

Enhancing Damaged Image Reconstruction Using Gated-GAN with Integrated Attention Mechanism: A Deep Learning Approach

Nazanin Bahrami

Communication Engineering Department, FH
Kärnten University of Applied Sciences, Kärnten,
Austria.

**Mohammad Hossein
Hariri***

R&D at Phenix Accelerator, Qeshm, Iran.

Abstract

Damaged image reconstruction is a critical challenge in image processing and computer vision, with broad applications in historical restoration, medical imaging, and industrial monitoring. This study proposes a framework based on the Gated-GAN architecture integrated with an attention mechanism to enhance the reconstruction quality of degraded images. A dataset containing artificially damaged images featuring cracks and color distortions was used for training. Quantitative evaluation using metrics such as PSNR and SSIM demonstrates that the integration of the attention mechanism improves visual clarity, enables focused reconstruction of damaged regions, reduces discriminator loss, and accelerates convergence. Qualitative results further highlight the model's superiority in recovering fine details. This research offers a novel direction for developing intelligent, deep learning-based image reconstruction systems.

Keywords: image reconstruction, Gated-GAN, attention mechanism, image processing, deep learning, damaged images

Received: 25/September/2025

Accepted: 12/July/2025

eISSN: 3060-6144

ISSN: 2980-8936

بهبود بازسازی تصاویر آسیب‌دیده با استفاده از Gated-GAN مبتنی بر مکانیسم توجه: یک رویکرد یادگیری عمیق

نازنین بهرامی

گروه مهندسی ارتباطات، دانشگاه علوم کاربردی FH کرنتن، کرنتن، اتریش.

محمدحسین حریری*

واحد تحقیق و توسعه شتاب‌دهنده فینیکس، قشم، ایران.

چکیده

بازسازی تصاویر آسیب‌دیده یکی از چالش‌های مهم در حوزه پردازش تصویر و بینایی ماشین محسوب می‌شود که کاربردهای گسترده‌ای در مرمت آثار تاریخی، تصویربرداری پزشکی و پایش صنعتی دارد. در این پژوهش، یک چارچوب مبتنی بر شبکه Gated-GAN به همراه مکانیسم توجه ارائه شده است تا کیفیت بازسازی تصاویر تخریب‌شده را بهبود بخشد. مجموعه داده‌ای شامل تصاویر با آسیب‌های مصنوعی، نظیر ترک‌ها و اعوجاج رنگ، تهیه و برای آموزش مدل استفاده شده است. ارزیابی مدل با معیارهایی مانند PSNR و SSIM نشان می‌دهد که افزودن مکانیسم توجه باعث بهبود وضوح، تمرکز دقیق بر نواحی آسیب‌دیده، کاهش خطای تفکیک گر و تسریع هم‌گرایی می‌شود. نتایج کیفی نیز بر برتری مدل پیشنهادی در بازسازی جزئیات تأکید دارد. این پژوهش، مسیر نوینی را برای توسعه سیستم‌های هوشمند بازسازی تصویر مبتنی بر یادگیری عمیق ارائه می‌دهد.

کلیدواژه‌ها: بازسازی تصویر، Gated-GAN، مکانیسم توجه، پردازش تصویر، یادگیری عمیق، تصاویر آسیب‌دیده

مقدمه

بازسازی تصویر، به‌ویژه مرمت تصاویر آسیب‌دیده، یکی از چالش‌های اساسی در حوزه‌های پردازش تصویر و هوش مصنوعی محسوب می‌شود. آسیب‌دیدگی تصاویر ممکن است به دلایلی مانند نویز، خرابی فیزیکی یا افت کیفیت ناشی از گذر زمان و شرایط نگهداری ایجاد شود که این امر منجر به از دست رفتن جزئیات حیاتی یا کاهش کلی کیفیت تصویر گردد. توانایی بازسازی چنین تصاویری نه تنها در زمینه‌های هنری و تاریخی، مانند مرمت آثار هنری کهن یا عکس‌های قدیمی، ضروری است، بلکه در کاربردهای پزشکی، امنیتی و صنعتی نیز نقش بسیار مهمی ایفا می‌کند. برای نمونه، در حوزه‌ی پزشکی، بازسازی تصاویر آسیب‌دیده می‌تواند به تشخیص‌های دقیق‌تری منتهی شود (Rangaiah & Augustine, 2025). همچنین، توسعه‌ی سیستم‌های خودکار و هوشمند در تجهیزات پزشکی برای اهداف پیشگیرانه، مانند کنترل فشار در تشک‌های طبی، از دیگر زمینه‌های پرکاربرد مهندسی در سلامت است (Shayan et al., 2021). در حوزه‌ی امنیت، بازیابی تصاویر تار یا مخدوش می‌تواند به بهبود شناسایی افراد یا اشیاء منجر شود (Zare et al., 2011). به‌طور مشابه، در صنایع نیز بازسازی تصویر به ارتقای فرایندهای کنترل کیفیت و بازرسی محصولات کمک می‌کند (Abraham et al., 2025).

در سال‌های اخیر، روش‌های مبتنی بر یادگیری عمیق، به‌ویژه شبکه‌های مولد تخصصی (GAN)، پیشرفت چشمگیری در حوزه‌ی بازسازی تصویر داشته‌اند (Yang, 2022). شبکه‌های GAN از دو شبکه عصبی تشکیل می‌شوند: یک «مولد» برای تولید تصاویر جدید و یک «تشخیص‌گر» که بین تصاویر واقعی و تولیدشده تمایز قائل می‌شود. این رقابت درونی موجب می‌شود مدل خروجی‌هایی با کیفیت بالاتر تولید کند (Jampour et al., 2023). در میان مدل‌های مبتنی بر GAN، شبکه Gated-GAN عملکرد قابل توجهی در وظایف تبدیل تصویر به تصویر، از جمله بازسازی تصاویر آسیب‌دیده، نشان داده است (Vaswani et al., 2017). این شبکه می‌تواند طرح‌های ابتدایی را به تصاویر واقعی تبدیل کرده یا بخش‌های آسیب‌دیده‌ی تصاویر را ترمیم کند. با این وجود، علی‌رغم موفقیت‌های چشمگیر Gated-GAN و مدل‌های مشابه، اغلب در بازسازی جزئیات دقیق ناتوان هستند و خروجی‌ها ممکن است فاقد وضوح و دقت لازم باشند (Zhai et al., 2025).

برای رفع این کاستی‌ها، مکانیسم‌های توجه به‌عنوان ابزارهای مؤثر در یادگیری عمیق مطرح شده‌اند (Hua et al., 2024). این مکانیسم‌ها به مدل‌ها اجازه می‌دهند تا بر نواحی مهم تصویر، به‌ویژه بخش‌های آسیب‌دیده یا دچار افت کیفیت شدید، تمرکز کنند. با تخصیص پویا و هوشمندانه‌ی منابع محاسباتی به این نواحی، مکانیسم توجه دقت بازسازی را به‌ویژه در موارد پیچیده‌ای مانند تصاویری با ترک‌های گسترده یا الگوهای ظریف ارتقا می‌بخشد. ترکیب این مکانیسم‌ها با مدل‌هایی چون Gated-GAN یک مسیر نوین و امیدوارکننده برای ارتقای بازسازی جزئیات دقیق تصویر ارائه می‌دهد (Yang et al., 2024).

در این پژوهش، تأثیر ترکیب شبکه Gated-GAN با مکانیسم توجه بر کیفیت بازسازی تصاویر آسیب‌دیده بررسی شده است. برای این منظور، مجموعه‌ای از تصاویر با آسیب‌های مصنوعی مانند ترک و تغییر رنگ تهیه شد و عملکرد Gated-GAN به تنهایی و همراه با مکانیسم توجه مورد ارزیابی قرار گرفت. نتایج حاکی از آن بود که ادغام مکانیسم توجه باعث افزایش چشمگیر کیفیت تصاویر بازسازی‌شده، به‌ویژه در جنبه‌هایی مانند جزئیات و وضوح شد. این بهبود، حاصل توانایی مکانیسم توجه در تمرکز بر نواحی مهم و تخصیص مؤثر منابع است (Xu et al., 2023).

دستاوردهای این پژوهش از دو جنبه قابل توجه هستند: نخست، نشان داده شد که ترکیب Gated-GAN با مکانیسم توجه در بازسازی تصاویر آسیب‌دیده مؤثر است. دوم، با استفاده از شاخص‌هایی مانند PSNR و SSIM ارزیابی جامعی صورت گرفت که برتری روش پیشنهادی را نسبت به رویکردهای سنتی به‌خوبی نمایان ساخت (Zare

(et al., 2019). این پژوهش، در حوزه‌هایی همچون مرمت تصاویر تاریخی، تصویربرداری پزشکی و کنترل کیفیت صنعتی کاربرد دارد. با وجود این، چالش‌هایی مانند زمان پردازش بالا و نیاز به مجموعه داده‌های بزرگ همچنان پابرجاست (Li & Zhao, 2023). در آینده، تلاش خواهد شد با بهینه‌سازی مدل و بهره‌گیری از تکنیک‌های پیشرفته‌تر، بازسازی تصاویر با کیفیت بالاتری صورت گیرد.

کارهای مرتبط

پژوهش‌های پیشین در زمینه‌ی بازسازی تصویر، زیربنای روش شناختی مطالعه‌ی حاضر را تشکیل داده‌اند. پیشرفت‌های اولیه در مرمت تصاویر طی چند دهه‌ی گذشته، بستر مناسبی را برای توسعه‌ی سیستم‌های نوین بازسازی تصویر فراهم کرده‌اند. چالش‌های اساسی در بازسازی تصاویر قدیمی؛ از جمله تخریب‌های ساختاری مانند خراش‌ها و لکه‌ها و تخریب‌های غیرساختاری نظیر نویز و تاری، در متون علمی به‌طور گسترده مورد بررسی قرار گرفته‌اند. روش‌های متنوعی از جمله شبکه‌های عصبی پیچشی (CNN)، مدل‌های یادگیری عمیق و تکنیک‌های ترجمه تصویر برای غلبه بر این چالش‌ها پیشنهاد شده‌اند. همچنین، مطالعات مرتبط با مدل‌سازی و بازسازی تصویر بر پایه داده‌های نهفته^۱ بر ظرفیت بالای یادگیری ماشین و شبکه‌های عصبی در این حوزه تأکید دارند.

در سال‌های اخیر، تمرکز پژوهش‌ها به‌طور فزاینده‌ای به سمت بهره‌گیری از شبکه‌های ترجمه تصویر و مکانیسم‌های توجه در بازسازی تصاویر قدیمی معطوف شده است. برای نمونه، وانگ و همکاران^۲ (۲۰۲۰) رویکردی نوین ارائه داده‌اند که از شبکه‌های ترجمه تصویر در فضای نهفته برای بازسازی تصاویر قدیمی استفاده می‌کند. این روش شامل دو شاخه‌ی اصلی است: شاخه‌ای جهانی برای مدیریت تخریب‌های ساختاری و شاخه‌ای محلی برای رسیدگی به تخریب‌های غیرساختاری که ترکیب آن‌ها موجب بهبود قابل توجه عملکرد بازسازی شده است. طبق نتایج، دقت بازسازی بین ۰/۵۲ تا ۳/۵۵ درصد بسته به نوع مجموعه داده و پارامترهای یادگیری افزایش یافته است (Zhai et al., 2025).

از دیگر چالش‌های اساسی در این حوزه می‌توان به شکاف میان داده‌های مصنوعی و واقعی و نیز نیاز به مجموعه داده‌های بزرگ برای آموزش اشاره کرد. سونی (۲۰۲۱) در مطالعه‌ای از دو شبکه خودرمزگذار متغیر (VAE) برای نگاشت تصاویر قدیمی و تصاویر با کیفیت به فضاهای نهفته جداگانه استفاده کرد. این روش با بهره‌گیری از یک بلوک نیمه‌غیرمحلی به منظور پردازش تخریب‌های ساختاری، عملکرد بازسازی تصاویر قدیمی را به‌طور محسوسی بهبود بخشید. یافته‌ها نشان دادند که ترکیب مکانیسم‌های توجه با شبکه‌های ترجمه تصویر می‌تواند باعث ارتقای چشمگیر در کیفیت بازسازی شود (Hua et al., 2024).

در مطالعه‌ای جدیدتر، ژو و همکاران^۳ (۲۰۲۳) یک چارچوب انتها-به-انتها برای بازسازی و رنگی‌سازی تصاویر قدیمی ارائه داده‌اند. این چارچوب شامل سه زیرشبکه اصلی بود: یک زیرشبکه برای بازسازی تخریب‌ها، یک زیرشبکه برای همسان‌سازی هیستوگرام رنگ و یک زیرشبکه برای پیش‌بینی اجزای رنگی تصویر. این ساختار ترکیبی باعث شد که حتی با وجود داده‌های آموزشی محدود نیز عملکرد بازسازی و رنگی‌سازی تصاویر ارتقا یابد. طبق گزارش آن‌ها، استفاده از هیستوگرام‌های رنگی با حفظ اطلاعات مکانی و همچنین، ادغام چندمقیاسی موجب بهبود بازسازی تصاویر قدیمی گردید (Yang et al., 2024).

۱. latent

۲. Wang et al.

۳. Xu et al.

با وجود پیشرفت‌های قابل توجه در این حوزه، همچنان چالش‌هایی نظیر وجود تخریب‌های ترکیبی و پیچیده، شکاف بین داده‌های مصنوعی و واقعی و نیاز به مجموعه داده‌های بزرگ مقیاس پابرجا است. این موانع بر اهمیت ادامه‌ی تحقیقات و توسعه‌ی روش‌های نوین بازسازی تصویر با دقت و پایداری بالاتر تأکید می‌کنند. بنابراین، تلاش‌های آینده باید بر حل این مشکلات تمرکز یابند تا مسیر پیشرفت این حوزه و ارتقای کیفیت تکنیک‌های بازسازی تصویر هموارتر شود.

روش پیشنهادی

در این پژوهش از شبکه‌ی Gated-GAN که نوعی شبکه‌ی مولد تخصصی شرطی^۱ محسوب می‌شود، برای انجام فرایند بازسازی تصاویر آسیب‌دیده استفاده شده است. معماری Gated-GAN از دو جزء اصلی تشکیل شده است:

۱. مولد^۲: این بخش وظیفه دارد تصاویر بازسازی شده را از ورودی‌های تخریب شده یا بی کیفیت تولید کند. مولد طی فرایند یادگیری، رابطه‌ای میان تصویر ورودی (نظیر یک تصویر آسیب‌دیده) و خروجی متناظر آن (تصویر ترمیم شده) برقرار می‌کند، به گونه‌ای که ساختار اصلی و جزئیات تصویر حفظ شوند (Zhai et al., 2025).
۲. تشخیص‌گر^۳: نقش این بخش ارزیابی صحت و کیفیت تصاویر تولید شده توسط مولد است. تشخیص‌گر بین تصاویر بازسازی شده و تصاویر واقعی تمایز قائل شده و بازخورد لازم برای بهبود عملکرد مولد را فراهم می‌آورد (Vaswani et al., 2017).

برای بهینه‌سازی مدل، از یک تابع هزینه ترکیبی متشکل از تابع L1 (برای دقت پیکسلی) و تابع خصمانه^۴ استفاده شده است. تابع L1 با کاهش اختلاف بین تصویر بازسازی شده و تصویر واقعی، دقت سطح پایین (پیکسلی) را تضمین می‌کند، در حالی که تابع خصمانه باعث تولید تصاویری با کیفیت بصری نزدیک‌تر به تصاویر واقعی می‌شود. ترکیب این دو تابع هزینه، موازنه‌ای میان حفظ جزئیات و واقع‌گرایی کلی تصویر ایجاد کرده و موجب ارتقای کیفیت نهایی بازسازی می‌گردد (Jampour et al., 2023).

الف) ادغام مکانیسم توجه

برای بهبود عملکرد شبکه‌ی Gated-GAN، یک مکانیسم توجه^۵ در ساختار مولد آن یکپارچه‌سازی شده است. این مکانیسم، امکان تمرکز بیشتر مدل را بر نواحی بحرانی تصویر، به ویژه بخش‌هایی با آسیب دیدگی یا افت کیفیت بالا، فراهم می‌سازد. با تخصیص هدفمند منابع محاسباتی به این نواحی، دقت بازسازی جزئیات افزایش می‌یابد. این قابلیت در مواجهه با تصاویر دارای تخریب‌های پیچیده مانند ترک‌های گسترده یا بافت‌های ظریف، بسیار مؤثر واقع شده است (Hua et al., 2024).

ب) گردآوری داده‌ها و پیش‌پردازش

مجموعه داده مورد استفاده در این تحقیق به صورت دستی و با استفاده از دوربین تلفن همراه تهیه شده است. این تصاویر از کیفیت بالایی برخوردار بوده و ابعاد اولیه‌ی آن‌ها 3000×4000 پیکسل بود. مراحل پیش‌پردازش برای آماده‌سازی داده‌ها جهت آموزش و ارزیابی شامل موارد زیر می‌باشند:

1. conditional GAN
2. generator
3. discriminator
4. adversarial loss
5. attention mechanism

- تغییر اندازه به 256×256 پیکسل:
- برای کاهش بار محاسباتی و افزایش کارایی مدل، تمامی تصاویر با استفاده از عملیات کانولوشنی به اندازه 256×256 پیکسل تغییر داده شدند؛ بدون آنکه ویژگی‌های مهم تصویر از بین برود.
- شناسایی و حذف داده‌های پرت با الگوریتم K-Means:
- به منظور حذف تصاویر نامتعارف و نویزدار، الگوریتم خوشه‌بندی K-ماینکین اعمال گردید که طی آن ۲۱ تصویر پرت حذف و تعداد نهایی تصاویر به ۶۰۳ عدد کاهش یافت.
- تبدیل تصاویر به سیاه و سفید و سبک قدیمی:
- برای شبیه‌سازی سناریوهای مختلف بازسازی، نیمی از تصاویر به سیاه و سفید تبدیل شدند و نیمی دیگر با افکت‌های رنگی سبک قدیمی و افزودن نویز گاوسی، ظاهری کهنه و فرسوده پیدا کردند.
- اعمال تخریب‌های مصنوعی:
- برای ایجاد شرایط مشابه دنیای واقعی، فیلترهایی شامل ترک‌های سطحی با شفافیت پایین و اعوجاج‌های تصادفی رنگ بر تصاویر اعمال شد تا فرسایش و اثرات محیطی تقلید شوند (Li & Zhao, 2023).
- تصاویر آسیب‌دیده به عنوان ورودی به شبکه‌ی Gated-GAN داده شدند و تصاویر اصلی سالم نقش داده‌های مرجع^۱ را برای آموزش و ارزیابی ایفا کردند (Zare et al., 2019).
- ادغام مکانیسم توجه با ساختار Gated-GAN همراه با پیش‌پردازش دقیق داده‌ها، مدلی توانمند برای بازسازی تصاویر ایجاد کرده است که توانایی بالایی در بازیابی جزئیات ظریف، حتی در تصاویر دارای تخریب پیچیده دارد. این ترکیب رویکردی مؤثر برای به کارگیری در زمینه‌هایی چون مرمت آثار تاریخی، تصویربرداری پزشکی و بازرسی صنعتی ارائه می‌دهد. شکل ۱ شامل تصاویر اصلی، فیلتر و تخریب‌شده مصنوعی می‌باشد.



شکل ۱. نمونه ای از تصویر تولید شده ورودی

شکل ۲ دقت و تابع زیان مدل را در طول دوره‌های آموزشی نشان می‌دهد.



شکل ۲. دقت و تابع زیان مدل در طول دوره‌های آموزشی

نتایج آزمایش‌های تجربی

عملکرد مدل Gated-GAN استاندارد و مدل Gated-GAN مجهز به مکانیسم توجه با استفاده از معیارهای کمی نظیر PSNR، SSIM، خطای مولد^۱ و خطای تشخیص‌گر^۲ و همچنین ارزیابی‌های کیفی دیداری، مورد بررسی قرار گرفت.

۱. معیار نرخ سیگنال به نویز اوج (PSNR) برای ارزیابی کمی کیفیت تصویر بازسازی‌شده و محاسبه‌ی میزان خطای پیکسلی نسبت به تصویر مرجع، از معیار PSNR استفاده کرده است که به صورت زیر تعریف می‌شود:

$$PSNR = 10 \cdot \log_{10} \left(\frac{MAX_I^2}{MSE} \right) \quad (1)$$

که در آن MAX_I حداکثر مقدار ممکن برای پیکسل تصویر و MSE میانگین مربعات خطا بین تصویر اصلی و تصویر بازسازی‌شده است.

۲. شاخص شباهت ساختاری (SSIM) به منظور سنجش شباهت ادراکی بین تصویر تولیدشده (x) و تصویر واقعی (y)، معیار SSIM بر اساس رابطه‌ی زیر محاسبه می‌گردد که تغییرات روشنایی، کنتراست و ساختار را در نظر می‌گیرد:

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

در این رابطه، μ میانگین شدت روشنایی، σ^2 واریانس و σ_{xy} کوواریانس تصاویر هستند و C_1 و C_2 مقادیر ثابت برای پایداری فرمول می‌باشند.

۱. generator loss

۲. discriminator loss

۳. تابع هزینه کل مولد^۱ همان‌طور که در روش پیشنهادی ذکر شد، تابع هزینه‌ی نهایی مولد (L_G)، ترکیبی وزن‌دار از خطای خصمانه (L_{GAN}) و خطای بازسازی پیکسلی (L_1) است تا تعادلی میان واقع‌گرایی و دقت بازسازی ایجاد شود:

$$L_{Total} = \lambda_{adv} \cdot L_{GAN} + \lambda_{L1} \cdot |I_{GT} - G(I_{input})|_1 \quad (۳)$$

که در آن I_{GT} تصویر زمین‌حقیقت (سالم)، $G(I_{input})$ تصویر تولیدشده توسط مولد و λ ضرایب وزنی هر بخش از تابع هزینه هستند.

۴. تابع هزینه تشخیص‌گر^۲ هدف شبکه تشخیص‌گر، بیشینه‌سازی احتمال تخصیص برچسب صحیح به تصاویر واقعی (y) و تصاویر تولیدشده ($G(x)$) است. تابع زیان آن به صورت زیر تعریف می‌شود:

$$L_D = -E_{y \sim P_{data}} [\log D(y)] - E_{x \sim P_{input}} [\log(1 - D(G(x)))] \quad (۴)$$

خلاصه‌ای از نتایج در جداول زیر ارائه شده است.

جدول ۱. مقایسه معیارهای عددی مدل‌ها

معیار	Gated-GAN استاندارد	Gated-GAN با مکانیسم توجه
PSNR	۲۱/۵۸	۲۱/۹۸
SSIM	۰/۵۱	۰/۵۱
خطای مولد	۷/۴۹	۹/۲۵
خطای تشخیص‌گر	۱/۲۱	۱/۰۵
دوره‌های آموزش	۱۱۲	۱۰۲

جدول ۲. پیشرفت آموزش در طول زمان

مدل	دوره ۱ (آغاز آموزش)	دوره نهایی (پس از آموزش)
Gated-GAN استاندارد	خطای مولد: ۲۷/۷۶	خطای مولد: ۷/۴۹
	خطای تشخیص‌گر: ۱/۴۹ PSNR: ۱۴/۳۸ SSIM: ۰/۳۲	خطای تشخیص‌گر: ۱/۲۱ PSNR: ۲۱/۵۸ SSIM: ۰/۵۱
Gated-GAN با مکانیسم توجه	خطای مولد: ۲۹/۵۷	خطای مولد: ۹/۲۵
	خطای تشخیص‌گر: ۱/۳۶ PSNR: ۱۴/۳۳ SSIM: ۰/۳۵	خطای تشخیص‌گر: ۱/۰۵ PSNR: ۲۱/۹۸ SSIM: ۰/۵۱

تحلیل نتایج

نتایج به دست آمده از ارزیابی کمی نشان می‌دهد که مدل Gated-GAN همراه با مکانیسم توجه در جنبه‌های مختلف عملکرد بهتری نسبت به نسخه استاندارد دارد. به‌ویژه، این مدل در معیار PSNR به مقدار بالاتری (۲۱/۹۸) در برابر (۲۱/۵۸) دست یافته است که نمایانگر بازسازی دقیق‌تر و باکیفیت‌تر تصویر است. همچنین، مقدار خطای تشخیص‌گر

۱. generator loss

۲. discriminator loss

در مدل توجه‌محور پایین‌تر (۱/۰۵ در برابر ۱/۲۱) بوده که به معنای تولید تصاویری واقعی‌تر از دیدگاه شبکه تفکیک‌گر است.

هرچند خطای مولد در مدل استاندارد کمتر است (۷/۴۹ در برابر ۹/۲۵) که می‌تواند دقت پیکسلی بالاتر را نشان دهد، اما مقدار SSIM در هر دو مدل یکسان (۰/۵۱) است که بیانگر شباهت ساختاری برابر با تصویر مرجع می‌باشد. نکته‌ی حائز اهمیت دیگر این است که سرعت هم‌گرایی بالاتر مدل دارای مکانیسم توجه است که تنها با ۱۰۲ دوره آموزشی به عملکرد مطلوب رسید، در حالی که نسخه استاندارد به ۱۱۲ دوره نیاز داشت.

به‌طور کلی، نتایج به‌روشنی نشان می‌دهد که افزودن مکانیسم توجه به ساختار Gated-GAN، موجب ارتقای قابل‌ملاحظه‌ای در کیفیت بازسازی تصویر، تمرکز بهتر بر نواحی آسیب‌دیده و تولید تصاویر واقعی‌تر می‌شود. این ویژگی‌ها مدل ترکیبی را به گزینه‌ای مناسب برای کاربردهای حرفه‌ای در حوزه‌ی بازسازی تصویر تبدیل می‌کند (Yu et al., 2019).

بحث و نتیجه‌گیری

در این پژوهش، اثربخشی ادغام مکانیسم توجه با ساختار شبکه‌ی Gated-GAN برای بازسازی تصاویر آسیب‌دیده مورد بررسی قرار گرفت. نتایج به‌دست آمده نشان می‌دهد که بهره‌گیری از مکانیسم توجه، کیفیت بازسازی تصویر را به‌طور معناداری ارتقا می‌دهد؛ به‌ویژه در زمینه‌ی بازیابی جزئیات دقیق و بهبود وضوح بصری. ارزیابی‌های کمی بر اساس شاخص‌هایی نظیر PSNR و SSIM حاکی از آن بود که مدل Gated-GAN همراه با مکانیسم توجه، نسبت به نسخه‌ی استاندارد این مدل عملکرد بهتری دارد؛ به‌طوری‌که به مقدار PSNR بالاتر و خطای تفکیک‌گر پایین‌تر دست یافت. همچنین، این مدل با تعداد دوره‌های آموزشی کمتر به هم‌گرایی رسید که بیانگر کارایی آموزشی بالاتر آن است.

مقایسه‌های کیفی دیداری نیز برتری مکانیسم توجه را به‌خوبی نشان دادند و آشکار ساختند که این مکانیسم قادر است، به‌طور مؤثر، بر نواحی آسیب‌دیده تمرکز کرده و بازیابی دقیقی از بافت‌ها و جزئیات ظریف ارائه دهد؛ امری که در تصاویر با تخریب پیچیده اهمیت ویژه‌ای دارد. هرچند مدل استاندارد از نظر دقت پیکسلی در برخی موارد قابل قبول عمل کرد، اما توانایی مدل مبتنی بر توجه در اولویت‌دهی به ویژگی‌های حیاتی، آن را به گزینه‌ای مناسب‌تر برای بازسازی باکیفیت تصاویر بدل ساخت.

با توجه به نتایج، استفاده از Gated-GAN به‌ویژه در ترکیب با مکانیسم‌های توجه، رویکردی مؤثر و آینده‌دار برای بازسازی تصاویر آسیب‌دیده به‌شمار می‌رود. این روش قابلیت به‌کارگیری در کاربردهای متنوعی نظیر مرمت تصاویر تاریخی و هنری، تصویربرداری پزشکی و کنترل کیفیت صنعتی را داراست. با این حال، چالش‌هایی مانند زمان پردازش نسبتاً بالا و نیاز به داده‌های آموزشی در مقیاس بزرگ همچنان پابرجاست. لذا، پیشنهاد می‌شود تحقیقات آتی بر بهینه‌سازی معماری مدل، بهره‌گیری از تکنیک‌های پیشرفته را افزایش داده و بر استفاده از ساختارهای سبک‌تر و سریع‌تر تمرکز یابند. یافته‌های این پژوهش نشان می‌دهد که ترکیب Gated-GAN با مکانیسم‌های توجه، مسیری امیدوارکننده برای ارتقای کیفی بازسازی تصاویر فراهم می‌سازد.

منابع

- Abraham, T., Todd, A., Orringer, D. A., & Levenson, R. (2025). Applications of artificial intelligence for image enhancement in pathology. In *Artificial intelligence in pathology* (pp. 183–210). Elsevier.

- Hua, Z., Qi, L., Yang, Z., & Sun, Y. (2024). An improved gated-GAN generative adversarial network for sand-dust image enhancement. *Signal, Image and Video Processing*, 1–8.
- Jampour, M., Zare, M., & Javidi, M. (2023). Advanced multi-GANs towards near-to-real image and video colorization. *Journal of Ambient Intelligence and Humanized Computing*, 14(9), 12857–12874.
- Li, S., & Zhao, X. (2023). High-resolution concrete damage image synthesis using conditional generative adversarial networks. *Automation in Construction*, 147, 104739.
- Rangaiyah, P. K., & Augustine, R. (2025). Improving burn diagnosis in medical image retrieval from grafting burn samples using B-coefficients and the CLAHE algorithm. *Biomedical Signal Processing and Control*, 99, 106814.
- Sabaria, S., & Thangakumar, J. (2024). Machine learning for identifying pedestrians and vehicles in low-light images: A survey. In *Proceedings of the 5th International Conference on Data Intelligence and Cognitive Informatics (ICDICI 2024)* (pp. 546–551). IEEE.
- Shayan, Z., Sabouri, M., Shayan, M., Asemani, M. H., Saroori, A. B., & Zare, M. (2021). Pressure control of cellular electromechanical medical mattress for bedsores prevention. In *Proceedings of the 7th International Conference on Control, Instrumentation and Automation (ICCIA 2021)* (pp. 1–6). IEEE.
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., & Polosukhin, I. (2017). Attention is all you need. In *Advances in neural information processing systems (NeurIPS)* (pp. 5998–6008).
- Wang, Z., Bovik, A. C., Sheikh, H. R., & Simoncelli, E. P. (2004). Image quality assessment: From error visibility to structural similarity. *IEEE Transactions on Image Processing*, 13(4), 600–612.
- Xu, R., Yu, H., Shi, H., Tang, Y., He, L., & Wang, G. (2023). Pik-Fix: Restoring and colorizing old photos. In *Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision (WACV)* (pp. 1724–1733).
- Xu, Z., Dai, Z., Sun, Z., Li, W., & Dong, S. (2023). Pavement image enhancement based on pixel-wise multi-level semantic information. *IEEE Transactions on Intelligent Transportation Systems*.
- Yang, H., Hu, Y., He, S., Xu, T., Yuan, J., & Gu, X. (2024). Applying conditional generative adversarial networks for imaging diagnosis. In *Proceedings of the IEEE 6th International Conference on Power, Intelligent Computing and Systems (ICPICS 2024)* (pp. 1717–1722). IEEE.
- Yang, T. (2022). Damaged photo restoration with high resolution through StyleGAN prior. *Preprint*, 1–8.
- Yu, J., Lin, Z., Yang, J., Shen, X., Lu, X., & Huang, T. S. (2019). Free-form image inpainting with gated convolution. In *Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV)* (pp. 4471–4480).
- Zare, M., Jampour, M., & Farrokhi, I. R. (2011). A heuristic method for gray image pseudo-coloring with histogram and RGB layers. In *Proceedings of the IEEE 3rd International Conference on Communication Software and Networks* (pp. 524–527). IEEE.
- Zare, M., Lari, K. B., Jampour, M., & Shamsinejad, P. (2019). Multi-GANs and its application for pseudo-coloring. In *Proceedings of the 4th International Conference on Pattern Recognition and Image Analysis (IPRIA 2019)* (pp. 1–6). IEEE.
- Zhai, W., Ni, Z., Xu, Z., Pan, J., & Wu, C. (2025). T2R-Gated-GAN: A method for constructing rural thematic road networks based on gated-GAN. *Computers and Electronics in Agriculture*, 230, 109911.

استناد به این مقاله: بهرامی، نازنین، و حریری، محمدحسین. (۱۴۰۴). بهبود بازسازی تصاویر آسیب‌دیده با استفاده از Gated-GAN مبتنی بر مکانیسم توجه: یک رویکرد یادگیری عمیق. فصلنامه پژوهش‌های نوین در شهر هوشمند، ۴(۱)، ۶۱–۷۰.



New Researches in The Smart City is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License.