

مه زدایی تصاویر دیجیتال با استفاده از ترکیب ویژگی‌ها و یادگیری عمیق

سمیه رستگاری فرا^۱، یاسر علمی سولا^{۲*}

چکیده

مه معمولاً باعث تداخل شدید در تصویر می‌شود. چنین تخریبی در تصاویر هم ناظران انسانی و هم سیستم‌های بینایی رایانه‌ای را با مشکل مواجه می‌کند. مه زدایی تصویر فرآیند بهبود کیفیت تصاویری است که تحت تأثیر پراکندگی ناشی از هوا یا قطرات ریز آب قرار گرفته‌اند. در این مقاله روشی نوین برای حذف مه با کیفیت بالا پیشنهاد شده است. الگوریتم پیشنهاد شده برای حذف مه از تصاویر از ترکیب دو روش کارآمد با پایه ریاضی و افزودن یک طبقه یادگیر عمیق کمک گرفته است. روش پیشنهادی در فاز اول مه زدایی را بر اساس یکسان سازی هیستوگرام تطبیقی و تصحیح گاما انجام می‌دهد. این بخش در فضای رنگ HSV و RGB عمل می‌کند. در فاز دوم از روش مبتنی بر کانال رنگ استفاده شده است که برای حذف مه با الگو گرفتن از مغز انسان، با پردازش بر روی روش‌شنایی و میزان اشباع پیکسل‌ها در یک تصویر مه‌آلود و برر سی تغییرات غلظت مه زدایی را انجام می‌دهد. در فاز سوم از شبکه عمیق رفع نویز DnCNN برای رسیدن به تصویر با کیفیت بالاتر کمک گرفته شده است. شبکه DnCNN با این توجیه که پس از پردازش تصاویر، مه باقیمانده از یک الگوی نویزی تبعیت می‌کند و می‌توان آن را نویز در نظر گرفت استفاده شده است. نتایج پیاده سازی و ارزیابی روش پیشنهادی بر روی پایگاه داده‌های تصویری استاندارد نشان داد که روش پیشنهادی علاوه بر بهبود کیفیت نتایج نسبت به روش‌های قبلی، از نظر حافظه‌ی اشغالی نیز بهتر عمل می‌کند. از دیگر امتیازات روش پیشنهادی آن است که می‌توان برای مه زدایی تصاویر با اندازه کوچک هم از این روش استفاده کرد.

کلمات کلیدی: مه زدایی تصویر، یادگیری عمیق، یکسان سازی هیستوگرام، شبکه عصبی کانولوشنی

دریافت مقاله :

پذیرش مقاله:

۱- مقدمه

مه یک پدیده هواشناسی است که زمانی رخ می‌دهد که قطرات آب یا کریستال‌های یخ در هوا در نزدیکی سطح زمین معلق می‌شوند و منجر به کاهش دید می‌شود. می‌توان آن را به صورت ابری در سطح زمین در نظر گرفت. شرایط نامساعد آب و هوایی مانند مه، باران سنگین و برف باعث کاهش کیفیت تصاویر در فضای باز می‌شوند. این وضعیت‌ها طیف گسترده‌ای از اختلالات مانند نویز و کاهش وضوح تصویر را به همراه دارند. در نتیجه، دوربین‌های مداربسته، سیستم‌های ردیابی و ناوبری و برنامه‌های کاربردی که قابلیت اطمینان در آنها حیاتی است (مانند نظارت در فضای باز و تشخیص شیء)، با مشکلات زیادی مواجه می‌شوند. مه زدایی تصاویر (SID)، فرایندی برای بازیابی یک تصویر تمیز از یک ورودی تخریب‌شده است، تصویری که از صحنه‌ای مه گرفته، گرفته شده است. هدف این مقاله، حذف مه از

تصاویر دیجیتال با ایجاد حداقل تخریب در آنهاست که از ترکیب مجموعه‌ای از ویژگی‌های حوزه زمان و فرکانس استفاده شده و الگوریتم‌های یادگیری عمیق به کار گرفته خواهد شد.

۱-۱ مدل سازی فرایند حذف مه

مه یک پدیده طبیعی است که می‌توان با استفاده از مدل ASM آن را توضیح داد. این مدل یک پایه قابل اعتماد برای حذف مه فراهم می‌کند. رابطه مربوط به آن به شکل زیر است:

$$I(x) = J(x)t(x) + A(1 - t(x)) \quad (1)$$

که در آن، مختصات پیکسل با x نشان داده می‌شود و A به معنای نور جوی است. در رابطه فوق $I(x), J(x) \in \mathbb{R}^3$ تصاویر رنگی اصلی و مه‌آلود، A روشنایی محیط و t تابع انتقال یا بازتابش محیط می‌باشد که توصیف بخشی از نور که پراکنده نشده و به دوربین نمی‌رسد توسط تابع انتقال

^۱ گروه مهندسی کامپیوتر، واحد سبزوار، دانشگاه آزاد اسلامی، سبزوار، ایران

^{۲*} گروه مهندسی کامپیوتر، واحد سبزوار، دانشگاه آزاد اسلامی، سبزوار، ایران (نویسنده مسئول : Yasser.Elmi@iau.ac.ir)

۲- سوابق پژوهش

روش های SID موجود را می توان به دو دسته طبقه بندی کرد، روش های سنتی پردازش تصویر و روش های مبتنی بر یادگیری عمیق. اخیراً، یادگیری عمیق در وظایف مختلف پردازش تصویر استفاده شده و عملکرد مناسبی نشان داده است. در مجموع با توجه به نتایج در حوزه SID روش های مبتنی بر یادگیری عمیق برتر از الگوریتم های سنتی هستند [۴-۱].

مدل های رفع مه به صورت نظارت شده معمولاً به انواع مختلف سیگنال های نظارتی در فرآیند آموزش نیاز دارند، مانند نقشه انتقال، نور جوی، برجسب تصویر بدون مه و غیره. به طور مفهومی، روش های رفع مه با نظارت می توانند به دو دسته مبتنی بر ASM و غیر مبتنی بر ASM تقسیم شوند. با این حال، ممکن است همپوشانی هایی در این دسته بندی وجود داشته باشد، زیرا هر دو الگوریتم مبتنی بر ASM و غیر مبتنی بر ASM ممکن است با سایر عملیات های مبتنی بر بینایی کامپیوتر مانند بخش بندی، تشخیص و تخمین عمق ترکیب شوند. بنابراین، این بخش الگوریتم های نظارتی را بر اساس مشارکت اصلی آن ها دسته بندی می کند تا تکنیک هایی که برای تحقیقات رفع مه مفید هستند به وضوح مشاهده شوند. برای نشان دادن یک تصویر کلی از نقاط ضعف روش های مختلف پیشنهاد شده تاکنون، یک کار مقایسه ای در جدول ۱ انجام شده است.

محیط صورت می گیرد. هدف از حذف مه محاسبه J با استفاده از A, t, I می باشد.

عبارت اول $I(x)t(x)$ میرایی مستقیم و عبارت دوم $A(1-t(x))$ نور محیطی است که جایگزین تابش مستقیم صحنه می شود. میرایی مستقیم، درخشندگی صحنه و واپاشی آن در محیط را توصیف کرده، و نور محیطی نتیجه نوری که قبلاً پراکنده شده و منجر به تغییر رنگ صحنه می شود، می باشد. در حالی که میرایی مستقیم ضربی از اعوجاج درخشندگی صحنه است، نور محیطی یک اشباع کننده است. $t(x)$ به معنای نقشه انتقال متوسط است که به صورت زیر تعریف می شود:

$$t(x) = e^{-\beta d(x)} \quad (2)$$

در این مدل، β و $d(x)$ به ترتیب نشان دهنده پارامتر پراکندگی جو و عمق $I(x)$ هستند. بنابراین، $t(x)$ توسط $d(x)$ تعیین می شود که می تواند برای سنتز تصویر مه آلود استفاده شود. اگر $t(x)$ و A قابل تخمین باشند، تصویر بدون مه $J(x)$ را می توان با استفاده از رابطه زیر به دست آورد:

$$J(x) = \frac{I(x) - A(1-t(x))}{t(x)} \quad (3)$$

در روش های رفع مه گرفتگی بر اساس ASM، معمولاً A ناشناخته است. $I(x)$ نشان دهنده تصویر مه گرفته و $J(x)$ نشان دهنده تصویر صحنه واضح است. برای بیشتر مدل های رفع مه گرفتگی، $I(x)$ ورودی و $J(x)$ خروجی مطلوب است

جدول ۱: مقایسه روش های مختلف حذف مه و نقاط ضعف هر یک

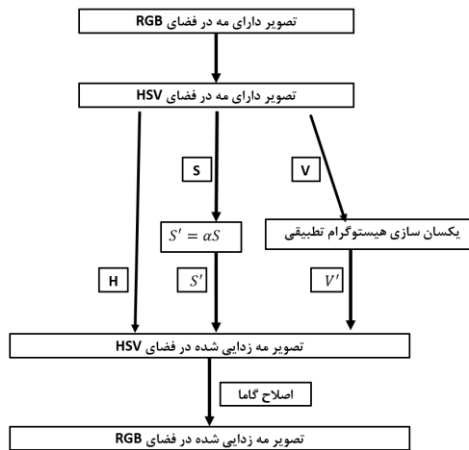
مرجع	نام روش	متد
[۵]	MSCNN	کمینه کردن خطای L2
[۶]	DCPDN	کمینه کردن خطای L2، خطای گرادیان دو جهته، و خطای لبه ویژگی
[۷]	GFN	ترکیب سه معیار مختلف وزن دار
[۸]	LAP-Net	استفاده از یک stagewise loss
[۹]	PFDN	مبتنی بر مجموعه ای از ویژگی ها
[۱۰]	DMMFD	استفاده از ضرب، جمع، توان و تجزیه لگاریتمی
[۹]	KDDN	یک مکانیزم یادگیری process-oriented
[۱۱]	AECR-Net	استفاده از مدل از پیش آموزش دیده
[۱۲]	pWAE	استفاده از یک وزن تطبیقی بین dehazed image و style information
[۱۳]	Retinex-CNN	استفاده از ارتباط بین تصویر مه آلود و تصویر بدون مه
[۱۴]	GCANet	استفاده از Residual Learning
[۱۵]	EMRA-Net	تبدیل موجک گسسته
[۱۶]	S2DNet	استفاده از داده عمق
[۱۷]	TSDCN-Net	استفاده از شبکه آبخاری

این ایرادات هنوز نیاز به روش های مبتنی بر هوش مصنوعی و تطبیقی با هدف الگو کردن بهتر مه در شرایط مختلف و حذف آن احساس می شود.

۳- روش پیشنهادی

همان طور که در بخش دوم اشاره شد روش های متفاوتی برای حذف مه از تصویر وجود دارد که یکی از این روش ها مه زدایی بر اساس یکسان سازی هیستوگرام تطبیقی و تصحیح گاما [۱۹] می باشد. روش پیشنهادی ترکیب این روش با یادگیری عمیق است لذا این روش به صورت کامل تبیین می شود. شکل ۱ فلوجارت روش [۱۹] را نشان می دهد. سه مرحله اصلی این روش شامل پردازش کانال های S, V در فضای HSV و اصلاح گاما می باشد.

روش های مبتنی بر خطا مانند [5-8, 18] به دلیل نبود تصویر مرجع همواره تقریبی هستند. روش های مبتنی بر ویژگی و الگوی آماری پویا و تطبیقی نیستند و ثابت حساب می شوند، بنابراین در شرایط مختلف افت کارایی دارند. شبکه های پیش آموزش داده شده به صورت عمومی طراحی شده اند و معمولاً کارایی نسبی مناسبی در حذف مه دارند. روش های مبتنی بر ارتباط بین بخش های مختلف تصویر دارای مه همگی آماری هستند و در شرایط مختلف منجر به بروز خطاهای عدم قطعیت می شوند. تبدیل موجک الگوی زمان فرکانس قوی تری نسبت به تبدیل فوریه دارد اما مشکلاتی در مدل کردن منحنی ها و جهت ها دارد. روش های باقیمانده فوق نیز به داده های اضافه عمق و رادار یا سنسور نیاز دارند که همیشه در دسترس نیست. با توجه به



شکل ۱: فلوجارت روش ارائه شده در [۱۹]

در پردازش کانال S، از آنجایی که همسان سازی هیستوگرام تطبیقی اشباع تصویر را کاهش می دهد، باید نوار اشباع را بهبود دهیم. در فضای HSV برای این کار باید کانال S را تغییر دهیم.

$$S' = \alpha S, \alpha > 0 \quad (4)$$

α پارامتری است که در [۱۹] 1.65 انتخاب شده و می تواند توسط کاربر به صورت دستی نیز وارد شود یا بر اساس حلقه تکرار و بهینه کردن تابع هزینه محاسبه شود. آخرین و مهم ترین مرحله این روش، تصحیح خطی گاما در فضای RGB است تا نتیجه مه زدایی نهایی را به دست آوریم:

$$f(u) = \begin{cases} -f(u), & \text{if } u < 0 \\ cu, & \text{if } 0 \leq u < d \\ (au + b)^Y, & u \geq d \end{cases} \quad (5)$$

یکسان سازی هیستوگرام تطبیقی (پردازش کانال V) یک روش افزایش کنتراست تصویر است. این روش در مناطق محلی تصویر (به عنوان مثال پنجره 5×5) عمل می کند. تابع تبدیل کنتراست برای هر پنجره محاسبه می شود و برای افزایش کنتراست به همان ناحیه اعمال می شود. بنابراین، هیستوگرام ناحیه تقریباً با هیستوگرام مشخص شده توسط توزیع هدف، مانند یکنواخت، را یلی یا نمایی مطابقت دارد. در نهایت، تمامی نواحی همسایه با استفاده از درون یابی دو خطی ترکیب می شوند تا ناپیوستگی احتمالی بین آنها حذف شود. درونیابی دو خطی در ریاضیات توسعه درونیابی خطی است که بر روی دو متغیر در جدول دو بعدی معمولی عمل می کند. تابع های درونیابی شده نباید از جمله های x^2 یا y^2 استفاده کند و تنها شامل xy که حالت دو خطی دو متغیر است خواهند بود.

در بیشتر موارد نقش مهم تری ایفا می‌کند، مناطق مه آلودتر در تصویر با روشنایی بالا و اشباع کم مشخص می‌شوند. علاوه بر این، هرچه مه غلیظتر باشد، تأثیر نور هوا قوی‌تر خواهد بود. این به ما امکان می‌دهد از تفاوت بین روشنایی و اشباع برای تخمین غلظت مه استفاده کنیم. همانطور که اشاره شد، از آنجایی که غلظت مه همراه با تغییر عمق صحنه به‌طور کلی افزایش می‌یابد، می‌توان فرض کرد که عمق صحنه با غلظت مه همبستگی مثبت دارد و داریم:

$$d(x) \propto c(x) \propto v(x) - s(x) \quad (10)$$

که d عمق، c غلظت، v و s روشنایی و اشباع هستند.

برای برآورد عمق، یک مدل خطی فرض می‌کنیم:

$$d(x) = \theta_0 + \theta_1 v(x) + \theta_2 s(x) + \varepsilon(x) \quad (11)$$

که در این رابطه $\theta_0, \theta_1, \theta_2$ ضرایب مجهول هستند.

$\varepsilon(x)$ یک متغیر تصادفی است که نشان دهنده خطای

مدل است و آن را می‌توان به‌عنوان یک تصویر تصادفی در نظر گرفت. برای ε در این مقاله از یک متغیر گاوسی با میانگین صفر و واریانس σ استفاده شده است. با توجه به

ویژگی توزیع گاوسی، داریم:

$$d(x) \sim p(d(x) | x, \theta_0, \theta_1, \theta_2, \sigma^2) = N(\theta_0 + \theta_1 v + \theta_2 s, \sigma^2) \quad (12)$$

یکی از مهم‌ترین مزایای این مدل داشتن خاصیت حفظ لبه است. این خاصیت تضمین می‌کند که اطلاعات عمق را می‌توان به‌خوبی حتی در نزدیکی ناپیوستگی‌های عمق در صحنه بازیابی کرد.

به‌منظور مشخص شدن ضرایب $\theta_0, \theta_1, \theta_2$ ، داده‌های آموزشی لازم است. در [۲۰]، از روش تانگ و همکاران [۲۱] برای تهیه داده‌های آموزشی استفاده شده و تصاویر بدون مه نیز از Google Images و Flickr جمع‌آوری و از آنها برای تولید نقشه‌های عمق مصنوعی و تصاویر مه‌آلود مربوطه استفاده شده است. فرآیند تولید نمونه‌های آموزشی [۲۰] در شکل ۲ نشان داده شده است. ابتدا برای هر تصویر بدون مه، یک نقشه عمق تصادفی با همان اندازه ایجاد و سپس مقادیر پیکسل‌ها در نقشه عمق مصنوعی از توزیع یکنواخت استاندارد مشخص می‌شوند. در مرحله دوم، نور تصادفی جو تولید می‌شود. در نهایت، تصویر مه‌آلود مطابق با رابطه ۴ و ۵ ایجاد می‌شود. در [۲۰]، ۵۰۰ تصویر بدون مه برای تولید نمونه‌های آموزشی استفاده شده است (۵۰۰ نقشه عمق تصادفی و ۵۰۰ تصویر مه‌آلود مصنوعی).

که f و u مقادیر پیکسل هر کانال قرمز / سبز / آبی تصویر اولیه مه زدایی شده در فضای رنگی RGB و تصویر نهایی در فضای رنگی استاندارد RGB می‌باشد.

این روش مبتنی بر کانال رنگ عمل می‌کند. در رابطه فوق، عمق صحنه d مهم‌ترین اطلاعات است زیرا ضریب پراکندگی β را می‌توان به‌عنوان یک ثابت در شرایط جوی همگن گرفت و با معلوم شدن این دو t را می‌توان به‌راحتی تخمین زد. در حالت ایده‌آل، محدوده d بین $[0, +\infty)$ است و از آنجایی که اشیاء که در تصویر ظاهر می‌شود می‌توانند از ناظر بسیار دور باشند، داریم:

$$I(x) = A, d(x) \rightarrow \infty \quad (6)$$

رابطه ۶ نشان می‌دهد که روشنایی پیکسل در عمق بی‌نهایت می‌تواند مقدار نور اتمسفر A را در رابطه ۴ نشان دهد. توجه داشته‌باشید که اگر عمق صحنه به‌اندازه کافی بزرگ باشد t بسیار کوچک است و I برابر A است. بنابراین، به‌جای محاسبه A می‌توانیم A را با تعریف یک آستانه $d_{\text{threshold}}$ به‌صورت زیر تخمین بزنیم:

$$I(x) = A, d(x) \geq d_{\text{threshold}} \quad (7)$$

لازم به ذکر است که برآورده شدن محدودیت $d(x) > d_{\text{threshold}}$ در بیشتر موارد محتمل است زیرا یک تصویر مه‌آلود که در فضای باز گرفته می‌شود، نمای دوری دارد که کیلومترها از ناظر فاصله دارد. به‌عبارت دیگر، پیکسل متعلق به منطقه با نمای دور دارای عمق بسیار زیادی است. با فرض اینکه هر تصویر مه‌آلود یک نمای دور دارد، داریم:

$$d(x) \geq d_{\text{threshold}}, \quad (8)$$

$$x \in \{x | \forall y: d(y) \leq d(x)\}$$

بر اساس این فرض، نور اتمسفر با رابطه:


$$A = I(x), \quad (9)$$

$$x \in \{x | \forall y: d(y) \leq d(x)\}$$

قابل محاسبه است. در این شرایط، وظیفه الگوریتم حذف مه می‌تواند بیشتر به بازیابی اطلاعات عمق تبدیل شود. اگرچه به‌دست آوردن نقشه عمق از یک تصویر مه‌آلود نیز یک کار چالش‌برانگیز است.

مغز انسان می‌تواند به‌سرعت منطقه مه‌آلود را از مناظر طبیعی بدون هیچ‌گونه اطلاعات اضافی شناسایی کند. برای این کار مغز از روشنایی و اشباع پیکسل‌ها در یک تصویر مه‌آلود همراه با تغییر غلظت مه استفاده می‌کند.

اثر نور هوایی سفید یا خاکستری بر مقادیر مشاهده شده افزایشی است. بنابراین، در اثر نور هوا، روشنایی افزایش می‌یابد در حالی که اشباع کاهش می‌یابد. از آنجایی که نور هوا



شکل ۲: فرآیند تولید نمونه‌های آموزشی [۲۰]

همانطور که در شکل ۳ نشان داده شده است، گازهای سفید در تصویر اول مناطقی هستند که مدل به سختی می‌تواند آنها را مدیریت کند و این مناطق به اشتباه با مقادیر عمق بالا در نقشه عمق تخمین زده شده‌اند. برای حل این مشکل در [۲۰] برای هر پیکسل بر اساس این فرض که عمق صحنه به صورت محلی ثابت است، نقشه عمق خام به صورت زیر پردازش می‌شود:

$$d_r(x) = \min_{y \in \Omega_r(x)} d(y) \quad (13)$$

که $\Omega_r(x)$ یک همسایگی $r \times r$ در نقطه x و d_r نقشه عمق با مقیاس r است.

در [۲۰] از ۵۰۰ نمونه آموزشی حاوی ۱۲۰ میلیون نقطه صحنه برای آموزش مدل خطی استفاده شده است. با توجه به این رابطه عمق صحنه بر اساس روشنای و تخمین زده شده و می‌توانیم نقشه عمق یک تصویر مه‌آلود ورودی داده شده را مطابق روابط فوق بازیابی کنیم. با این حال، این مدل ممکن است در برخی شرایط خاص درست کار نکند. به عنوان مثال، اشیا سفید در یک تصویر معمولاً دارای مقادیر بالایی روشنایی و مقادیر کم اشباع هستند. بنابراین، مدل پیشنهادی تمایل دارد که اجسام صحنه با رنگ سفید را دور در نظر بگیرد. متأسفانه، این طبقه بندی اشتباه در برخی موارد منجر به تخمین نادرست عمق می‌شود.



شکل ۳: اصلاح نقشه عمق. راست) تصویر مه‌آلود. چپ) نقشه عمق خام [۲۰]

باقیمانده از یک الگوی نویزی تبعیت می‌کند و می‌توان آن را نویز در نظر گرفت استفاده شده است. DnCNN یک شبکه عصبی کانولوشنال عمیق برای حذف نویز تصویر است که در آن از یادگیری باقیمانده برای جداسازی نویز از تصویر استفاده می‌شود. در DnCNN نرمال سازی دسته‌ای و یادگیری باقیمانده برای سرعت بخشیدن به روند آموزش و همچنین افزایش عملکرد حذف نویز یکپارچه شده‌اند. بر خلاف مدل‌های بازسازی و رفع نویز مرسوم که مدل‌های خاصی را برای سطوح نویز معین آموزش می‌دهند، مدل DnCNN این ظرفیت را دارد که نویز زدایی کور با سطح نویز ناشناخته را مدیریت کند. علاوه بر این، امکان آموزش مدل DnCNN برای انجام سه وظیفه حذف نویز تصویر کلی، از جمله حذف نویز گاوسی با سطح نویز ناشناخته، بالا

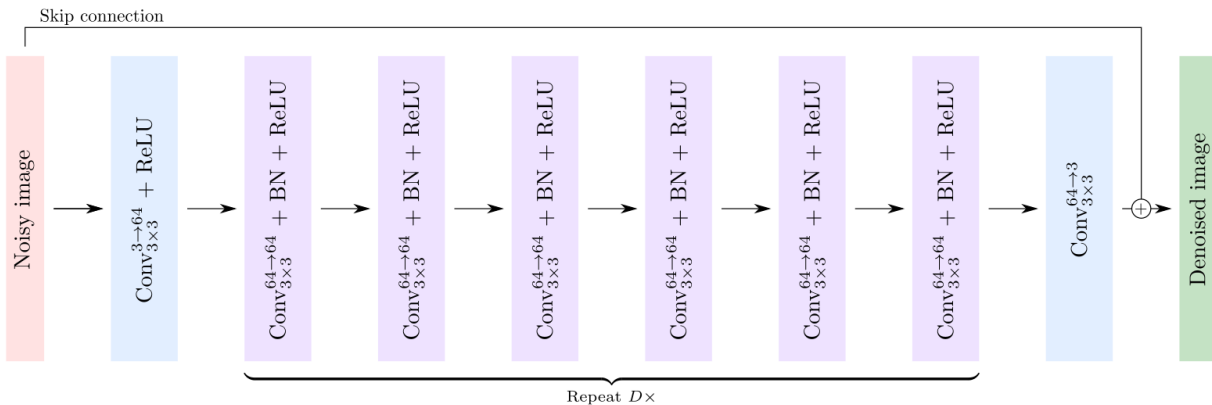
در نهایت برای اصلاح نقشه عمق، از فیلتر تصویر هدایت شده [۲۲]، برای صاف کردن تصویر نهایی استفاده شده است.

با معلوم شدن عمق هر پیکسل و ایجاد تابع t و می‌توان تصویر اصلی را با معلوم بودن پارامترهای مختلف بازیابی نمود. برخی جزئیات مانند محدود نمودن تابع t برای بالا بردن کارایی و کم کردن احتمال خطا نیز در [۲۰] در نظر گرفته شده است.

از آنجا که خروجی هر دو متد توضیح داده شده ایده‌آل نبوده و هر دو هنوز دارای مه محسوب می‌شوند در گام آخر از یک شبکه عمیق رفع نویز کانولوشنی DnCNN برای رسیدن به تصویر با کیفیت بالاتر کمک گرفتیم. شبکه استفاده شده با این توجیه که پس از پردازش تصاویر، مه

مطلوب حذف نویز تصویر را از نظر کمی و کیفی در طیف گسترده‌ای از تصاویر دارد. ساختار DnCNN به صورت زیر است:

بردن وضوح تصویر با چندین فاکتور ارتقا، و رفع انسداد تصویر JPEG با فاکتورهای کیفیت متفاوت وجود دارد. نتایج تجربی گسترده نشان داده که DnCNN عملکرد



شکل ۴: ساختار DnCNN [۲۳]

بررسی عملکرد تمامی روش‌های پیشنهادی در پردازش تصویر می‌باشد. این امر برای استاندارد کردن مقایسه عملکرد روش‌های مختلف نیز اهمیت به سزایی دارد. در زمینه مه زدایی به دلیل کاربرد بودن این موضوع پایگاه داده‌های بسیار متفاوت و عکس‌های بسیار متنوعی در مناظر مختلف و در شرایط مختلف برداشت و آرشیو شده است. که از بین مجموعه‌ی پایگاه داده‌های موجود، در این مطالعه از دو پایگاه داده [۲۴] NH-HAZE و [۲۵] Dense-Haze استفاده شده است.

NH-HAZE یک مجموعه داده واقعی غیر همگن با جفت تصاویر مه‌آلود واقعی و متناظر بدون مه است. این مجموعه داده غیر همگن است که دارای ۵۵ صحنه در فضای باز است. در این مجموعه مه غیر همگن با استفاده از یک مه ساز حرفه‌ای که شرایط واقعی صحنه‌های مه‌آلود را تقلید می‌کند ایجاد شده است. Dense-Haze که شامل صحنه‌های مه‌آلود متراکم و همگن است، دارای ۳۳ جفت تصویر مه‌آلود واقعی و ایده‌آل بدون مه همان تصویر از صحنه‌های مختلف در فضای باز است. صحنه‌های مه‌آلود با مه واقعی، تولید شده توسط ماشین‌های مه حرفه‌ای ثبت شده است. از جمله پایگاه داده‌های دیگر مه زدایی می‌توان به پایگاه داده دانشگاه واترلو اشاره نمود. پایگاه داده دانشگاه واترلو [۲۶] شامل ۲۵ تصویر دارای مه است که از این میان ۲۲ تصویر آن در فضای بیرون به صورت واقعی و ۳ تصویر آن با استفاده از نرم‌افزار تهیه شده‌اند. تصاویر ایده‌آل این پایگاه داده همه به صورت بدون مه به صورت مشابه از همان صحنه، بدون تغییر شرایط برداشت شده‌اند. در مجموع در این پایگاه داده

این شبکه در حالت عمومی ۵۹ لایه دارد که تکرار ساختار فوق محسوب می‌شود. در رویکرد پیشنهادی ابتدا تصاویر خروجی از دو رویکرد اول با وزن مساوی با یکدیگر ترکیب شده و تصویر حاصل به عنوان ورودی شبکه DnCNN در نظر گرفته شده است. خروجی DnCNN تصویر بدون مه خواهد بود. به دلیل آنکه ابعاد ورودی DnCNN بسیار کوچک‌تر از تصاویر مرسوم است، از پیچ‌های بریده شده از قسمت‌های مختلف تصاویر موجود به عنوان ورودی و خروجی شبکه در آموزش استفاده شده است. شبکه اولیه با وزنه‌های پیش فرض DnCNN آموزش داده شده بوده و از این نظر یک انتقال یادگیری نیز محسوب می‌شود. انتقال یادگیری به معنای آماده‌سازی (مقداردهی اولیه) شبکه با پارامترهای از قبل آموزش داده شده به جای پارامترهای تصادفی است. این روش در مدل‌های مبتنی بر CNN بسیار محبوب است چرا که فرآیند یادگیری را تسریع کرده و همین طور قابلیت تعمیم را بهبود می‌بخشد. شبیه سازی‌های گسترده‌ای بر روی الگوریتم‌های فعلی انجام شده تا دلیل اینکه چرا شبکه‌های از قبل آموزش داده شده از شبکه‌هایی که به صورت سنتی آموزش داده می‌شوند، بهتر کار می‌کنند را نشان دهد.

۴- ارزیابی و نتایج پیاده سازی

در این بخش روش پیشنهادی در مقام مقایسه بر روی مجموعه‌ای از دو پایگاه داده کاملاً استاندارد با مفروضات کاملاً مشابه پیاده سازی شده، و بهبود کارایی آن در شرایط کاملاً یکسان در همه موارد تایید شده است. استفاده از یک پایگاه داده استاندارد یکی از مهم‌ترین مراحل آزمایش

در گام اول نتایج پاسخ مراحل مختلف روش یکسان سازی هیستوگرام تطبیقی و تصحیح گاما بر تصویر مه دار را مقایسه کرده ایم. تصاویر انتخاب شده از هر دو پایگاه داده هستند که غلظت مه متفاوتی دارند.

به ازای هر تصویر دارای مه ۸ تصویر مه زدایی شده با روش های مختلف قرار داده شده که درجات مه زدایی آنها متفاوت است.



شکل ۵: تصویر نمونه بررسی شده. حالت ایده آل و حالت مه دار (معمولی و مه غلیظ)



شکل ۶: تصویر نهایی قبل از اصلاح گاما و نتیجه نهایی


پایین آمده است. این موضوع می تواند به دلیل عدم تطبیقی بودن ضرایب انتخاب شده در محاسبات باشد. با این حال محاسبات نسبتاً سبک این روش و کارایی آن در حذف مه در نتیجه نهایی تا حد زیادی خود را نشان داده است.

از نتایج به دست آمده از بخش اول روش پیشنهادی می توان دید، اگرچه روش ارائه شده در حذف مه کارایی دارد، اما تصویر نهایی معمولاً از تصویر اولیه تیره تر بوده و علاوه بر آن در حالتی که مه بسیار غلیظ است، کارایی روش به شدت

۴-۱ نتایج روش مبتنی بر کانال رنگ

در گام دوم نتایج پاسخ مراحل مختلف روش مبتنی بر کانال رنگ بر تصویر مه دار را مقایسه کرده ایم. مشابه قسمت قبل

در این بخش دو تصویر از پایگاه داده اول و یک تصویر از پایگاه داده دوم انتخاب شده است.



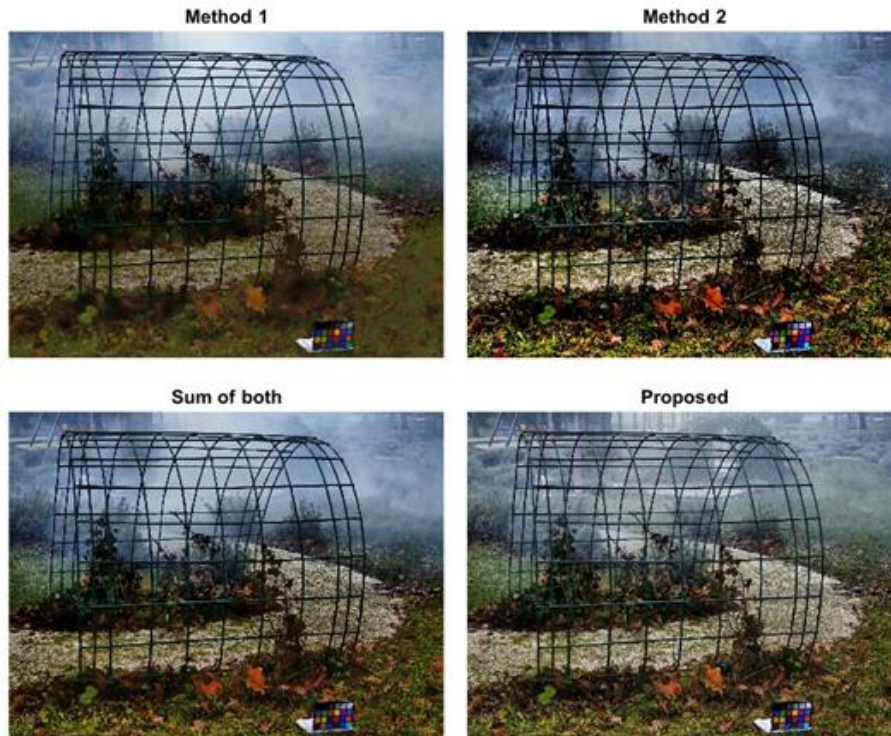
شکل ۷: به ترتیب از بالا به پایین: نقشه عمق کانالهای رنگ تصویر نویزی، تابع انتقال، تصویر مه دار و تصویر نهایی سمت

روش در حذف مه کارایی ضمنی از خود نشان داده است کارایی نهایی آن مناسب نیست.

۴-۲ نتایج ترکیب دو روش و یادگیری عمیق

در این مرحله خروجی دو روش قبل با یکدیگر جمع شده و نتیجه به عنوان ورودی شبکه حذف نویز پس از آموزش داده شدن شبکه اعمال و خروجی آن رسم شده است.

از نتایج بصری می توان فهمید که در مواردی که مه بسیار غلیظ بوده است عملاً نقشه انتقال کارایی خود را نداشته و روش به خوبی نمی تواند مه غلیظ را حذف کند. در قسمت های دارای مه معمولی نیز الگوریتم تصویر را پررنگ کرده و تصویر خروجی نهایی نسبت به تصویر اولیه دارای کیفیت مناسبی محسوب نمی شود و در مجموع با آنکه



شکل ۸: نتیجه مه زدایی با روش اول، روش دوم، جمع نتیجه دو روش و نتیجه روش پیشنهادی جدول ۲: نتیجه حاصل از تغییر تعداد لایه DnCNN با سه معیار مختلف

تعداد بلاکهای سه تایی	تعداد کل لایهها	NH-HAZE			Dense-Haze		
		MSE	PSNR	SSIM	MSE	PSNR	SSIM
2	11	1.64	8.69	0.39	4.65	8.17	0.36
3	14	1.54	9.12	0.39	4.47	8.72	0.36
4	17	1.59	9.82	0.42	4.39	8.75	0.38
5	20	1.56	10.25	0.45	4.38	8.84	0.41
6	23	1.54	11.03	0.49	4.28	10.13	0.44
7	26	1.47	10.55	0.47	4.18	10.56	0.43
8	29	1.45	11.42	0.54	4.17	10.94	0.48
9	32	1.46	11.64	0.53	4.14	11.89	0.51
10	35	1.36	13.28	0.60	3.93	11.73	0.51
11	38	1.28	12.89	0.62	3.83	12.70	0.52
12	41	1.34	13.73	0.67	3.61	12.55	0.57
13	44	1.27	14.78	0.66	3.47	14.04	0.59
14	47	1.20	15.76	0.73	3.44	14.42	0.65
15	50	1.23	16.89	0.78	3.33	15.91	0.63
16	53	1.10	16.85	0.76	3.30	16.34	0.69
17	56	1.09	18.72	0.84	3.25	17.58	0.72
18	59	0.98	20.14	0.91	2.83	18.78	0.81
19	62	0.99	20.68	0.90	2.84	19.48	0.84
20	65	1.02	20.48	0.92	2.91	18.50	0.83
21	68	1.03	20.57	0.87	2.76	19.13	0.78
22	71	0.99	20.43	0.95	2.76	18.39	0.81
23	74	1.01	19.98	0.94	2.76	18.84	0.80
24	77	0.96	19.92	0.93	2.76	19.40	0.82

همانطور که از نتایج جدول ۲ می توان دید تعداد تعداد بلاک های سه تایی ۱۸ و ۱۹ جواب های بسیار مناسب و در عین حال نزدیکی از خود نشان داده اند که بیانگر بهینه بودن نسبی ساختار DnCNN است. برای مقایسه دقیق تر این دو حالت با یکدیگر هر یک از این دو حالت ده بار مختلف اجرا و نتیجه در جدول ۳ آورده شده است.

بر اساس نتایج به دست آمده می توان دید در تمامی موارد روش پیشنهادی نتیجه نسبتاً بهتری از دو روش قبل داشته و کارایی خروجی آن بهتر شده است. با هدف بررسی پارامترهای دخیل در نتیجه روش پیشنهادی و بهینه سازی آن ها، و با توجه به آنکه روش های [۱۹، ۲۰] مبتنی بر الگوهای ریاضی و مشخص بودند، از تحلیل لایه های DnCNN استفاده شد. جدول ۲ نتیجه حاصل از این کار را با سه معیار مختلف در دو پایگاه داده مقایسه کرده است.

جدول ۳: نتیجه ده بار اجرای مختلف

تعداد بلاک های سه تایی	تعداد کل لایه ها	NH-HAZE			میانگین			Dense-Haze			میانگین		
		MS E	PSN R	SSI M	MS E	PSN R	SSI M	MS E	PSN R	SSI M	MS E	PSN R	SSI M
18	59	0.97	20.46	0.92	0.98	20.13	0.91	2.87	18.70	0.84	2.85	18.78	0.81
18	59	0.98	20.02	0.89				2.88	18.51	0.82			
18	59	0.96	20.26	0.89				2.79	18.43	0.78			
18	59	0.96	20.22	0.93				2.79	18.60	0.80			
18	59	0.97	20.17	0.91				2.77	18.99	0.78			
18	59	1.00	19.91	0.90				2.89	19.05	0.81			
18	59	0.99	19.89	0.92				2.88	18.96	0.81			
18	59	1.00	20.09	0.93				2.89	18.32	0.85			
18	59	1.00	19.87	0.92				2.83	19.10	0.84			
18	59	1.00	20.45	0.91				2.88	19.18	0.81			
19	62	1.02	19.62	0.87	1.02	19.17	0.87	2.91	18.11	0.80	2.99	17.85	0.78
19	62	1.01	18.71	0.87				3.03	17.46	0.74			
19	62	1.04	19.19	0.83				3.04	17.76	0.76			
19	62	1.03	18.76	0.88				2.96	18.05	0.81			
19	62	1.00	19.45	0.91				2.93	18.07	0.80			
19	62	1.00	19.63	0.85				3.00	17.62	0.79			
19	62	1.02	18.74	0.91				3.02	17.66	0.78			
19	62	1.00	19.58	0.85				2.99	18.02	0.76			
19	62	1.01	18.70	0.90				3.01	17.84	0.81			
19	62	1.04	19.33	0.86				2.97	17.97	0.74			

است. جدول ۴ نتیجه این مقایسه را نشان داده است. همانطور که از جدول می توان دید روش پیشنهادی در هر سه مورد کارایی مناسبی از خود نشان داده است. لازم به ذکر است معیار MSE باید کاهش و دو معیار SSIM و PSNR باید افزایش یابد که در هر دو پایگاه داده این اتفاق رخ داده است.

بر اساس نتایج جدول ۳ می توان دید تعداد تعداد بلاک سه تایی ۱۸ مناسب تر است. برای اثبات کارایی به صورت کمی، نتیجه روش های متفاوت و مجموع ساده و روش پیشنهادی با یکدیگر مقایسه شده است. سه معیار استفاده شده مشابه جداول قبل بوده بوده و با توجه به در دسترس بودن کدها تمامی روش ها بر روی پایگاه داده های منتخب پیاده سازی شده اند. برای محاسبه معیارهای کیفیت از دستورات نرم افزار متلب استفاده شده

جدول ۴: مقایسه عددی روش پیشنهادی با روش های مه زدایی مختلف

متد	NH-HAZE			Dense-Haze		
	MSE	PSNR	SSIM	MSE	PSNR	SSIM
[27]	1.07	19.81	0.92	2.99	18.38	0.82
[28]	1.10	19.90	0.93	2.98	18.03	0.78
[16]	1.08	19.14	0.93	3.05	18.61	0.80
[29]	1.12	19.90	0.90	2.99	17.78	0.82
[17]	1.10	19.63	0.92	3.00	18.14	0.83
[30]	1.08	19.11	0.88	3.07	18.09	0.84
[31]	1.08	19.28	0.92	3.08	18.44	0.80
[32]	1.07	19.55	0.86	3.02	18.47	0.77
[33]	1.09	19.95	0.88	2.95	17.92	0.77
[19]	1.13	19.95	0.86	3.05	18.19	0.78
[20]	1.08	19.17	0.87	3.01	18.15	0.83
[21]	1.08	19.96	0.93	3.06	18.33	0.78
میانگین ساده	1.44	17.11	0.84	7.41	14.52	0.73
روش پیشنهادی	0.98	20.14	0.91	2.83	18.78	0.81

صورت می گیرد. یکسان سازی هیستوگرام تطبیقی منجر به افزایش کنتراست کانال I می گردد. در این رویکرد هیستوگرام ناحیه تقریباً با هیستوگرام مشخص شده توسط توزیع هدف، مانند یکنواخت، را پلی یا نمایی یکسان خواهد بود. در نهایت، تمامی نواحی همسایه با استفاده از درون یابی دو خطی ترکیب می شوند تا ناپیوستگی احتمالی بین آنها حذف شود. در پردازش کانال S، از آنجایی که همسان سازی هیستوگرام تطبیقی اشباع تصویر را کاهش می دهد، باید فضای اشباع را بهبود دهیم لذا در فضای HSV باید کانال S را تغییر دهیم. در گام دوم از روش مبتنی بر کانال رنگ استفاده شد. در این مرحله با الگو گرفتن از مغز انسان که می تواند به سرعت منطقه مه آلود را از مناظر طبیعی بدون هیچ گونه اطلاعات اضافی شناسایی کند از روشنایی و اشباع پیکسل ها در یک تصویر مه آلود همراه با تغییر غلظت مه استفاده برای حذف مه استفاده شد.

با توجه عددی و مثال های مختلف نشان داده شد، سه ویژگی (روشنایی، اشباع و تفاوت این دو) در اکثر موارد مستعد تغییر منظم در یک تصویر مه آلود هستند. در نهایت عمق صحنه بر اساس روشنایی تصویر آلوده به مه تخمین زده شده و می توانیم بر اساس آن خود تصویر ایده ال را بازیابی کنیم. متأسفانه، این مدل تمایل دارد که اجسام صحنه با رنگ سفید را دور در نظر بگیرد و این مناطق به اشتباه با مقادیر عمق بالا در نقشه عمق تخمین زده می

در این بخش نتایج روش پیشنهادی که در بخش ۳ بیان شده بود در تمامی بلوک دیگرام ها و مراحل الگوریتم های پیشنهادی به تفکیک آورده شد و بر روی نتایج بحث لازم صورت گرفت. رویکرد پیشنهادی با افزایش کیفیت ترکیب خروجی دو روش ذکر شده خصوصاً در مواردی که غلظت مه بالا بوده است توانسته کیفیت خروجی را بهبود بخشد. اگرچه لازم به ذکر است خصوصاً در حالت مه با غلظت بالا حتی پس از اعمال روش پیشنهادی مه بر روی تصویر وجود داشته و کیفیت قابل قبول نیست، اما روش پیشنهادی توانسته کیفیت خروجی روش های دیگر را به صورت قابل ملاحظه ای خصوصاً در نواحی دارای غلظت مه بالا افزایش دهد.

۵- نتیجه گیری

با توجه به کاربرد بسیار گسترده ی حذف مه در سیستم های مدرن مبتنی بر پردازش تصویر خصوصاً سیستم های ناوبری و هدایت خودکار ماشین ها در این پایان نامه یک الگوریتم حذف مه با کیفیت بالا پیشنهاد شده است. الگوریتم پیشنهاد شده با هدف بالا بردن کیفیت خروجی از ترکیب روش های قبلی و اضافه کردن یک طبقه یادگیر عمیق کمک گرفته است. در روش پیشنهادی در این پایان نامه ابتدا مه زدایی بر اساس یکسان سازی هیستوگرام تطبیقی و تصحیح گاما صورت می گیرد. پروسه یکسان سازی هیستوگرام در فضای رنگ HSV و فقط بر روی کانال I

است. در نهایت روش پیشنهادی و روش های پایه بر روی تصاویر دو پایگاه داده کاملاً استاندارد پیاده سازی و حفظ کیفیت در روش پیشنهادی به صورت کامل نشان داده شد. از نظر حافظه‌ی اشغالی نیز روش پیشنهادی نسبتاً بهینه بوده و می‌توان این‌طور گفت که حافظه‌ی اشغالی آن قابل قبول است. از دیگر امتیازات روش پیشنهادی آن است که حتی در تصاویر با ابعاد بسیار اندک نیز می‌توان از آن به صورت مناسب استفاده نمود.

شوند. برای حل این مشکل برای هر پیکسل بر اساس این فرض که عمق صحنه به صورت محلی ثابت است، نقشه عمق خام اصلاح شد. بر اساس نتایج شبیه سازی مشخص شد خروجی هر دو متد ایده‌آل نبوده و هر دو هنوز دارای مه محسوب می‌شوند. در گام آخر از شبکه عمیق رفع نویز DnCNN برای رسیدن به تصویر با کیفیت بالاتر کمک گرفته شد. شبکه استفاده شده با این توجیه که پس از پردازش تصاویر، مه باقیمانده از یک الگوی نویزی تبعیت می‌کند و می‌توان آن را نویز در نظر گرفت استفاده شده

۶- منابع

- [1] Liu, J., et al., *DFP-Net: An unsupervised dual-branch frequency-domain processing framework for single image dehazing*. Engineering Applications of Artificial Intelligence, 2024. **136**: p. 109012.
- [2] Fu, H., et al., *HyperDehazing: A hyperspectral image dehazing benchmark dataset and a deep learning model for haze removal*. ISPRS Journal of Photogrammetry and Remote Sensing, 2024. **218**: p. 663-677.
- [3] Asha, C., et al., *ODD-Net: a hybrid deep learning architecture for image dehazing*. Scientific Reports, 2024 : (۱) ۴ .p. 30619.
- [4] Balla, P.K., A. Kumar, and R. Pandey, *A 4-channelled hazy image input generation and deep learning-based single image dehazing*. Journal of Visual Communication and Image Representation, 2024. **100**: p. 104099.
- [5] Ren, W., et al. *Single image dehazing via multi-scale convolutional neural networks*. in *Computer Vision—ECCV 2016: 14th European Conference, Amsterdam, The Netherlands, October 11-14, 2016, Proceedings, Part II* 14. 2016. Springer.
- [6] Zhang, H. and V.M. Patel. *Densely connected pyramid dehazing network*. in *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2018.
- [7] Ren, W., et al. *Gated fusion network for single image dehazing*. in *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2018.
- [8] Li, Y., et al. *LAP-Net: Level-aware progressive network for image dehazing*. in *Proceedings of the IEEE/CVF international conference on computer vision*. 2019.
- [9] Dong, J. and J. Pan. *Physics-based feature dehazing networks*. in *Computer Vision—ECCV 2020: 16th European Conference, Glasgow, UK, August 23–28, 2020, Proceedings, Part XXX* 16. 2020. Springer.
- [10] Deng, Z., et al. *Deep multi-model fusion for single-image dehazing*. in *Proceedings of the IEEE/CVF international conference on computer vision*. 2019.
- [11] Khosla, P., et al., *Supervised contrastive learning*. Advances in neural information processing systems, 2020. **33**: p. 18661-18673.
- [12] Kim, G., S.W. Park, and J. Kwon, *Pixel-wise Wasserstein autoencoder for highly generative dehazing*. IEEE Transactions on Image Processing, 2021. **30**: p. 5452-5462.
- [13] Li, P., et al., *Deep retinex network for single image dehazing*. IEEE Transactions on Image Processing, 2020. **30**: p. 1100-1115.
- [14] Chen, D., et al. *Gated context aggregation network for image dehazing and deraining*. in *2019 IEEE winter conference on applications of computer vision (WACV)*. 2019. IEEE.
- [15] Wang, J., C. Li, and S. Xu, *An ensemble multi-scale residual attention network (EMRA-net) for image Dehazing*. Multimedia Tools and Applications, 2021. **80**(19): p. 29299-29319.
- [16] Hambarde, P. and S. Murala, *S2DNet: Depth estimation from single image and sparse samples*. IEEE Transactions on Computational Imaging, 2020. **6**: p. 806-817.

- [17] Cheng, L. and L. Zhao. *Two-stage image dehazing with depth information and cross-scale non-local attention*. in *2021 IEEE International Conference on Big Data (Big Data)*. 2021. IEEE.
- [18] Li, B., et al. *Aod-net: All-in-one dehazing network*. in *Proceedings of the IEEE international conference on computer vision*. ۲۰۱۷ .
- [19] Thanh, D.N., N.M. Hue, and V.S. Prasath. *Single image dehazing based on adaptive histogram equalization and linearization of gamma correction*. in *2019 25th Asia-Pacific Conference on Communications (APCC)*. 2019. IEEE.
- [20] Zhu, Q., J. Mai, and L. Shao, *A fast single image haze removal algorithm using color attenuation prior*. *IEEE transactions on image processing*, 2015. **24**(11): p. 3522-3533.
- [21] Tang, K., J. Yang, and J. Wang. *Investigating haze-relevant features in a learning framework for image dehazing*. in *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2014.
- [22] He, K., J. Sun, and X. Tang, *Guided image filtering*. *IEEE transactions on pattern analysis and machine intelligence*, 2012. **35**(6): p. 1397-1409.
- [23] Zhang, K., et al., *Beyond a gaussian denoiser: Residual learning of deep cnn for image denoising*. *IEEE transactions on image processing*, 2017. **26**(7): p. 3142-3155.
- [24] Ancuti, C.O., C. Ancuti, and R. Timofte. *NH-HAZE: An image dehazing benchmark with non-homogeneous hazy and haze-free images*. in *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition workshops*. 2020.
- [25] Ancuti, C.O., et al. *Dense-haze: A benchmark for image dehazing with dense-haze and haze-free images*. in *2019 IEEE international conference on image processing (ICIP)*. 2019. IEEE.
- [26] Ma, K., W. Liu, and Z. Wang. *Perceptual evaluation of single image dehazing algorithms*. in *2015 IEEE International Conference on Image Processing (ICIP)*. 2015. IEEE.
- [27] Yang, H.-H., C.-H.H. Yang, and Y.-C.J. Tsai. *Y-net: Multi-scale feature aggregation network with wavelet structure similarity loss function for single image dehazing*. in *ICASSP 2020-2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)* . ۲۰۲۰ . IEEE.
- [28] Liu, J., et al. *Trident dehazing network*. in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops*. 2020.
- [29] Lee, B.-U., et al. *CNN-based simultaneous dehazing and depth estimation*. in *2020 IEEE international conference on robotics and automation (ICRA)*. 2020. IEEE.
- [30] Sakaridis, C., et al. *Model adaptation with synthetic and real data for semantic dense foggy scene understanding*. in *Proceedings of the european conference on computer vision (ECCV)*. 2۰۱۸
- [31] Zhang, X., et al., *Hierarchical feature fusion with mixed convolution attention for single image dehazing*. *IEEE Transactions on Circuits and Systems for Video Technology*, 2021. **32**(2): p. 510-522.
- [32] Das, S.D. and S. Dutta. *Fast deep multi-patch hierarchical network for nonhomogeneous image dehazing*. in *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition workshops*. 2020.
- [33] Zheng, Z., et al. *Ultra-high-definition image dehazing via multi-guided bilateral learning*. in *2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. 2021. IEEE.

Digital image defogging using feature fusion and deep learning Somaye RastgariFar¹, Yasser Elmi Sola^{1,*}

1. Department of Computer Engineering, Sab.C., Islamic Azad University, Sabzevar, Iran

*Corresponding Author: Yasser.Elmi@iau.ac.ir

Abstract

Fog usually causes severe interference in the image. Such image degradation presents a challenge to both human observers and computer vision systems. Image dehazing is the process of improving the quality of images that are affected by air scattering or water droplets. In this paper, a novel method for high-quality dehazing is proposed. The proposed algorithm for removing fog from images is based on a combination of two efficient mathematically based methods and the addition of a deep learning layer. The proposed method performs dehazing in the first phase based on adaptive histogram equalization and gamma correction. It operates in the HSV and RGB color spaces. In the second phase, a color channel-based method is used to dehazing by modeling it on the human brain, processing the brightness and saturation of pixels in a foggy image and examining the changes in concentration. In the third phase, a deep denoising network DnCNN is used to achieve a higher quality image. The DnCNN network was used with the justification that after image processing, the remaining fog follows a noisy pattern and can be considered as noise. The results of implementing and evaluating the proposed method on standard image databases showed that the proposed method, in addition to improving the quality of the results compared to previous methods, also performs better in terms of occupied memory. Another advantage of the proposed method is that it can be used for dehazing small-sized images.

Keywords: Image Dehazing, Deep learning, Histogram Equalization, Convolutional Neural Network
