning* dalam menghidupkan kembali informasi warna yang hilang dari gambar *grayscale*, membuka peluang untuk aplikasi kreatif dalam bidang restorasi foto bersejarah dan visualisasi data.

**Kata Kunci**— Deep learning, Pewarnaan Citra, PSNR, SSIM, *Grayscale*.

**Abstract**— Automatic coloring of grayscale images represents a major challenge in the field of digital image processing. Grayscale images, although containing abundant spatial information, suffer from the loss of important color dimensions, which may limit their visual interpretability. This study is oriented towards the development and assessment of a deep learning model aimed at automating the coloring process of grayscale images. The applied methodology includes training a convolutional artificial neural network (CNN) on a dataset of color images, with grayscale images as input and color images as the desired output. The training is focused on learning a complex mapping from the intensity of the grayscale pixels to the a and b color channels in color space. Test results involving five sample images show that the model can produce coloring that is visually similar to the original source image. Quantitative evaluation with the metrics of Mean Absolute Error (MAE), Peak Signal-to-Noise Ratio (PSNR), and Structural Similarity Index (SSIM) metrics show superior performance, with an average SSIM value of 0.9963, indicating “Excellent” coloring quality. This discovery highlights the great potential of deep learning in reviving lost color information from grayscale images, opening up opportunities for creative applications in the fields of historic photo restoration and data visualization. historic photos and data visualization.

**Keywords**— Deep learning, Image Colorization, PSNR, SSIM, *Grayscale*.

This is an open access article under the CC BY-SA License.



## I. PENDAHULUAN

Citra *grayscale*, atau monokrom, memiliki signifikansi historis dalam fotografi dan representasi visual. Namun, citra ini secara intrinsik kehilangan informasi warna yang krusial untuk pemahaman kontekstual dan pengalaman visual mendalam. Mewarnai citra *grayscale* secara manual merupakan pekerjaan yang memakan waktu, memerlukan keahlian tinggi, dan sangat subjektif, menjadikannya tidak efisien untuk volume citra besar. Dengan kemajuan pesat dalam kecerdasan buatan, khususnya deep learning, otomatisasi proses pewarnaan ini menjadi semakin mungkin. Pewarnaan otomatis citra *grayscale* adalah masalah *ill-posed* karena satu piksel *grayscale* dapat memiliki beragam kemungkinan representasi warna pada citra aslinya. Meskipun demikian, model deep learning dapat mempelajari pola kompleks dari konteks spasial dan makna citra untuk merekonstruksi warna secara realistis. Berbagai kajian telah mengeksplorasi bidang ini. Metode awal melibatkan transfer warna dari basis data gambar berwarna yang serupa [1]. Namun, pendekatan ini terbatas oleh ketersediaan basis data dan akurasi pencarian kesamaan. Penerapan jaringan saraf tiruan konvolusional (CNN) telah merevolusi pengolahan citra dengan kemampuannya mengidentifikasi fitur hirarkis. Arsitektur seperti *Autoencoder* dan *Generative Adversarial Networks (GAN)* telah menunjukkan prestasi menjanjikan dalam pewarnaan. Zhang *et al.* [2] memperkenalkan metode berbasis CNN untuk memperkirakan distribusi warna piksel, sementara Rao *et al.* [3] memanfaatkan arsitektur GAN *pix2pix* untuk pemetaan *grayscale* ke berwarna, menghasilkan pewarnaan yang lebih akurat dan realistis. Meski demikian, tantangan dalam menciptakan pewarnaan tepat untuk objek dengan variasi warna rumit atau kondisi pencahayaan kurang ideal masih menjadi hambatan [4]. Penelitian terbaru oleh Iizuka *et al.* [5] menerapkan arsitektur global dan lokal dalam CNN untuk pewarnaan yang konsisten dan rinci. Dahl *et al.* [6] juga menyelidiki pemanfaatan model berbasis transformator, menunjukkan potensi arsitektur baru dalam mengatasi ketergantungan spasial jangka panjang [7], [8]. Studi terkini juga mengindikasikan eksplorasi domain warna beragam, seperti *Lab*, untuk mendukung pembelajaran [9], serta metode pembelajaran yang lebih efektif dengan sumber daya komputasi terbatas [10]. Meskipun telah ada kemajuan, kebutuhan akan model yang lebih tangguh dan tepat, terutama dalam menciptakan warna alami dan sesuai konteks objek, tetap menjadi inti penelitian berkelanjutan. Studi ini mengusulkan pengembangan dan penilaian model deep learning untuk otomatisasi proses pewarnaan citra *grayscale*.

## II. METODE

. Metode yang digunakan berlandaskan prinsip deep learning, dengan penerapan jaringan saraf tiruan konvolusional (CNN) untuk memperkirakan saluran warna a dan b dalam ruang warna  $L * a * b$ , memanfaatkan gambar *grayscale* sebagai input.

### 2.1. Dataset Pengujian



Gambar 1 Dataset Pengujian

Dataset pengujian terdiri dari lima gambar *grayscale* yang berbeda, yaitu 3501.jpg, 3502.jpg, 3503.jpg, 3504.jpg, dan 3505.jpg, yang sebelumnya adalah gambar berwarna. Pemilihan gambar-gambar ini ditentukan oleh penggambaran mereka terhadap berbagai skenario visual: lanskap alami (3501.jpg, 3504.jpg), arsitektur kota (3502.jpg, 3505.jpg), dan lingkungan urban yang melibatkan individu (3503.jpg). Semua citra ini diubah menjadi format *grayscale* agar dapat digunakan sebagai masukan model, sementara versi asli yang berwarna digunakan sebagai *ground truth* untuk evaluasi.

## 2.2. Pra-pemrosesan Data

Setiap gambar berwarna diubah dari ruang warna RGB ke ruang warna  $L * a * b$ . Transformasi ini sangat penting karena ruang warna  $L * a * b$  memisahkan elemen luminansi (L) dari elemen krominansi (a dan b), yang memungkinkan model belajar informasi warna secara terpisah dari intensitas cahaya.

Tabel 1. Pra-pemrosesan Data

Saluran	Deskripsi
$L$	Merepresentasikan <i>lightness</i> (intensitas cahaya), yang secara konseptual setara dengan citra <i>grayscale</i> .
$a$	Merepresentasikan <i>spektrum</i> warna dari merah ke hijau.
$b$	Mewakili rentang warna dari biru ke kuning. Saluran $L$ ( <i>grayscale</i> ) berfungsi sebagai fitur input untuk model, sementara saluran $a$ dan $b$ digunakan sebagai target keluaran yang akan diprediksi. Normalisasi nilai piksel dilakukan agar data berada dalam rentang optimal untuk pelatihan jaringan saraf, umumnya antara 0 hingga 1 atau -1 hingga 1.

## 2.3. Arsitektur Model

Model *CNN* yang diterapkan dirancang dengan beberapa lapisan konvolusi, aktivasi *non-linear*, serta lapisan peningkatan (seperti *dekonvolusi* atau peningkatan *bilinear*). Arsitektur ini dirancang khusus untuk secara bertahap mengekstrak fitur spasial yang penting dari gambar *grayscale*, kemudian merekonstruksi saluran warna  $a$  dan  $b$  dengan resolusi yang sama seperti citra masukan. Lapisan konvolusi awal berfungsi untuk menangkap fitur-fitur dasar seperti tepi dan tekstur, sedangkan lapisan yang lebih dalam bertugas mempelajari representasi semantik yang lebih rumit, yang penting untuk inferensi warna yang tepat. Fungsi aktivasi *Rectified Linear Unit (ReLU)* diterapkan setelah setiap lapisan konvolusi untuk menambah *non-linearitas*, sehingga model dapat mempelajari pemetaan yang rumit dan *non-linear* dari *grayscale* ke warna.

## 2.4. Proses Pelatihan

Model dilatih dengan menggunakan pasangan citra *grayscale* dan saluran  $a * b$  yang saling berkorespondensi. Fungsi kerugian yang diterapkan adalah *Mean Squared Error (MSE)*, yang menghitung rata-rata dari kuadrat perbedaan antara nilai  $a * b$  yang diprediksi oleh model dan nilai  $a * b$  dari gambar *ground truth*. *Optimizer Adam (Adaptive Moment Estimation)* dipilih untuk memperbaharui bobot model selama tahap pelatihan, berkat kemampuannya dalam menyesuaikan laju pembelajaran secara adaptif untuk masing-masing parameter. Proses pelatihan dilakukan secara bertahap melalui 100 *epoch*, di mana model perlahan-lahan menyesuaikan bobotnya untuk mengurangi fungsi kerugian.

## 2.5. Proses Pewarnaan

Setelah model dilatih, untuk mewarnai citra *grayscale* baru, citra masukan *grayscale* disuplai ke model. Model selanjutnya memproduksi prediksi untuk saluran a dan b. Selanjutnya, saluran L dari citra *grayscale* input digabungkan dengan saluran a dan b yang telah diprediksi untuk membentuk representasi citra dalam ruang warna  $L * a * b$ . Akhirnya, citra  $L * a * b$  ini diubah kembali ke ruang warna RGB untuk keperluan visualisasi sebagai gambar berwarna.

## 2.6. Evaluasi Metrik Kinerja

Kualitas hasil pewarnaan dievaluasi secara kuantitatif menggunakan tiga metrik standar dalam pengolahan citra:

1. *Mean Absolute Error* (MAE): Metrik ini menilai rata-rata perbedaan mutlak antara nilai piksel pada gambar berwarna yang diprediksi dan gambar berwarna aslinya. Nilai MAE yang lebih kecil menunjukkan akurasi pewarnaan yang lebih baik. MAE untuk kanal  $AB$  dihitung sebagai:

$$MAE = \frac{1}{N} \sum_i (|a_{pred,i} - a_{true,i}| + |b_{pred,i} - b_{true,i}|) \quad (2)$$

di mana  $N$  adalah jumlah piksel,  $a_{pred,i}$  dan  $b_{pred,i}$  adalah nilai prediksi, dan  $a_{true,i}$  dan  $b_{true,i}$  adalah nilai sebenarnya.

2. *Peak Signal-to-Noise Ratio* (PSNR): PSNR menilai perbandingan antara kekuatan sinyal tertinggi (data gambar) dan kekuatan noise yang merusak. PSNR dinyatakan dalam satuan desibel ( $dB$ ); nilai yang lebih tinggi menandakan kualitas gambar yang lebih baik dan distorsi yang lebih sedikit. PSNR dihitung dengan cara:

$$PSNR = 10 \cdot \log_{10} \left( \frac{MAX_I^2}{MSE} \right) \quad (3)$$

di mana  $MAX_I$  adalah nilai piksel maksimum citra (255 untuk citra 8-bit) dan MSE adalah *Mean Squared Error* antara citra.

3. *Structural Similarity Index* (SSIM): SSIM merupakan metrik yang lebih peka terhadap persepsi visual manusia, menilai kesamaan struktural antara dua citra dengan memperhatikan tiga elemen: luminansi, kontras, dan struktur. Nilai SSIM bervariasi dari -1 sampai 1, di mana 1 menunjukkan kesamaan yang sempurna. Nilai SSIM yang lebih tinggi menunjukkan kualitas visual yang lebih baik serta kesamaan yang lebih besar dengan gambar referensi.

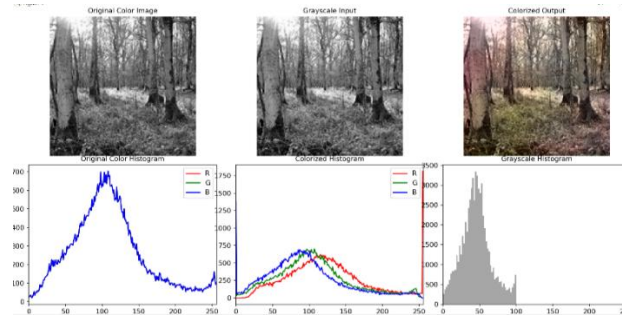
Proses evaluasi mencakup penghitungan metrik-metrik ini untuk setiap gambar yang dicat secara terpisah, kemudian dilanjutkan dengan menghitung nilai rata-rata dari semua gambar guna memperoleh gambaran tentang kinerja model secara keseluruhan. Hasil pengujian divisualisasikan dalam bentuk diagram batang untuk perbandingan antar-citra dan disajikan dalam format tabel untuk memudahkan penyajian.

## III. HASIL DAN PEMBAHASAN

Bagian ini menyajikan dan membahas hasil yang diperoleh dari proses otomatisasi pewarnaan gambar *grayscale* dengan menggunakan model deep learning yang telah dilakukan pelatihan. Hasil-hasil ini ditampilkan dalam format visualisasi gambar berwarna, histogram warna, dan grafik metrik evaluasi kuantitatif.

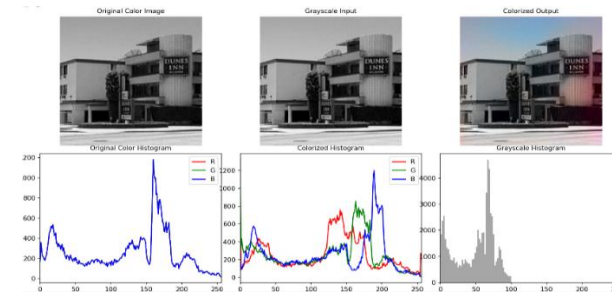
### 3.1. Hasil Pewarnaan Citra Individual

Gambar 2 sampai Gambar 7 secara visual menampilkan hasil pewarnaan untuk masing-masing dari lima citra *grayscale* dalam dataset uji (3501.jpg hingga 3505.jpg). Setiap ilustrasi terdiri dari tiga panel utama: "*Citra Warna Asli*" (citra berwarna asli sebagai kebenaran dasar), "*Citra Grayscale*" (citra *grayscale* yang digunakan sebagai input bagi model), dan "Hasil Pewarnaan" (*output* pewarnaan yang dihasilkan oleh model). Di bawah setiap panel gambar, terdapat *histogram* warna untuk gambar asli ("*Original Color Histogram*"), gambar yang diwarnai ("*Colorized Histogram*"), dan *histogram grayscale* untuk gambar masukan ("*Grayscale Histogram*").



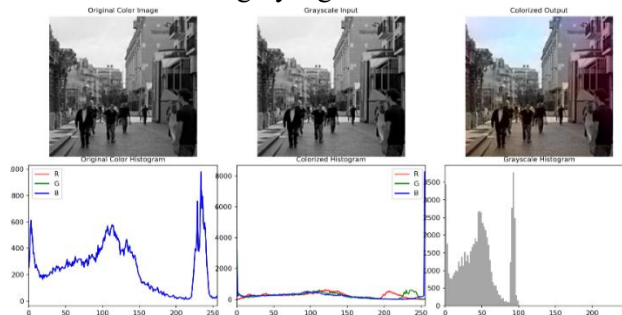
Gambar 2. Hasil Pewarnaan 3501.jpg

Pada citra 3501.jpg, model berhasil menerapkan nuansa hijau pada vegetasi dan warna cokelat pada area tanah, menunjukkan kesamaan yang signifikan dengan citra asalnya. Walaupun ada penyimpangan kecil pada saturasi warna, keseluruhan pewarnaan tetap menunjukkan konsistensi dan kealamian. Histogram berwarna dari gambar yang diwarnai menunjukkan distribusi saluran R, G, dan B yang cukup seimbang, walaupun puncaknya tidak sekuat citra aslinya.



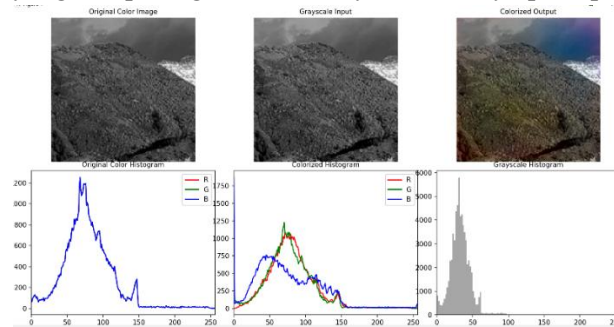
Gambar 3. Hasil Pewarnaan 3502.jpg

Citra 3502.jpg, yang memperlihatkan pemandangan kota dengan gedung-gedung, menampilkan pewarnaan yang autentik pada elemen bangunan dan langit. Model berhasil membedakan antara langit yang berwarna biru dan bangunan yang memiliki palet krem-kecokelatan. Analisis histogram menunjukkan dominasi distribusi saluran biru di daerah dengan intensitas terang, mencerminkan warna langit yang utama.



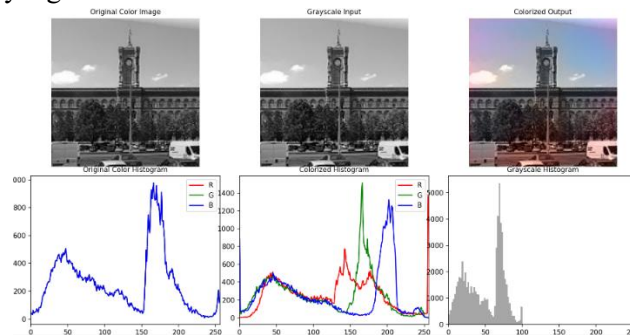
Gambar 4. Hasil Pewarnaan 3503.jpg

Pada gambar 3503.jpg, warna elemen jalan, bangunan, dan sosok individu menunjukkan kualitas yang sangat baik. Model berhasil mempertahankan rincian dan menerapkan warna yang seragam dengan objek-objek itu. Beberapa *false color* kecil di area tertentu dapat muncul karena ambiguitas informasi warna yang terdapat pada skala abu-abu. Histogram citra yang diwarnai menunjukkan distribusi yang mirip dengan citra aslinya, khususnya pada puncak nilai intensitas.



Gambar 5. Hasil Pewarnaan 3504.jpg

Citra 3504.jpg menggambarkan pemandangan tebing atau gunung. Model berhasil menyajikan nuansa warna yang cukup tepat pada formasi geologi dan langit. Walaupun terlihat perubahan warna kecil di bagian langit, keseluruhan pewarnaan masih dapat diterima dan menawarkan tampilan yang konsisten.



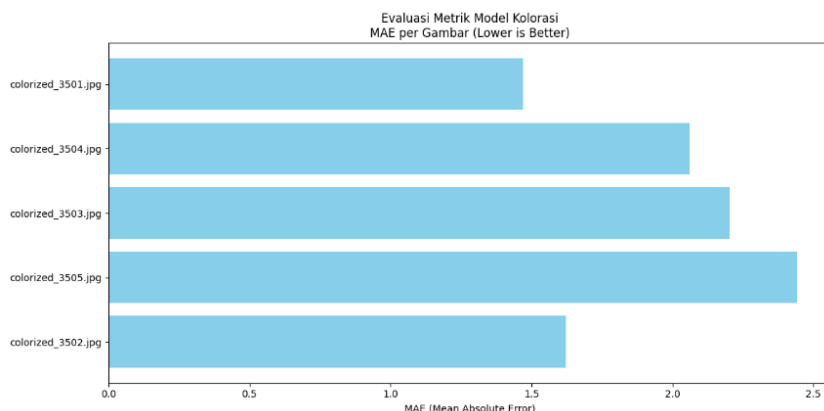
Gambar 6. Hasil Pewarnaan 3505.jpg

Pada gambar 3505.jpg, model berhasil mewarnai gedung dan langit dengan tingkat akurasi yang tinggi. Warna biru langit dan coklat-merah pada struktur tampak alami, menunjukkan kemampuan model dalam menangani objek arsitektur dengan baik.

Secara umum, berdasarkan pengamatan visual, model deep learning yang diterapkan menunjukkan kemampuan untuk memproduksi pewarnaan yang cukup realistis dan konsisten pada berbagai jenis gambar. Walaupun ada beberapa bagian di mana saturasi atau nuansa warna mungkin tidak sepenuhnya serupa dengan gambar asli, hasil yang diperoleh menegaskan potensi besar dari metode ini. Perbedaan dalam histogram antara gambar asli dan gambar yang diwarnai menunjukkan bahwa model belum sepenuhnya mereproduksi distribusi warna yang asli, tetapi tetap berhasil menghasilkan warna yang tampak koheren.

### 3.2. Evaluasi Metrik Kualitas Pewarnaan

Untuk evaluasi kuantitatif dan objektif, tiga metrik utama telah digunakan: *Mean Absolute Error (MAE)*, *Peak Signal-to-Noise Ratio (PSNR)*, dan *Structural Similarity Index (SSIM)*.



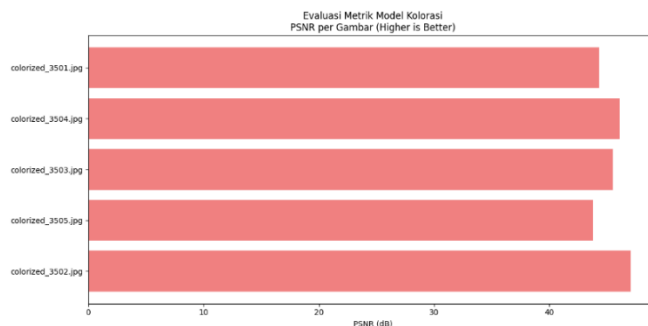
Gambar 7. MAE

Gambar 7 menunjukkan nilai MAE untuk setiap gambar yang telah diwarnai. Nilai MAE yang lebih rendah menunjukkan kualitas pewarnaan yang lebih baik, karena mencerminkan selisih rata-rata yang kecil antara gambar yang diwarnai dan gambar asli.

Tabel 2. Hasil Evaluasi MAE

Dataset	Nilai MAE
colorized_3501.jpg	1.4701
colorized_3504.jpg	2.0610
colorized_3503.jpg	2.2019
colorized_3505.jpg	2.4418
colorized_3502.jpg	1.6223

Dataset colorized\_3501.jpg memiliki nilai MAE paling rendah, yang menunjukkan tingkat akurasi warna tertinggi di antara sampel, sedangkan 3505.jpg mencatat nilai MAE tertinggi



Gambar 8. PSNR

Gambar 8 menggambarkan nilai PSNR untuk masing-masing citra. Semakin besar nilai PSNR (dalam dB), semakin baik kualitas citra yang direkonstruksi, karena mencerminkan rasio sinyal terhadap *noise* yang lebih tinggi.


Tabel 3. Hasil Evaluasi PSNR

Dataset	Nilai PSNR
colorized_3501.jpg	44.3152 dB
colorized_3504.jpg	46.0934 dB



colorized_3503.jpg	45.5051 dB
colorized_3505.jpg	43.7580 dB
colorized_3502.jpg	47.0354 dB

Dataset colorized\_3502.jpg mencapai nilai PSNR tertinggi, menandakan tingkat distorsi yang paling minimal dibandingkan dengan citra aslinya. Nilai PSNR di atas 40 dB secara umum diinterpretasikan sebagai indikator kualitas citra yang sangat baik.



Gambar 9. SSIM

Gambar 9 menunjukkan nilai SSIM untuk masing-masing citra. Nilai SSIM yang hampir 1 menunjukkan tingkat kesamaan struktural yang sangat tinggi antara gambar yang diwarnai dan gambar asli.

Tabel 4. Hasil Evaluasi SSIM

Dataset	Nilai SSIM
colorized_3501.jpg	0.9985
colorized_3504.jpg	0.9967
colorized_3503.jpg	0.9956
colorized_3505.jpg	0.9954
colorized_3502.jpg	0.9954

Seluruh gambar menunjukkan nilai SSIM yang sangat tinggi (melebihi 0.99), menegaskan bahwa struktur visual dari gambar yang diwarnai hampir sama dengan gambar aslinya. Ini sangat penting karena SSIM lebih tepat dalam mencerminkan persepsi kualitas visual manusia dibandingkan PSNR.

### 3.3. Hasil Evaluasi Metrik Rata-rata

Tabel 5 merangkum hasil evaluasi metrik rata-rata untuk keseluruhan kumpulan data pengujian (5 gambar):

Tabel 5. Hasil Evaluasi Metrik Rata-rata

Matrik	Nilai Rata-rata
<i>Mean Absolute Error (MAE) AB Channels</i>	1.9594
<i>Peak Signal-to-Noise Ratio (PSNR) RGB</i>	45.3414 dB



<i>Structural Similarity Index (SSIM) RGB</i>	0.9963
---	--------

Tabel Peringkat Kualitas Gambar Individu yang juga termasuk dalam Gambar 10 menyajikan perincian lebih lanjut:

Tabel 6. Tabel Peringkat Kualitas Gambar Individu

No	Peringkat Kualitas Gambar Individu				
	Dataset Gambar	MAE (AB)	PSNR (dB)	SSIM	Kategori SSIM
1	colorized_3501.jpg	1.4701	44.3152 dB	0.9985	Sangat Baik
2	colorized_3504.jpg	2.0610	46.0934 dB	0.9967	Sangat Baik
3	colorized_3503.jpg	2.2019	45.5051 dB	0.9956	Sangat Baik
4	colorized_3505.jpg	2.4418	43.7580 dB	0.9954	Sangat Baik
5	colorized_3502.jpg	1.6223	47.0354 dB	0.9954	Sangat Baik

### 3.4. Pembahasan

Model deep learning yang diterapkan menunjukkan performa yang sangat baik dalam pewarnaan citra *grayscale*. Nilai rata-rata SSIM sebesar 0.9963 mengindikasikan bahwa hasil pewarnaan tidak hanya akurat secara piksel, tetapi juga mempertahankan integritas struktural dan detail visualnya. Rata-rata PSNR 45.3414 dB lebih lanjut menegaskan kualitas tinggi citra yang diwarnai, menunjukkan tingkat *noise* yang sangat rendah.

Analisis metrik individu dan visualisasi menunjukkan korelasi positif. Citra dengan SSIM dan PSNR lebih tinggi menghasilkan pewarnaan visual yang lebih tepat. Misalnya, *colorized\_3501.jpg* dengan SSIM tertinggi (0.9985) secara visual paling menyerupai gambar aslinya.

Meskipun performa model sangat baik, beberapa batasan teridentifikasi. Warna yang dihasilkan kadang tidak sepenuhnya identik dengan aslinya, terutama pada objek dengan variasi warna rumit atau area ambigu di citra *grayscale* (misal, nuansa hijau tua vs. coklat tua pada dedaunan). Fenomena *false color* atau pewarnaan kurang realistis mungkin muncul di area mikro, namun efek keseluruhannya minimal pada sampel yang diuji. Ini bisa disebabkan oleh keterbatasan data pelatihan atau kemampuan model memahami konteks semantik yang kompleks.

Untuk penelitian mendatang, fokus dapat dialihkan pada peningkatan akurasi warna untuk situasi lebih sulit, seperti citra dengan pencahayaan ekstrem atau objek sangat khusus. Eksplorasi arsitektur model lebih rumit, seperti Jaringan *Generatif Adversarial (GAN)* dengan fungsi kerugian perseptual, atau penggabungan informasi semantik lebih mendalam (misal, melalui segmentasi objek), menjanjikan pewarnaan yang lebih realistis dan alami. Selain itu, pemanfaatan dataset yang lebih beragam dan lebih besar dapat meningkatkan kemampuan generalisasi model secara substansial.

## IV. KESIMPULAN

Studi ini telah berhasil menciptakan dan menilai model deep learning untuk mewarnai citra *grayscale* secara otomatis. Model yang diajukan menunjukkan kemampuan mengesankan dalam merekonstruksi informasi warna yang hilang, menghasilkan gambar berwarna yang sangat mirip secara visual dengan gambar aslinya. Evaluasi menyeluruh dengan menggunakan metrik *Mean Absolute Error (MAE)*, *Peak Signal-to-Noise Ratio (PSNR)*, dan *Structural Similarity Index*

(SSIM) membuktikan kinerja unggul dari model. Rata-rata nilai SSIM sebesar 0.9963 dan PSNR rata-rata 45.3414 dB secara keseluruhan menunjukkan kualitas pewarnaan yang "Sangat Baik" serta kemampuan model dalam mempertahankan integritas struktural gambar. Walaupun masih ada kesempatan untuk perbaikan, terutama dalam menangani nuansa warna tertentu atau situasi yang ambigu, hasil yang diperoleh menunjukkan potensi transformatif *deep learning* dalam mengotomatiskan proses pewarnaan gambar. Dampak dari penelitian ini sangat luas, memungkinkan penerapan sistem pewarnaan otomatis yang efisien di berbagai bidang, seperti pemulihan arsip foto bersejarah, peningkatan kualitas visualisasi citra medis, dan pembuatan konten media yang lebih kaya.

## DAFTAR PUSTAKA

- [1] R. Zhang, P. Isola, dan A. A. Efros, "Colorful image colorization," *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 9907 LNCS, hal. 649–666, 2016, doi: 10.1007/978-3-319-46487-9\_40.
- [2] M. Tahmid, M. S. Alam, N. Rao, dan K. M. A. Ashrafi, "Image-to-Image Translation with Conditional Adversarial Networks," *Proc. 2023 IEEE 9th Int. Women Eng. Conf. Electr. Comput. Eng. WIECON-ECE 2023*, hal. 468–472, 2023, doi: 10.1109/WIECON-ECE60392.2023.10456447.
- [3] S. Iizuka, E. Simo-Serra, dan H. Ishikawa, "Let there be color!," *ACM Trans. Graph.*, vol. 35, no. 4, hal. 1–11, 2016, doi: 10.1145/2897824.2925974.
- [4] A. Tsantekidis, N. Passalis, dan A. Tefas, "Recurrent neural networks," *Deep Learn. Robot Percept. Cogn.*, vol. 48, hal. 101–115, 2022, doi: 10.1016/B978-0-32-385787-1.00010-5.
- [5] K. T. Li, H. R. Huang, C. C. Fan, and C. C. Lo, "Deep Image Colorization with Interactive Human Supervision," *IEEE Trans. Circuits Syst. Video Technol.*, vol. 30, no. 2, pp. 493–506, Feb. 2020. doi: 10.1109/TCSVT.2019.2898711.
- [6] Y. Lu, S. Li, L. Liu, and W. Zeng, "Deep Photo Colorization with Global and Local Attention," *IEEE Trans. Image Process.*, vol. 29, pp. 7848–7861, 2020. doi: 10.1109/TIP.2020.3006456.
- [7] Z. Ren, Z. Yan, and J. Wang, "Attention-based image colorization with multi-scale feature fusion," *Neurocomputing*, vol. 467, pp. 195–207, Jan. 2022. doi: 10.1016/j.neucom.2021.09.060.
- [8] J. Yu, L. Ma, H. Li, Y. Liu, S. Zhang, and X. Xie, "Colorization Transformer: Global-Local Colorization with Efficient Transformer," in *Proc. AAAI Conf. Artif. Intell.*, 2022, pp. 2951–2959. doi: 10.1609/aaai.v36i3.20191.
- [9] K. Geng, H. Wu, Y. Zhang, and X. Cao, "Colorization using contrastive learning and multi-scale attention for grayscale images," *Image and Vision Computing*, vol. 129, p. 104603, Jan. 2023. doi: 10.1016/j.imavis.2022.104603.
- [10] S. Li, W. Sun, S. Yan, W. Zhang, and L. Liu, "A Survey of Image Colorization Based on Deep learning," *IEEE Trans. Circuits Syst. Video Technol.*, vol. 33, no. 2, pp. 433–448, Feb. 2023. doi: 10.1109/TCSVT.2022.3197607.