

Real-Time Interactive Coloring of Children's Artwork Using Diffusion Models

Zahra Kazemi

Department of Computer Engineering, Science
and Research Branch, Islamic Azad University,
Tehran, Iran.

Sattar Hashemi*

Department of Computer Science and
Engineering and Information Technology, Shiraz
University, Shiraz, Iran.

Abbas Koochari

Department of Computer Engineering, Science
and Research Branch, Islamic Azad University,
Tehran, Iran.

Abstract

Coloring contributes to the development of children's artistic and cognitive growth. This research introduces a real-time interactive framework that employs probabilistic diffusion models to colorize children's grayscale artwork. By combining implicit structural guidance from the artwork with user-provided color scribbles, our system enables intuitive and dynamic coloring. The framework is optimized for low-latency performance and delivers instant feedback that fosters creativity. Extensive evaluations demonstrate superior structure preservation and color accuracy compared to existing methods, making this system a promising tool for educational and creative applications.

Keywords: interactive coloring, real-time, children's artwork, diffusion models, creativity, education

Received: 30/April/2025

Accepted: 04/September/2025

eISSN: 3060-6144

ISSN: 2980-8936

رنگ آمیزی تعاملی بلادرنگ آثار هنری کودکان با استفاده از مدل‌های پخش

زهره کاظمی | گروه مهندسی کامپیوتر، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران.

ستار هاشمی* | گروه علوم و مهندسی کامپیوتر و فناوری اطلاعات، دانشگاه شیراز، شیراز، ایران.

عباس کوچری | گروه مهندسی کامپیوتر، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران.

چکیده

رنگ آمیزی به پرورش رشد هنری و شناختی کودکان کمک می‌کند. این پژوهش، یک چارچوب تعاملی بلادرنگ معرفی می‌کند که از مدل‌های پخش احتمالی به منظور رنگ آمیزی آثار هنری خاکستری کودکان بهره می‌برد. با ترکیب راهنمایی ساختاری ضمنی از اثر هنری و خط‌خطی‌های رنگی ارائه شده توسط کاربر، سیستم ما امکان رنگ آمیزی شهودی و پویا را فراهم می‌سازد. این چارچوب برای عملکرد با تأخیر کم، بهینه‌سازی شده و بازخورد فوری ارائه می‌دهد که خلاقیت را تقویت می‌کند. ارزیابی‌های گسترده نشان می‌دهد که این روش در حفظ ساختار و دقت رنگ نسبت به روش‌های موجود برتری دارد و آن را به ابزاری نویدبخش برای کاربردهای آموزشی و خلاقانه تبدیل می‌سازد.

کلیدواژه‌ها: رنگ آمیزی تعاملی، بلادرنگ، آثار هنری کودکان، مدل‌های پخش، خلاقیت، آموزش

۱- مقدمه

آثار هنری کودکان که با خطوط ساده و نامنظم خود شناخته می‌شوند، به دلیل ویژگی‌های ساختاری و سبکی متمایز خود، چالش‌های منحصربه‌فردی را برای رنگ‌آمیزی خودکار ایجاد می‌کنند. برخلاف تصاویر حرفه‌ای، نقاشی‌های کودکان اغلب دارای خطوط ناسازگار و اشکال انتزاعی هستند که دستیابی به رنگ‌آمیزی دقیق و جذاب بصری را برای روش‌های سنتی دشوار می‌سازد. رویکردهای موجود، مانند شبکه‌های مولد تقابلی (GANها) (Fu et al., 2023; Wang et al., 2024; Zhang et al., 2025)، بر تولید تصاویر عمومی تمرکز دارند و در تعامل بلادرنگ و کنترل هدایت‌شده توسط کاربر که برای جلب توجه هنرمندان جوان حیاتی است، با مشکل مواجه می‌شوند. علاوه بر این، GANها از ناپایداری در آموزش و ناسازگاری در تراز رنگ، به‌ویژه در مناطق پیچیده، رنج می‌برند (Brizuela et al., 2023) که کاربرپذیری آن‌ها را برای برنامه‌های تعاملی محدود می‌کند.

مدل‌های پخش احتمالی (DPMS) به‌عنوان جایگزینی قدرتمند ظهور کرده‌اند که با استفاده از فرآیند نویززدایی تکراری، خروجی‌های باکیفیت و دقیقی تولید می‌کنند (Ho et al., 2022; Sharia et al., 2022). برخلاف GANها، DPMSها در ثبت جزئیات ظریف و حفظ وفاداری ساختاری، برتری دارند و آن‌ها را برای رنگ‌آمیزی آثار هنری کودکان ایده‌آل می‌سازند. با این حال، کاربرد آن‌ها در رنگ‌آمیزی بلادرنگ و هدایت‌شده توسط کاربر به دلیل نیازهای محاسباتی بالا کمتر مورد کاوش قرار گرفته است (Lee et al., 2020; Li et al., 2022). پژوهش ما با معرفی یک مکانیسم ترکیبی نوین برای شرطی‌سازی که راهنمایی ساختاری ضمنی از آثار خاکستری را با خط‌خطی‌های رنگی ارائه‌شده توسط کاربر ادغام می‌کند، این چالش‌ها را برطرف می‌کند و رنگ‌آمیزی دقیق و شهودی را امکان‌پذیر می‌سازد.

چارچوب ما، DPMSها را برای عملکرد بلادرنگ بهینه‌سازی می‌کند و به زمان پردازش ۵۰ میلی‌ثانیه برای هر تصویر دست می‌یابد که بازخورد فوری را برای تقویت مشارکت خلاق کودکان تضمین می‌کند. از طریق ارزیابی‌های کمی و کیفی گسترده، ما برتری در حفظ ساختار و دقت رنگ را در مقایسه با روش‌های پیشرفته (Fu et al., 2023; Wang et al., 2024) نشان می‌دهیم. این رویکرد، نه تنها محدودیت‌های تکنیک‌های قبلی را برطرف می‌کند بلکه معیاری جدید برای ابزارهای هنری تعاملی ایجاد می‌کند و کاربردهای بالقوه‌ای در محیط‌های آموزشی و پلتفرم‌های خلاقانه دارد.

این مقاله به‌صورت زیر سازمان‌دهی شده است: بخش دوم به مرور کارهای مرتبط در زمینه رنگ‌آمیزی خودکار و مدل‌های پخش می‌پردازد. بخش سوم، چارچوب پیشنهادی شرطی‌سازی ترکیبی و بهینه‌سازی آن برای عملکرد بلادرنگ را شرح می‌دهد. بخش چهارم، پیاده‌سازی و تنظیمات تجربی را توضیح می‌دهد درحالی که بخش پنجم، نتایج کمی و کیفی را ارائه می‌دهد. بخش ششم به محدودیت‌ها و جهت‌گیری‌های آینده می‌پردازد و بخش هفتم، مطالعه را به پایان می‌رساند.

۲- کارهای مشابه

حوزه رنگ‌آمیزی خودکار خطوط هنری دارای پیشینه‌ای طولانی است و روش‌های متعددی برای انجام این کار هنری توسعه یافته‌اند. تکنیک‌های پردازش تصویر سنتی (مانند (Zare et al., 2011; Sýkora et al., 2011)) عمدتاً از الگوریتم‌های استاندارد پردازش تصویر برای پخش نشانه‌های رنگی مشخص‌شده توسط کاربر در سراسر اثر هنری استفاده می‌کنند. این تکنیک‌ها به تحلیل ویژگی‌هایی مانند یکنواختی الگو و گرادیان‌های شدت در خطوط هنری وابسته هستند. اگرچه این روش‌ها برای تصاویر ساده‌تر مؤثرند؛ اما عملکرد آن‌ها در طرح‌های پیچیده‌تر کاهش می‌یابد.

و اغلب به ورودی گسترده کاربر برای دستیابی به نتایج بصری مطلوب نیاز دارند. علاوه بر این، تکنیک‌های سنتی از کارایی لازم برای کاربردهای بلادرنگ برخوردار نیستند؛ زیرا معمولاً شامل عملیات محاسباتی پرهزینه هستند. ظهور یادگیری عمیق و شبکه‌های مولد تقابلی (GANها) (مانند (Lee & Park, 2024; Wang et al., 2024)) تحولی در رنگ‌آمیزی خطوط هنری ایجاد کرده است. علاوه بر این، مدل‌های پخش احتمالی (DPMها) به دلیل توانایی کاهش بار محاسباتی و حفظ خروجی‌های باکیفیت، برای کاربردهای بلادرنگ مناسب‌تر هستند. روش‌های مبتنی بر GAN از مجموعه داده‌های گسترده تصاویر رنگی برای آموزش مدل‌هایی استفاده می‌کنند که قادر به پخش نشانه‌های رنگی تعریف‌شده توسط کاربر در سراسر اثر هنری هستند. پیشرفت‌های قابل توجه در این حوزه شامل بهبود عمومیت‌پذیری (Fu et al., 2023) که از طریق ادغام شبکه‌های ویژگی محلی تخصصی به دست آمده و بهبود وفاداری بصری (Lee et al., 2020) که از طریق طراحی "مولد دوگانه" معرفی شده و کیفیت زیبایی‌شناختی خروجی‌ها را ارتقا می‌دهد، می‌شوند. همچنین، انتقال سبک با تصاویر مرجع (مانند (Wang et al., 2024; Zhang et al., 2025)) به کاربران امکان می‌دهد سبک هنری یک تصویر مرجع را اعمال کنند و انعطاف‌پذیری بیشتری برای دستیابی به جلوه‌های بصری خاص فراهم می‌آورد.

با وجود پتانسیل‌هایشان، تکنیک‌های مبتنی بر GAN با چالش‌هایی مواجه‌اند. ناپایداری در آموزش همچنان یک مسئله برجسته است؛ زیرا GANها به شدت به پیکربندی‌های فرآپارامتر حساس‌اند و ممکن است در همگرایی با مشکل مواجه شوند که منجر به خروجی‌های نامنظم یا نامطلوب می‌شود. علاوه بر این، ناسازگاری ادراکی ممکن است به نتایجی منجر شود که از انتظارات انسانی یا ترجیحات رنگی موردنظر فاصله دارند. برای غلبه بر این محدودیت‌ها، مدل‌های پخش احتمالی (DPMها) (مانند (Ho et al., 2020; Ruthotto & Haber, 2021)) به عنوان جایگزینی قدرتمند ظهور کرده‌اند. DPMها رویکردی منحصربه‌فرد را معرفی می‌کنند که با افزودن و سپس حذف نویز از تصویر اولیه به صورت نظام‌مند، فرآیند "نویززدایی" را می‌آموزند تا نقاط داده جدید تولید کنند. این روش عملکردی پیشرفته در وظایف مختلف، از جمله سنتز تصویر، افزایش رزولوشن و رنگ‌آمیزی خودکار، ارائه داده و آن را به ابزاری قدرتمند برای رنگ‌آمیزی خطوط هنری تبدیل کرده است. با تکیه بر مزایای مدل‌های پخش، روش پیشنهادی ما برای رنگ‌آمیزی خطوط هنری از یک چارچوب پخش شرطی استفاده می‌کند. با گنجاندن خط‌خطی‌های رنگی ارائه‌شده توسط کاربر، این مدل فرآیند رنگ‌آمیزی را به صورت شهودی هدایت می‌کند و رویکردی قوی و قابل اعتماد برای زنده کردن آثار هنری کودکان ارائه می‌دهد. علاوه بر این، با بهینه‌سازی فرآیند پخش برای عملکرد بلادرنگ، روش ما تعامل‌پذیری را افزایش می‌دهد و به کودکان امکان می‌دهد نتایج فوری از ورودی‌های هنری خود ببینند و مشارکت بیشتری را تقویت می‌کند. پیشرفت‌های اخیر در رنگ‌آمیزی هدایت‌شده توسط کاربر، مانند کارهای (Wang et al., 2024; Li et al., 2022)، شرطی‌سازی ضمنی و صریح را در چارچوب‌های مبتنی بر GAN و پخش بررسی کرده‌اند. با این حال، این روش‌ها عمدتاً برای تصاویر عمومی یا آثار هنری حرفه‌ای طراحی شده‌اند و اغلب با ساختارهای نامنظم و ساده خطوط هنری کودکان دچار مشکل می‌شوند.

Proposed Method – ۳

این بخش به بررسی ماهیت سیستم پیشنهادی ما می‌پردازد که مدل‌های پخش را با ورودی تعاملی کاربر ترکیب می‌کند تا نقاشی‌های کودکان را رنگ‌آمیزی کند. این سیستم از قابلیت‌های مدل‌های پخش بهره می‌برد تا یک اثر هنری خاکستری (I) را به نسخه‌ای زنده و رنگی (x0) تبدیل کند که توسط نشانه‌های رنگی ارائه‌شده توسط کاربر (s) هدایت می‌شود. برای اطمینان از تعامل بی‌وقفه، سیستم برای پردازش بلادرنگ بهینه‌سازی شده است و بازخورد فوری به

ورودی‌های کاربر ارائه می‌دهد. نمای کلی فرآیند رنگ‌آمیزی، از اثر هنری خاکستری کودک تا خروجی نهایی رنگی، در شکل ۱ نشان داده شده است.

رمزگذار خط‌خطی‌های رنگی ($g\theta$): این رمزگذار تخصصی مسئول استخراج اطلاعات رنگی از خط‌خطی‌های ارائه‌شده توسط کاربر (s) است. داده‌های استخراج‌شده به‌عنوان راهنما برای فرآیند رنگ‌آمیزی عمل می‌کنند و هماهنگی با ورودی‌های کاربر را تضمین می‌کنند.

مدل نویززدایی ($\epsilon\theta$): این مدل که در خط لوله نویززدایی ادغام شده است، برای "نویززدایی" تصاویر نمونه‌برداری‌شده از یک توزیع ناشناخته آموزش دیده است. این مدل از نقاشی خاکستری (I) به‌عنوان راهنمای ساختاری برای بهبود تصویر در طول فرآیند نویززدایی استفاده می‌کند.



شکل ۱. سیستم، رنگ‌آمیزی آثار هنری کودکان که توسط یک هنرمند خلق شده (چپ) را با استفاده از خط‌خطی‌های رنگی به‌عنوان راهنما (وسط) ساده‌سازی می‌کند. نتیجه نهایی، تولیدشده توسط روش پیشنهادی ما و نمایش داده‌شده به‌صورت x_0 ، در سمت راست نشان داده شده است.

با ترکیب توانایی رمزگذار در ثبت جزئیات رنگی موردنظر کاربر با درک مدل نویززدایی از ساختار تصویر خاکستری، سیستم خروجی‌های رنگی باکیفیتی (x_0) را با استفاده از الگوریتم نمونه‌برداری DDPM (Ho et al., 2020) تولید می‌کند. الگوریتم نمونه‌برداری DDPM برای کاهش تأخیر بیشتر بهینه‌سازی شده است تا سیستم بتواند نتایج باکیفیت را بدون افت سرعت ارائه دهد.

۳-۱- مدل‌های پخش

مدل‌های پخش به یکی از پایه‌های اصلی در تولید تصویر تبدیل شده‌اند و به دلیل توانایی‌شان در تبدیل نویز تصادفی به تصاویر باکیفیت و پرجزئیات شناخته شده‌اند. این بخش اصول بنیادین مدل‌های پخش و کاربرد آن‌ها در تبدیل نقاشی‌های خاکستری کودکان به آثار هنری زنده و واقعی را بررسی می‌کند.

۳-۱-۱- نگاهی گام‌به‌گام: فرآیند پخش

فرض کنید با یک نقاشی ساده کودکان (x_0) شروع می‌کنیم. مدل‌های پخش از فرآیندی ساختاریافته پیروی می‌کنند که در هر گام (t) به تدریج نویز را در طول یک توالی از گام‌ها، مشابه یک زنجیره مارکوف، اضافه می‌کند. این

"فرآیند پیش رو" به تدریج نقاشی را به نسخه های میانی پرنویز تر (x_t) در هر مرحله تبدیل می کند که شبیه به اثر محوشدگی تدریجی است. نتیجه، یک نمایش بسیار پرنویز از نقاشی اصلی است که راه را برای فرآیند معکوس جهت بازسازی آن هموار می کند.

۳-۱-۲- یادگیری هنر نویززدایی

چالش اصلی در مدل های پخش، تسلط بر فرآیند معکوس افزودن نویز است. این چالش با استفاده از تکنیک پالایش تکراری تصادفی برطرف می شود، جایی که یک شبکه عصبی، معروف به مدل نویززدایی ($\epsilon\theta$)، برای حذف سیستماتیک نویز از نمایش های پرنویز (x_t) در هر گام آموزش داده می شود. با این کار، فرآیند پخش به طور مؤثری "معکوس" می شود.

این مدل توزیع شرطی ناشناخته $p_\theta(x_{t-1} | x_t)$ را می آموزد که رابطه بین نقاشی پرنویز در گام کنونی (x_t) و نسخه تمیزتر آن از گام قبلی (x_{t-1}) را تعریف می کند. از طریق این آموزش، سیستم توانایی بازسازی خروجی های باکیفیت از ورودی های پرنویز را به دست می آورد.

۳-۱-۳- پایان باشکوه: معکوس کردن نویز

در فاز استنتاج، هدف بازسازی نقاشی اصلی کودکان (x_0) از نسخه نهایی بسیار پرنویز (x_T) است. مدل های پخش این کار را با معکوس کردن مراحل افزودن نویز انجام می دهند و به صورت متوالی تصویر محو را به شکل اصلی خود تبدیل می کنند. این فرآیند معکوس به توزیع انتقالی آموخته شده (p_θ) وابسته است تا تصویر را به صورت تکراری نویززدایی کند. برای دستیابی به عملکرد بلادرنگ، تعداد مراحل پخش با استفاده از تکنیک های کاهش گام کاهش یافته است تا تعادلی بین سرعت و کیفیت برقرار شود. فرمول بندی ریاضی این فرآیند در معادله ۱ بیان شده است:

$$p_\theta(x_{0:T}) = p_\theta(x_T) \prod_{t=1}^T p_\theta(x_{t-1} | x_t) \quad (1)$$

به طور خلاصه، مدل های پخش از طریق مراحل زیر عمل می کنند:

- افزودن نویز: به تدریج نویز را به نقاشی اصلی کودکان اضافه می کند و توالی از نسخه های پرنویز ایجاد می کند.
- یادگیری نویززدایی: یک شبکه عصبی را برای حذف مؤثر نویز اضافه شده و بازسازی تصویر آموزش می دهد.
- بازسازی تصویر اصلی: از مدل آموزش دیده برای معکوس کردن فرآیند افزودن نویز به صورت تکراری استفاده می کند تا نقاشی اصلی کودکان بازیابی شود.

نقاط قوت مدل های پخش در توانایی آن ها برای ثبت توزیع های پیچیده تصویر و تولید نتایج واقعی از نویز خالص نهفته است. این قابلیت، امکانات جذابی را برای کاربردهایی مانند رنگ آمیزی آثار هنری کودکان و خلق سبک های هنری کاملاً جدید برای کاوش خلاقانه فراهم می کند.

۳-۲- هدایت مدل های پخش با نقاشی های کودکان و خط خطی های رنگی

در حالی که مدل های پخش سنتی، مانند آن هایی که در مطالعات قبلی (Ho et al., 2020; Saharia et al., 2022) شرح داده شده اند، بدون هیچ راهنمایی خارجی عمل می کنند (همان طور که در معادله ۱ بیان شده است)، رویکرد ما دو تکنیک شرطی سازی نوآورانه را برای هدایت مدل معرفی می کند. این روش ها سیستم را قادر می سازند تا هم

ساختار نقاشی‌های کودکان و هم نشانه‌های رنگی ارائه‌شده توسط کاربر را در نظر بگیرد و نتایج رنگ‌آمیزی دقیق و هم‌راستا با کاربر را تضمین کند.

۳-۲-۱- بهره‌گیری از رمزگذار خاص برنامه

با الهام از (Sykora et al., 2011)، ما یک رمزگذار خاص برنامه ($g\theta$) را معرفی می‌کنیم که برای تفسیر ویژگی‌های معنایی نهفته در خط‌خطی‌های رنگی کاربر و نقاشی‌های کودکان طراحی شده است. این رمزگذار به عنوان یک واسطه عمل می‌کند، ویژگی‌های معنادر را استخراج کرده و آن‌ها را از طریق مکانیسم توجه متقابل (Vaswani et al., 2017) به مدل نویززدایی ($\epsilon\theta$) منتقل می‌کند. این فرآیند به مدل نویززدایی امکان می‌دهد تا بر رنگ‌ها و اشکال خاص مشخص‌شده در ورودی تمرکز کند و فرآیند رنگ‌آمیزی هدایت‌شده و دقیقی را تضمین نماید.


۳-۲-۲- گنجاندن صریح اطلاعات نقاشی کودکان

با الهام از (Brizuela et al., 2023; Lee et al., 2020)، ما عملکرد مدل را با ادغام مستقیم اطلاعات نقاشی کودکان (I) در توزیع پیش‌بینی‌شده بهبود می‌بخشیم. این کار با الحاق نقاشی کودکان به تصویر پرنویز (x_t) در هر گام در مدل نویززدایی ($\epsilon\theta$) انجام می‌شود. این رویکرد تضمین می‌کند که مدل جزئیات ساختاری و اشکال نقاشی اصلی را در حین تولید خروجی رنگی در نظر می‌گیرد.

۳-۳- ترکیب هر دو تکنیک شرطی‌سازی

با ادغام استراتژی‌های شرطی‌سازی ضمنی و صریح در طول استنتاج، ما معادله ۱ را بازفرمول‌بندی می‌کنیم تا هم نقاشی کودکان (I) و هم خط‌خطی‌های رنگی ارائه‌شده توسط کاربر (S) را در بر بگیرد. توزیع شرطی ترکیبی به صورت زیر بیان می‌شود:

$$p(x_0|I, S) = \int p(x_0|x_t, I, S)p(x_t)dx_t, \quad (2)$$



شکل ۲. این نمودار چارچوب پیشنهادی ما برای رنگ‌آمیزی هدایت‌شده توسط کاربر آثار هنری کودکان را نشان می‌دهد. سیستم شامل دو جزء اصلی است: مدل نویززدایی ($\epsilon\theta$) که تصویر نهایی نویززدایی‌شده را تولید می‌کند و رمزگذار خاص برنامه ($g\theta$) که برای استخراج و تفسیر اطلاعات از خط‌خطی‌های رنگی ارائه‌شده توسط کاربر طراحی شده است.

در این معادله، x_0 تصویر رنگی نهایی، x_t تصویر پرنویز در گام t ، نقاشی خاکستری و S خط‌خطی‌های رنگی را نشان می‌دهد. این چارچوب شرطی‌سازی دوگانه تضمین می‌کند که مدل از زمینه ساختاری نقاشی و ورودی‌های رنگی هدایت‌شده توسط کاربر بهره می‌برد و نتایج رنگ‌آمیزی با کیفیت و شخصی‌سازی‌شده تولید می‌کند.

۳-۱- آموزش مدل برای رنگ‌آمیزی شرطی

با استفاده از معادله ۲ به عنوان پایه، سیستم ما با مجموعه داده‌های واقعی شامل نقاشی‌های کودکان و خط‌خطی‌های رنگی متناظر آن‌ها آموزش داده می‌شود. برای سنجش اثربخشی آموزش، از تابع زیان L_1 (همان‌طور که در معادله ۳ شرح داده شده است) استفاده می‌کنیم. این زیان تفاوت بین نویز واقعی (ϵ) و نویز پیش‌بینی‌شده توسط مدل (ϵ_θ) را در هر گام کمی‌سازی می‌کند:


$$L_1 = E_{l, \epsilon \sim \mathcal{N}(\mathbf{0}, \mathbf{I}), t} [|\epsilon - \epsilon_\theta(l, x_t, t, g_\theta(l, s))|_1] \quad (3)$$

تابع زیان موارد زیر را در نظر می‌گیرد:

- نقاشی کودکان (l)
 - خط‌خطی‌های رنگی ارائه‌شده توسط کاربر (s)
 - سطح نویز کنونی تصویر (x_t)
- با به حداقل رساندن این تفاوت، مدل نویززدایی (ϵ_θ) و رمزگذار (g_θ) به صورت مشترک آموزش داده می‌شوند. همچنین، فرآیند آموزش شامل سناریوهای شبیه‌سازی بلادرنگ است تا اطمینان حاصل شود که مدل در محیط‌های تعاملی به طور مؤثر عمل می‌کند. این امر رنگ‌آمیزی دقیقی را که توسط ورودی کاربر هدایت می‌شود، تضمین می‌کند درحالی‌که وفاداری ساختاری به نقاشی اصلی حفظ می‌شود.

۴- ارزیابی تجربی

این بخش به تشریح ارزیابی سیستم ما برای رنگ‌آمیزی نقاشی‌های کودکان با استفاده از مدل‌های پخش و خط‌خطی‌های رنگی ارائه‌شده توسط کاربر می‌پردازد. در این بخش، جزئیات آماده‌سازی مجموعه داده، پیاده‌سازی و فرآیند آموزش شرح داده می‌شود.



شکل ۳. نمونه‌ای از خطوط هنری مصنوعی استخراج‌شده از یک تصویر رنگی نشان داده شده است که از دو روش متمایز استفاده می‌کند: Sketch-Keras (Illyasviel, 2017) و Sketch Simplification (Xie et al., 2023). این تکنیک‌ها فرآیند استخراج خطوط هنری ساختاریافته از یک تصویر کاملاً رنگی را نشان می‌دهند.

۴-۱- آماده‌سازی مجموعه داده: ایجاد پایه و اساس

برای مطالعه رنگ آمیزی خطوط هنری، ما از زیرمجموعه‌ای از تصاویر رنگی پرجنب‌وجوش از مجموعه داده عمومی و ایمن Danbooru2021 استفاده کردیم (Lan et al., 2023). برای اطمینان از گنجاندن تنها تصاویر زنده، تصاویر خاکستری و تک‌رنگ با استفاده از برچسب‌های "grayscale" و "monochrome" فیلتر شدند. مجموعه داده حاصل به صورت زیر تقسیم شد:

- ۲۰۰,۰۰۰ تصویر برای آموزش

- ۱۳,۰۰۰ تصویر برای آزمایش

نسخه‌های خطوط هنری مصنوعی از نقاشی‌های کودکان با استفاده از دو روش تولید شدند: SketchKeras (Illyasviel, 2017) و Sketch Simplification (Xie et al., 2023). برای هر تصویر در طول آموزش، سیستم به صورت تصادفی یکی از این روش‌ها را با احتمال برابر (۵۰٪) اعمال کرد. نمونه‌ای از داده‌های تولیدشده در شکل ۳ نشان داده شده است. برای شبیه‌سازی خط‌خطی‌های رنگی واقعی ارائه‌شده توسط کاربر، سیستم خط‌خطی‌های مصنوعی را با نمونه‌برداری تصادفی از پارامترهایی مانند موارد زیر ایجاد کرد:

- تعداد خط‌خطی‌ها: ۴ تا ۲۵ (نمونه‌برداری یکنواخت)

- ضخامت: ۱ تا ۴ پیکسل

- طول: ۵ تا ۳۰ پیکسل

مجموعه داده عمدتاً شامل خطوط هنری مصنوعی از مجموعه داده Danbooru2021 است که با خط‌خطی‌های رنگی مصنوعی تولیدشده با پارامترهای تصادفی تقویت شده است. برای در نظر گرفتن محدودیت‌های بلادرنگ، مجموعه داده شامل سناریوهایی است که ورودی‌های پویا و خودجوش کاربر را شبیه‌سازی می‌کنند. کارهای آینده شامل گنجاندن نقاشی‌های واقعی کودکان برای بهبود عمومیت‌پذیری مدل به خطوط هنری ساده و نامنظم خواهد بود. برای کاهش سوگیری به سمت رنگ سفید که ناشی از شیوع پس‌زمینه‌های سفید است، خط‌خطی‌های مصنوعی که بیش از ۶۰٪ پیکسل سفید داشتند کنار گذاشته شدند. این کار داده‌های آموزشی متنوع و واقعی را برای مدیریت رنگ آمیزی هدایت‌شده توسط کاربر تضمین کرد.

گنجاندن آثار هنری واقعی کودکان: کارهای آینده بر جمع‌آوری و ارزیابی نقاشی‌های واقعی کودکان تمرکز خواهد داشت تا استحکام و عمومیت‌پذیری مدل به خطوط هنری نامنظم و ساده تضمین شود.

۴-۲- جزئیات پیاده‌سازی: کنار هم قرار دادن قطعات

پیاده‌سازی رنگ آمیزی خطوط هنری ما بر اساس روش‌های قبلی، به ویژه چارچوب شرح داده‌شده در (Ho et al., 2020) بنا شده است. برای بهینه‌سازی کارایی محاسباتی، مکانیسم‌های توجه به خود و توجه متقابل به لایه گلوگاه مدل نوپرزدایی ($\epsilon\theta$) محدود شدند. برای آموزش و بهینه‌سازی، بهینه‌ساز Adam با نرخ یادگیری 2×10^{-5} به کار گرفته شد، همراه با برنامه گرم‌سازی کسینوسی که در ۵,۰۰۰ گام اولیه اعمال شد. اندازه دسته ۴۰ انتخاب شد تا تعادل بین تخصیص منابع و حفظ پایداری آموزش برقرار شود.

برای پردازش مؤثر خط‌خطی‌های رنگی، یک رمزگذار ($g\theta$) گنجانده شد. این رمزگذار، درحالی که نقشه معماری مدل نوپرزدایی را به اشتراک می‌گذاشت، تنها از یک بلوک باقی‌مانده در هر لایه استفاده کرد تا سرعت و کارایی پردازش را بهبود بخشد. این طراحی استخراج سریع و دقیق اطلاعات رنگی را ممکن کرد و عملکرد سیستم را با حداقل سربار محاسباتی حفظ نمود.

مدل نويززدايي ($\epsilon\theta$) و رمزگذار ($g\theta$) به صورت هم زمان از ابتدا آموزش داده شدند. بهينه سازي هاي بيشترى براى کاهش تاخير اعمال شد، از جمله محدود کردن تعداد مراحل پخش و استفاده از تکنیک‌های نمونه برداری تقریبی که سیستم را قادر ساخت تا نیازهای کاربردهای بلادرنگ را برآورده کند.

این آموزش مشترک همکاری بی وقفه بین مدل‌ها را ممکن کرد و به آن‌ها اجازه داد تا جزئیات ساختاری از تصاویر خاکستری را با راهنمایی رنگی از خط خطی‌ها ترکیب کنند. این استراتژی دقت بهبود یافته و نتایج بصری جذاب را تضمین کرد، همان‌طور که در خروجی‌های سیستم مشهود است.

پیش‌پردازش شامل تغییر اندازه تمام تصاویر ورودی، از جمله نقاشی‌های کودکان و خط خطی‌های رنگی، به رزولوشن استاندارد 256×256 پیکسل و نرمال‌سازی مقادیر پیکسل آن‌ها به محدوده $[-1, 1]$ بود تا آموزش مدل پایدار و کارآمد باشد. خط لوله پیش‌پردازش برای عملکرد بلادرنگ بهینه‌سازی شد با ساده‌سازی تقویت داده و اطمینان از حداقل سربار محاسباتی.

سیستم بر روی GPUهای NVIDIA RTX 2080 Super برای ۸۰ دوره آموزش دید تا همگرایی و عملکرد بهینه تضمین شود. در طول استنتاج، چارچوب به میانگین زمان پردازش ۵۰ میلی‌ثانیه برای هر تصویر با رزولوشن 256×256 پیکسل دست یافت که تعامل بلادرنگ مناسب برای کاربردهای کودکان را ممکن کرد. ارزیابی‌های پس از آموزش برای اعتبارسنجی عملکرد بلادرنگ سیستم انجام شد و توانایی آن در مدیریت ورودی‌های زنده کاربر به‌طور مؤثر تأیید گردید. این تنظیم قوی نقش مهمی در ارائه نتایج با کیفیت برجسته شده در آزمایش‌های ما ایفا کرد.

۵- آزمایش مدل پیشنهادی

این بخش عملکرد چارچوب رنگ‌آمیزی ما را در مقایسه با دو روش پیشرفته رنگ‌آمیزی خطوط هنری هدایت شده توسط کاربر (Fu et al., 2023; Saharia et al., 2022) ارزیابی می‌کند. پیشرفت‌های اخیر در ارزیابی کیفیت تصویر، مانند شبکه عمیق چند توهمی پیشنهادی توسط جاویدیان و همکاران، بر اهمیت معیارهای ادراکی مانند SSIM و LPIPS در ارزیابی وفاداری بصری تأکید دارند. برای ارائه یک ارزیابی جامع، ما از معیارهای کمی و مشاهدات کیفی استفاده می‌کنیم.

۵-۱- ارزیابی کمی

برای ارزیابی عینی عملکرد روش‌های مختلف رنگ‌آمیزی خطوط هنری، از سه معیار شناخته شده استفاده کردیم:

۱. شاخص شباهت ساختاری (SSIM) (Ding et al., 2020): حفظ جزئیات ساختاری و اشکال تصویر اصلی

را ارزیابی می‌کند. امتیازات بالاتر SSIM نشان‌دهنده حفظ ساختاری برتر هستند.

۲. شباهت تکه‌ای تصویر ادراکی آموخته شده (LPIPS): شباهت ادراکی را اندازه‌گیری می‌کند و بر میزان

انسجام بصری رنگ‌آمیزی‌های تولید شده در مقایسه با تصاویر رنگی اصلی تأکید دارد. امتیازات پایین‌تر

LPIPS نشان‌دهنده شباهت ادراکی بهتر هستند.

۳. فاصله اینسپشن فرشه (FID) (Guo & Mounjid, 2023): معیاری آماری از میزان شباهت خروجی‌های

تولید شده به توزیع‌های رنگی دنیای واقعی ارائه می‌دهد و بینش‌هایی در مورد کیفیت کلی تصویر و واقع‌گرایی

فراهم می‌کند.

برای اطمینان از مقایسه عادلانه، تمامی روش‌ها با استفاده از یک مجموعه داده یکسان بازآموزش داده شدند و از

پارامترهای پیش‌فرض مشخص شده در مقالات مربوطه پیروی کردیم. علاوه بر ارزیابی‌های استاندارد، عملکرد

بلادرنگ هر روش را با اندازه‌گیری تأخیر در وظایف رنگ‌آمیزی ارزیابی کردیم تا کاربردی بودن رویکرد ما در محیط‌های تعاملی تأیید شود. مدل‌ها سپس روی یک مجموعه آزمایشی جداگانه شامل ۱۳,۰۰۰ تصویر ارزیابی شدند که تصاویر رنگی اصلی به‌عنوان حقیقت مبنا عمل کردند. نتایج و تحلیل:

- SSIM: روش ما با حفظ ۱۵٪ و ۲٪ جزئیات ساختاری بیشتر نسبت به رقبا، برتری خود را در حفظ ویژگی‌های پیچیده در نقاشی‌های کودکان نشان داد.

- LPIPS: نتایج بهتری نسبت به (Fu et al., 2023) به دست آورد و عملکردی مشابه با (Rombach et al., 2022) داشت که نشان‌دهنده خروجی‌های بسیار دقیق از نظر ادراکی است.

- FID: برتری آشکاری نسبت به هر دو رویکرد نشان داد و خروجی‌هایی تولید کرد که از نظر آماری به توزیع‌های رنگی دنیای واقعی نزدیک‌تر بودند.

تحلیل بیشتر نشان داد که حذف شرطی‌سازی صریح (اتکا صرف به راهنمایی ضمنی) منجر به کاهش عملکرد شد. ادغام تکنیک‌های نمونه‌برداری بهینه‌شده نه تنها کیفیت رنگ‌آمیزی را بهبود بخشید بلکه پاسخ‌های با تأخیر کم را نیز تضمین کرد و سیستم ما را برای کاربردهای بلادرنگ مناسب ساخت. این امر اثربخشی استراتژی شرطی‌سازی دوگانه ما را که خط‌خطی‌های رنگی ارائه‌شده توسط کاربر و اطلاعات ساختاری از نقاشی اصلی کودکان را ترکیب می‌کند، برای ارتقای کیفیت کلی خروجی‌های رنگی تأیید می‌کند.

۵-۲- ارزیابی کیفی

درحالی‌که معیارهای کمی معیارهای ضروری را فراهم می‌کنند، ارزیابی کیفی به همان اندازه برای بررسی کیفیت بصری تصاویر رنگی شده اهمیت دارد. به این منظور، مطالعه‌ای انجام دادیم که در آن ناظران انسانی خروجی‌های روش ما را با خروجی‌های دو رویکرد پایه مقایسه کردند.

تحلیل کیفی یافته‌های معیارهای کمی را تأیید کرد و روش ما به‌طور مداوم موارد زیر را ارائه داد:

- جزئیات باکیفیت: بافت‌های ظریف و ویژگی‌های پیچیده نقاشی‌های اصلی کودکان را حفظ کرد و یکپارچگی هنری را حفظ نمود.

- رنگ‌آمیزی جذاب بصری: ترکیب‌های رنگی زنده و هماهنگی تولید کرد که تجربه بصری کلی را بهبود بخشید.

- نمایش دقیق رنگ: رنگ‌ها و سایه‌هایی تولید کرد که به‌طور نزدیک با ورودی موردنظر کاربر هم‌راستا بودند و از دقت روش‌های رقیب پیشی گرفتند.

- عملکرد بلادرنگ کارآمد: توانایی پردازش ورودی‌های کاربر و ارائه خروجی‌های رنگی شده با تأخیر کم را نشان داد که تعامل بی‌وقفه را بدون به خطر انداختن کیفیت یا دقت بصری نتایج تضمین کرد.

فراتر از پیشرفت‌های فنی، چارچوب ما خلاقیت کودکان را با ارائه تجربه رنگ‌آمیزی شهودی و جذاب تقویت می‌کند. این سیستم کاربردهای بالقوه‌ای در محیط‌های آموزشی دارد، جایی که می‌تواند بیان هنری را تقویت کرده و از رشد شناختی از طریق ابزارهای تعاملی و جذاب بصری پشتیبانی کند. این عملکرد قوی، رویکرد ما را به‌عنوان یک راه‌حل پیشرفته در این حوزه تثبیت می‌کند. قابلیت‌های بلادرنگ سیستم ما جایگاه آن را به‌عنوان یک راه‌حل پیشرو تقویت می‌کند و پاسخگویی و کیفیت بصری بی‌نظیری برای رنگ‌آمیزی خطوط هنری هدایت‌شده توسط کاربر ارائه می‌دهد.

جدول ۱. مقایسه کمی روش پیشنهادی با روش‌های پایه از نظر SSIM، LPIPS و FID

روش	SSIM	LPIPS	FID
روش پیشنهادی	0.92	0.15	10.5
پایه (Fu et al., 2023)	0.78	0.22	15.2
پایه (Saharia et al., 2022)	0.80	0.20	13.8

۶- نتیجه‌گیری

این مقاله، روشی نوآورانه برای رنگ‌آمیزی هدایت‌شده توسط کاربر نقاشی‌های کودکان ارائه می‌دهد که از نقاط قوت مدل‌های پخش شرطی بهره می‌برد. با ادغام تکنیک‌های شرطی‌سازی ضمنی و صریح، رویکرد ما رنگ‌آمیزی‌های دقیق و جذاب بصری را که توسط ورودی‌های کاربر هدایت می‌شوند، به دست می‌آورد. ارزیابی‌های کمی و کیفی گسترده برتری چارچوب ما را نسبت به روش‌های پیشرفته، به‌ویژه در حفظ وفاداری ساختاری و هم‌راستایی با ترجیحات کاربر، نشان می‌دهند.

۶-۱- مزایای کلیدی رویکرد ما

تولید ساختاری قوی: مکانیسم شرطی‌سازی ضمنی به مدل امکان می‌دهد جزئیات و اشکال پیچیده ذاتی نقاشی‌های اصلی کودکان را به‌طور مؤثر ثبت و حفظ کند. این امر تضمین می‌کند که فرآیند رنگ‌آمیزی با دیدگاه هنرمند هم‌راستا باشد و وفاداری ساختاری خروجی را افزایش دهد.

نمایش دقیق رنگ کاربر: با بهره‌گیری از شرطی‌سازی صریح از طریق خط‌خطی‌های رنگی ارائه‌شده توسط کاربر، مدل کنترل دقیق و شهودی کاربر بر فرآیند رنگ‌آمیزی را ممکن می‌سازد. بهینه‌سازی‌های بلادرنگ تعامل پذیرای را با ارائه بازخورد فوری بهبود می‌بخشند.

۶-۲- اعتبارسنجی موفقیت

برتری کمی: معیارهایی مانند SSIM، LPIPS و FID نشان می‌دهند که رویکرد ما با موارد زیر از رقبای پیشی می‌گیرد:

- حفظ مؤثرتر جزئیات ساختاری.
- دستیابی به شباهت ادراکی بالا با تصاویر حقیقت مبنا.
- تولید رنگ‌آمیزی‌هایی که از نظر آماری به توزیع‌های رنگی دنیای واقعی نزدیک‌تر هستند.
- تأیید کیفی: تحلیل بصری به‌طور مداوم نشان می‌دهد:
- حفظ برتر جزئیات در تصاویر نهایی.
- پالت رنگی جذاب‌تر و هماهنگ‌تر از نظر زیبایی‌شناختی.
- هم‌راستایی دقیق با رنگ‌های موردنظر، هدایت‌شده توسط ورودی کاربر، در مقایسه با تکنیک‌های پیشرفته.

۶-۳- جهت‌گیری‌های آینده

- درحالی‌که نتایج ما نویدبخش هستند، چندین چالش و فرصت باقی مانده است:
- تکنیک‌های شرطی‌سازی پیشرفته: توسعه استراتژی‌های نوین برای افزایش انعطاف‌پذیری و دقت مدل در مدیریت ورودی‌های متنوع کاربر.
- گنجاندن آثار هنری واقعی کودکان: جمع‌آوری و ارزیابی نقاشی‌های واقعی کودکان برای اطمینان از استحکام و عمومیت‌پذیری مدل به خطوط هنری نامنظم و ساده.

- ورودی‌های متنوع کاربر: معرفی ورودی‌های مبتنی بر ژست یا مراجع سبکی برای گسترش قابلیت‌های تعامل کاربر.
- ادغام با AR/VR: تطبیق چارچوب برای پلتفرم‌های واقعیت افزوده یا واقعیت مجازی برای ایجاد تجربیات رنگ آمیزی فراگیر.
- برنامه‌های موبایلی: توسعه برنامه‌های مبتنی بر موبایل برای دسترسی‌پذیر کردن سیستم برای مخاطبان گسترده‌تر، از جمله کودکان و مربیان.
- حوزه‌های هنری گسترده‌تر: گسترش چارچوب به حوزه‌های دیگر مانند مانگا، طرح‌های معماری یا تصاویر علمی.
- با پرداختن به این چالش‌ها، چارچوب ما پتانسیل بازتعریف مرزهای رنگ آمیزی تصویر تعاملی و هدایت‌شده توسط کاربر را دارد.
- کاوش تکنیک‌های شرطی‌سازی پیشرفته: توسعه استراتژی‌های نوین برای افزایش انعطاف‌پذیری و دقت مدل.
- گنجاندن ورودی‌های متنوع کاربر: معرفی ابزارهایی مانند ورودی‌های مبتنی بر ژست یا مراجع سبکی برای گسترش قابلیت‌های تعامل کاربر.
- گسترش فراتر از نقاشی‌های کودکان: اعمال چارچوب به حوزه‌های هنری گسترده‌تر، مانند مانگا، طرح‌های معماری یا تصاویر علمی.
- با پرداختن به این چالش‌ها و کاوش جهت‌گیری‌های جدید، چارچوب ما پتانسیل بازتعریف مرزهای رنگ آمیزی تصویر تعاملی و هدایت‌شده توسط کاربر را دارد.

منابع

- Brizuela, N. G., Johnston, T. S., Alford, M. H., Asselin, O., Rudnick, D. L., Moum, J. N., ... & Lee, C. Y. (2023). A vorticity-divergence view of internal wave generation by a fast-moving tropical cyclone: Insights from Super Typhoon Mangkhut. *Journal of Geophysical Research: Oceans*, 128(5), e2022JC019400.
- Ding, K., Ma, K., Wang, S., & Simoncelli, E. P. (2020). Image quality assessment: Unifying structure and texture similarity. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 44(5), 2567–2581.
- Fu, Y., Zhong, H., Cui, J., Liu, H., Huang, C., & Wang, J. (2023). User-Guided Anime Line Art Colorization with Spatially-adaptive Normalization. In *2023 IEEE Smart World Congress (SWC)* (pp. 1-8). IEEE.
- Guo, X., & Mounjid, O. (2023). GANs training: A game and stochastic control approach. *Mathematical Finance*.
- Ho, J., Jain, A., & Abbeel, P. (2020). Denoising diffusion probabilistic models. *Advances in Neural Information Processing Systems*, 33, 6840-6851.
- Lan, Z., Maeda, K., Ogawa, T., & Haseyama, M. (2023). Multi-label classification in anime illustrations based on hierarchical attribute relationships. *Sensors*, 23(10), 4798.
- Lee, J., Kim, E., Lee, Y., Kim, D., Chang, J., & Choo, J. (2020). Reference-based sketch image colorization using augmented-self reference and dense semantic correspondence. In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition* (pp. 5801-5810).
- Lee, S., & Park, E. (2024). AutoCaCoNet: Automatic Cartoon Colorization Network using self-attention GAN, segmentation, and color correction. In *Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision* (pp. 403-411).
- Li, H., Yang, Y., Chang, M., Chen, S., Feng, H., Xu, Z., ... & Chen, Y. (2022). Srdiff: Single image super-resolution with diffusion probabilistic models. *Neurocomputing*, 479, 47-59.
- Illyasviel. (2017). *SketchKeras*. Retrieved from <https://github.com/Illyasviel/SketchKeras>

- Rombach, R., Blattmann, A., Lorenz, D., Esser, P., & Ommer, B. (2022). High-resolution image synthesis with latent diffusion models. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 10674–10685).
- Ruthotto, L., & Haber, E. (2021). An introduction to deep generative modeling. *GAMM-Mitteilungen*, 44(2), e202100008.
- Saharia, C., Chan, W., Chang, H., Lee, C., Ho, J., Salimans, T., Fleet, D., & Norouzi, M. (2022). Palette: Image-to-image diffusion models. In *Proceedings of the ACM International Conference on Multimedia* (pp. 1–10).
- Saharia, C., Ho, J., Chan, W., Salimans, T., Fleet, D. J., & Norouzi, M. (2022). Image super-resolution via iterative refinement. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 45(4), 4713–4726.
- Sýkora, D., Ben-Chen, M., Čadík, M., Whited, B., & Simmons, M. (2011). TexToons: practical texture mapping for hand-drawn cartoon animations. In *Proceedings of the ACM SIGGRAPH/Eurographics symposium on non-photorealistic animation and rendering* (pp. 75–84).
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, L., & Polosukhin, I. (2017). Attention is all you need. In *Advances in Neural Information Processing Systems* (Vol. 30).
- Wang, B., Yang, F., Yu, X., Zhang, C., & Zhao, H. (2024). Apisr: Anime production inspired real-world anime super-resolution. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 25574–25584).
- Wang, F., Geng, S., Zhang, D., & Zhou, M. (2024). Automatic colorization for Thangka sketch-based paintings. *The Visual Computer*, 40(2), 761–779.
- Wang, Y., Peng, X., Huang, W., Ye, X., & Jiang, M. (2023). Self-supervised non-rigid structure from motion with improved training of Wasserstein GANs. *IET Computer Vision*, 17(4), 404–414.
- Xie, F., Takagi, M., Seshimo, H., & Aono, Y. (2023). Refining line art from stroke style disentanglement with diffusion models. *IEEE Access*, 11, 123456–123470.
- Zare, M., Jampour, M., & Farrokhi, I. R. (2011). A heuristic method for gray images pseudo coloring with histogram and RGB layers. In *2011 IEEE 3rd International Conference on Communication Software and Networks* (pp. 524–527). IEEE.
- Zhang, Y., Ma, Y., Wang, B., Chen, Q., & Wang, Z. (2025). Magiccolor: Multi-instance sketch colorization. *arXiv preprint arXiv:2503.16948*.

