

کاهش نویز تصاویر دیجیتال با استفاده از اثر توجه و کاهش عمق شبکه های عصبی

عمیق

مرتضی یوسفی^۱، وحید مهرداد^۲

چکیده

یکی از مهمترین موضوعات در پردازش تصویر حذف نویز می باشد تا بتوان کیفیت تصویر را بهبود بخشید. از آنجائیکه شبکه های عصبی عمیق به تنهایی با افزایش عمق شبکه با مشکلاتی مانند محو گرادیان مواجه می شوند و نمی توانستند جزئیات را به خوبی برای یک وظیفه خاص پوشش دهند در این مقاله، با کاهش عمق شبکه و افزایش پهنای آن، امکان استخراج ویژگی های متنوع از کانال های مختلف فراهم می شود، که این امر منجر به افزایش دقت شبکه می گردد. با افزایش پهنای شبکه به دو انشعاب، اطلاعات متفاوتی از تصویر نویزی استخراج می شود که این عمل برای تفکیک داده های نویزی از تصویر بسیار موثر است. اثر توجه به ویژگی ها در هر کانال و وزن دهی آنها در عملیات حذف نویز نیز در نظر گرفته می شود. در نهایت برای بررسی کارآمدی روش پیشنهادی، نتایج با آخرین دستاوردهای این حوزه مقایسه می شوند. نتایج شبیه سازی با بررسی دو معیار PSNR و SSIM و هم از نگاه بصری نشان می دهد این روش در مقابله با انواع نویز ترکیبی و کور جهت انجام کارهای پردازشی در حد قابل قبولی می باشد و از طرفی استفاده از اثر توجه و شبکه های موازی می تواند در مواجهه با نویز حقیقی بسیار موثر باشد و توانسته است به میانگین PSNR=36.34db دست یابد.

کلید واژه ها

حذف نویز، شبکه های عصبی عمیق، شبکه های کانولوشنی موازی، مکانیزم توجه، استخراج ویژگی

۱- مقدمه:

باشند که در کنار آنها، روش های مبتنی بر رویکردهای مدل کردن نویز مستقل از یادگیری نیز وجود دارند. این روش ها اشکالاتی از قبیل بار محاسباتی و نیاز به تنظیم دقیق پارامترها را به همراه دارند.

اگرچه روش های قبل می توانند به عملکرد نویز زدایی قابل قبولی دست یابند، اما با چالش های تنظیم دستی پارامترها و الگوریتم های بهینه پیچیده ای روبرو هستند. برای پرداختن به این مسائل، روش های یادگیری متمایز مختلفی برای آموزش مدل های قبلی تصویر پیشنهاد شد. اخیرا با توجه به کارایی شبکه های عصبی عمیق و دستاوردهایی که در حوزه های مختلف از جمله متن، صوت و تصویر حاصل نموده اند، محققین حوزه حذف نویز نیز با طراحی شبکه های عصبی، به نویز زدایی از تصاویر پرداخته اند.

نویز زدایی از تصویر یکی از مسائل مهم و سطح پایین در زمینه بینایی ماشین می باشد [۱۱، ۱۲]. نویز به محتوای فرکانس بالا یعنی همان جزئیات مربوط می شود، لذا باید بین کاهش نویز تا حد امکان و از دست ندادن جزئیات زیاد، بتوان یک سازشی پیدا کرد [۱۶]. رایجترین روش های حذف نویز، مبتنی بر فیلترینگ می-

این مقاله در آبان ماه ۱۴۰۱ دریافت، در دی ماه بازنگری و در بهمن ماه همان سال پذیرفته شد.

^۱ دانشجوی دکتری گروه مهندسی برق دانشگاه لرستان

رایانامه: yousefi.mo@fe.lu.ac.ir

^۲ استادیار گروه مهندسی برق دانشگاه لرستان

رایانامه: mehrdad.v@lu.ac.ir

ارائه کردند. چن و همکاران [۱۷] روش انتشار واکنش غیرخطی قابل آموزش (TNRD^۳) را برای آموزش یک مدل حذف نویز بر اساس تصویر قبلی حوزه متخصصان با استنتاج گرادینان کاهش می‌کنند. اگرچه این روش‌ها برای حذف نویز تصویر به خوبی عمل می‌کنند، اما کاربرد این روش‌ها متناسب با نیاز تکنولوژی‌های جدید نمی‌باشد. همچنین آنها برای به دست آوردن پارامترهای بهینه به چندین پارامتر تنظیم شده نیاز دارند [۶]. علاوه بر این، روش‌های فوق فقط برای یک سطح نویز خاص مفید بوده و برای حذف نویز کور ناکارآمد می‌باشند.

برخی از جزئیات ریز به سختی از نویز قابل تشخیص می‌باشند و براحتی در فرآیند حذف نویز بیش از حد صاف می‌شوند. بنابراین، برای حل این مشکل، مدل‌های خود-شباهت غیرمحلی (NSS^۴) [۴, ۲۵] پیشنهاد شدند. این روش‌ها نمی‌توانند نویزها را به طور کامل حذف کنند و بالا بودن زمان محاسبات را نیز به همراه دارند. اخیراً، روش‌های مبتنی بر شبکه عصبی کانولوشنال عمیق [۱۴, ۲۶] (CNN^۵) پیشنهاد شده‌اند. این روش‌ها نیز می‌توانند نتایج بیش از حد صافی را با از بین بردن برخی جزئیات، به ویژه برای تصاویر بافت، ایجاد کنند. حذف نویز از تصاویر بافت نویز برای اکثر روش‌ها چالش برانگیز خواهد بود. همچنین، ویژگی‌های عمیق حاوی اطلاعات متفاوتی هستند. برخی از ویژگی‌ها دارای نویز بیشتری می‌باشند، اما برخی ویژگی‌ها حاوی اطلاعات بافتی و ساختاری بیشتری می‌باشند. نقشه ویژگی با وزن کانال کم حاوی اطلاعات بیشتر شبیه نویز است. در مقابل، نقشه ویژگی با وزن کانال بالا حاوی اطلاعات ساختاری بیشتری است. این مقایسه نشان می‌دهد که اینها تفاوت آشکار بین کانال‌ها یا نقشه‌های ویژگی هستند. بنابراین، باید به ویژگی‌های با اطلاعات بافتی و ساختاری بیشتر توجه نمود.

در توسعه‌های اخیر در زمینه بینایی سطح بالا، ویژگی‌های کانال اصلی [۲۷] و عناصر اولیه بصری [۲۸] مورد بررسی قرار گرفته است. آثار آنها نشان می‌دهد که می‌توان از توجه سراسری، برای جبران اطلاعات از دست رفته در طول مقیاس بندی ویژگی‌ها استفاده کرد.

از معماری LeNet [۲۹] تا معماری‌های به سبک باقیمانده [۳۰-۳۳]، شبکه‌ها برای بیان غنی‌تر، عمیق‌تر شده‌اند. VGGNet [۳۴] نشان می‌دهد که بلوک‌های پشت سرهم با شکل یکسان نتایج منصفانه‌ای را می‌دهند. GoogleNet [۳۵] نشان می‌دهد که پهنا فاکتور مهم دیگری است که عملکرد مدل را بهبود می‌دهد. Komodakis و Zagoruyko [۳۳] افزایش پهناي شبکه بر اساس معماری ResNet را پیشنهاد دادند. آنها نشان دادند که یک ResNet ۲۸ لایه با افزایش پهنا می‌تواند نسبت به یک

شبکه های دوگانه یک سیگنال را به ساختارها و جزئیات آن تقسیم می‌کنند [۱۹]. این شبکه‌ها از دو شاخه موازی تشکیل شده‌اند که در یک رفتار انتها به انتها، ساختار و جزئیات سیگنال ورودی را بازیابی می‌کنند. آنها یک چارچوب انعطاف‌پذیر دارند و می‌توانند براحتی به شبکه‌های کانولوشنی موجود اضافه شوند. لذا یک مدل دوگانه می‌تواند بطور موثری به تعداد زیادی از مسائل بینایی سطح پایین اعمال شود.

ماژول توجه بلوک کانولوشنی، یک مکانیزم توجه موثر و ساده برای شبکه‌های عصبی کانولوشنی پیشخور می‌باشد [۱]. با توجه به نقشه ویژگی میانی، این ماژول به صورت پی در پی نگاشت‌هایی از توجه را در طول دو بعد، شامل کانال و مکان به طور جداگانه استنتاج می‌کند، سپس این نگاشت‌ها از توجه، در نقشه ویژگی ورودی برای پالایش ویژگی‌های تطبیقی ضرب می‌شوند تا بر ویژگی‌های معنادار تاکید کنند.

برای افزایش بازیابی جزئیات در کارهای سطح پایین بینایی ماشین، شبکه‌های عصبی کانولوشنی دوگانه می‌توانند ویژگی‌های مکملی را استخراج کنند، با این انگیزه در این پژوهش از شبکه دوگانه برای حذف نویز در تصویر استفاده می‌شود. یک جنبه متفاوت از طراحی معماری، بررسی اثر توجه می‌باشد که موضوع پژوهش حاضر نیز خواهد بود با استفاده از مکانیزم توجه می‌توان قدرت بیان شبکه را با تمرکز روی ویژگی‌های مهم و حذف ویژگی‌های غیر ضروری افزایش داد. با استفاده از توجه سراسری می‌توان به جبران اطلاعات از دست رفته در طول مقیاس بندی ویژگی‌ها پرداخت.

در ادامه مقاله، در بخش دوم مروری بر کارهای پیشینان داشته و در بخش سوم به تشریح روش پیشنهادی پرداخته شده است، در بخش چهارم آزمایشات و شبیه سازی‌ها و در بخش پنجم نتیجه گیری ارائه می‌شود.

۲- مرور کارهای پیشینان:

روش تطبیق بلوک و فیلتر سه بعدی (BM3D) [۴]، داده‌های سه بعدی و پراکنده را قبل از مقابله با مشکلات حذف نویز تصویر ترکیب می‌کند. استفاده همزمان از تکنیک‌های پردازش سیگنال و سایر تکنیک‌های قبلی، برای برنامه‌های کاربردی پردازش تصویر مفید است [۲۲]. برای بهبود کارایی نویززدایی، تکنیک‌های یادگیری فرهنگ لغت برای حذف نویز توسعه داده شد [۲۳].

اشمیت و همکاران [۹] مدل آبشاری میدان‌های انقباض (CSF^۲) را برای بازیابی تصاویر با استفاده از بهینه‌سازی نیمه درجه دوم

³ Trainable Nonlinear Reaction Diffusion

⁴ Non-local Self Similarity

⁵ Convolutional Neural Network

¹ Block Matching and 3-D filtering

² Cascade of Shrinking Fields

اعمال مکانیزم توجه در شبکه های عصبی عمیق [۲۷, ۳۹, ۴۰] برای کاربردهای مختلف، مانند محلی سازی و درک در تصاویر [۴۱, ۴۲]، شبکه های مبتنی بر توالی [۴۳, ۴۴] پیشنهاد کرده اند.

ژانگ و همکاران [۷] یک شبکه نويززداي سريع و انعطاف پذير به نام FFDNet را بر اساس نگاشت های سطح نويز و تصاویر نويزدار برای حذف نويز کور ارائه کردند. ساختارهای اصلی نمی-توانند به خوبی برای کارهای مختلف یا پیچیده، مانند نويز کور و تصویر نويز واقعي، بازیابی انجام دهند.

جدای از این فاکتورها، در مورد اهمیت توجه در شبکه های قبلی نیز مطالعات زیادی صورت گرفته است [۳۹, ۴۲, ۴۵-۴۸]. با استفاده از ماژولی به نام CBAM^۸ که ساختار آن در شکل (۱) مشاهده می شود می توان ماژولی را برای تاکید بر ویژگی های معنادار در امتداد دو بعد اصلی کانال و مکان اتخاذ نمود.

در کارهای ذکر شده در بالا شبکه های یگانه بکار رفته است که از ضعف های شبکه های یگانه، می توان به عدم تنوع ویژگی ها اشاره کرد، همچنین عدم وزن دهی به کانال ها و ویژگی های مربوطه باعث می شد، همه کانال ها و ویژگی ها با اهمیت یکسانی در نظر گرفته شوند، لذا در این پژوهش با کمک شبکه های دوگان، ضمن استخراج ویژگی های متنوع، به دلیل پایین بودن عمق، شبکه دچار مشکل محو گرادیان نخواهد شد، از طرفی با استفاده از مکانیزم توجه، با وزن دهی به کانال و مکان، تاثیر به سزای آن در تفکیک نويز از تصویر و به خصوص تاثیر بسزای آن در حذف نويز حقیقی مشاهده می شود.

۳- روش پیشنهادی

روش های مبتنی بر پردازش تصویر برای حذف نويز از تصویر با استفاده از فیلترهایی مثل میانه، میانگین و انواع پردازش های مختلف استفاده می کنند، که کاربرد این روش ها محدود بوده و خیلی برای مسائل پردازشی از قبیل بخش بندی تصاویر و تشخیص و تفسیر کاربرد نمی باشند.

در روش پیشنهادی با استفاده از شبکه های عصبی کانولوشنی از دو شبکه به طور موازی استفاده شده که در یکی از شبکه ها، میان لایه ها ماژول توجه لحاظ گردیده و شبکه دیگر از لایه های کانولوشنی ساده ای تشکیل شده است. این دو شبکه باعث استخراج ویژگی های مختلفی از تصویر نويزی ورودی می شوند که به تفصیل در بخش های ذیل شرح داده شده اند.

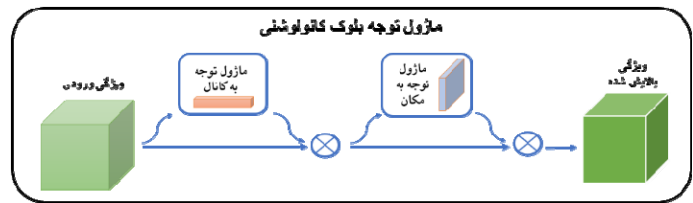
ResNet عمیق با ۱۰۰۱ لایه روی پایگاه داده CIFAR عملکرد بهتری داشته باشد. Xception [۳۶] و ResNext [۳۲] برای افزایش دادن قدرت شبکه وارد عرصه شدند. آنها بطور تجربی نشان می دهند که نه تنها بطور اساسی کل تعداد پارامترها را ذخیره می کنند بلکه منجر به قدرت بیان قوی تری از دو فاکتور عمق و پهنا می شوند.

دابوف و همکاران [۴] روش BM3D که مبتنی بر فیلترینگ مشترک در حوزه تبدیل با گروه بندی وصله های تصویر مشابه غیر محلی می باشد را پیشنهاد کردند، در این روش برای کاهش نويز، پراکندگی تصویری که دارای نمایش های پراکنده در حوزه تبدیل است، با گروه بندی وصله های دو بعدی مشابه، به گروه های سه بعدی ارتقا می یابد [۳۷]. گو و همکاران [۸]، استفاده از روش تقریبی مرتبه پایین WNNM^۹ را پیشنهاد کردند. متدهای بر اساس NSS متحمل برخی نواقص می باشند که شامل: جستجوی وصله های مشابه کمتر از حد بهینه، حل یک مسئله پیچیده بهینه و شامل چندین پارامتر انتخاب شده بصورت دستی برای موقعیت های مختلف حذف نويز می باشند. چن و همکاران [۱۷] انتشار واکنش غیر خطی قابل آموزش (TNRD) را برای یادگیری تصاویر قبلی پیشنهاد کردند. چنین روش های یادگیری متمایزی، همچنین شامل پارامترهای دستی زیاد و قابلیت محدود در بدست آوردن ویژگی های بیشتر از تصاویر می باشند. از سوی دیگر گروه دیگری از روش های مبتنی بر یادگیری از شبکه عصبی کانولوشنال عمیق بهره می برند [۱۴, ۱۵]. ماو و همکاران [۱۴] با استفاده از اتصالات پرش متقارن RED را پیشنهاد دادند. ژانگ و همکاران [۶] با استفاده از نگاشت آموزش از تصاویر نويزی به نويزها DnCNN را برای بهبود بیشتر با نرمال سازی وصله ها پیشنهاد کردند [۳۸]. ژانگ و همکاران با استفاده از روش بهینه سازی مبتنی بر مدل و نويززداي CNN یکپارچه IRCNN^۷ را برای بازیابی تصویر پیشنهاد دادند [۱۵]. بیشتر این روش ها عمق شبکه زیادی ندارند (به عنوان مثال عمق ۳۰ برای RED)، که مانع از توانایی بازنمایی می شود. روش های مبتنی بر CNN اخیر نمی توانند به عمق شبکه بسیار بزرگی دست یابند و ورودی های آموزشی بزرگ را به طور همزمان مدیریت کنند و حذف نويز واقعي تصویر کار سختی خواهد بود. علاوه بر این، هیچ یک از این روش های مبتنی بر CNN وابستگی کانال را در بین ویژگی ها بررسی نمی کنند، که می تواند به عنوان مکانیزم توجه در نظر گرفته شود و برای حذف نويز تصویر با کیفیت بالا مورد بررسی قرار گیرد. به طور کلی، اثر توجه به عنوان راهنمایی برای سوگیری تخصیص منابع پردازش موجود در نظر گرفته می شود و این به انتخاب آموزنده ترین مؤلفه ها از ورودی کمک می کند [۲۷]. امروزه، محققان کارهای آزمایشی را برای



⁶ weighted nuclear norm minimization

⁷ Image Restoration CNN

⁸ Convolutional Block Attention Module



شکل (۱): ماژول CBAM [1]



شکل (۲): دیاگرام هر زیرماژول توجه [۱]

۱-۳ شبکه های دوگانه

کند که در شکل (۲) نشان داده شده است، سپس نقشه های توجه در نقشه ویژگی ورودی برای اصلاح ویژگی انطباقی، المان به المان ضرب می شوند. چون CBAM یک ماژول سبک وزن و کلی است می تواند با هر معماری کانولوشنی یکپارچه ای با سربار ناچیز و با کانولوشن های پایه قابل آموزش ادغام شود. کل فرآیند توجه مطابق فرمول (۱) و شکل (۲) خلاصه می شود:

$$\begin{cases} F' = M_c(F) \otimes F \\ F'' = M_s(F) \otimes F' \end{cases} \quad (1)$$

که \otimes نشان دهنده ضرب المان به المان می باشد. در هنگام ضرب، مقادیر توجه، مطابق با آن گسترش می یابند: یعنی مقادیر توجه به کانال در طول بُعد مکان و مقادیر توجه به مکان در امتداد بُعد کانال گسترش می یابند. از آنجاییکه عملیات کانولوشنی ویژگی های اطلاعاتی را با ترکیب اطلاعات مکان و کانال متقابل با همدیگر استخراج می کنند، این مکانیزم برای تاکید ویژگی های معنادار در طول دو بعد اصلی محورهای کانال و مکان اتخاذ می شود. که برای رسیدن به آن، به صورت دنباله ای، مکانیزم های توجه کانال و مکان اعمال می شوند که در شکل (۱) نیز نشان داده شده اند، به نحوی که هر انشعابی می تواند یاد بگیرد که در هر کانال و مکانی به ترتیب چه چیزی و کجا را مورد توجه قرار دهد. این ماژول به طور کارآمدی به جریان اطلاعاتی شبکه به وسیله یادگیری، این کمک را می کند که کدام اطلاعات را مورد تاکید قرار دهد یا صرف نظر کند.

شبکه های دوگانه، دو مولفه ساختار و جزئیات را پوشش می دهند، که می توانند سیگنال هدف را مطابق با مسئله برای یک کار خاص تولید کنند. این شبکه ها نشان می دهند که می توانند به طور کارآمد و موثری روی تعداد زیادی کارهای بینایی سطح پایین اعمال شوند.

مدل کانولوشن دوگانه پیشنهادی، شامل دو انشعاب به صورت موازی می باشد، که ساختار و جزئیات را به صورت یک رفتار انتها به انتها پوشش می دهند. ساختار و جزئیات می توانند سیگنال های هدف را مطابق با یک مدل ایجاد شده برای هر کاربرد خاص تولید کنند. شبکه های دوگانه کانولوشنی چارچوبی منعطف برای کارهای بینایی سطح پایین دارند و می توانند به راحتی به شبکه های کانولوشنی موجود اضافه شوند. شبکه های دوگانه به طور موثر و کارآمدی برای وظایف بینایی سطح پایین، با عملکرد قابل قبولی در برابر آخرین دستاوردها اعمال می شوند.

۲-۳ مکانیزم توجه

در این پژوهش از ماژولی شامل بلوک کانولوشنی توجه که از آن با نام CBAM در سایر بخشهای مقاله یاد می شود و در شکل (۱) شمای کلی آن را می بینید استفاده شده که یک مکانیزم توجه موثر و ساده برای شبکه های عصبی کانولوشنی مسیر مستقیم می باشد. در یک نقشه ویژگی میانی $F \in \mathbb{R}^{C \times H \times W}$ داده شده، مکانیزم توجه به صورت دنباله ای، نقشه های توجه را در دو بعد جداگانه کانال $M_c \in \mathbb{R}^{C \times 1 \times 1}$ و مکان $M_s \in \mathbb{R}^{1 \times H \times W}$ استنتاج می-

خروجی، لایه‌گذاری صفر با گام یک بکار رفته است. در شاخه سمت راست برای لایه‌های ۲، ۵، ۹ و ۱۲ از بلوک CBAM استفاده شده که جزئیات آن قبلاً در بخش‌های قبل بیان شده است.

لایه‌های کانولوشنی که در بلوک فشرده‌ساز بکار رفته از فیلترهای با ابعاد 1×1 استفاده شده و تعداد آنها در فشرده‌ساز شماره یک ۶۴ فیلتر یعنی $64 \times 1 \times 1 \times 64$ و سه فیلتر برای فشرده‌ساز شماره (۲) یعنی $3 \times 1 \times 1 \times 128$ بکار رفته است. در این لایه‌ها نیز از لایه‌گذاری صفر و گام یک استفاده شده است.

علت اینکه تعداد فیلترها ۶۴ انتخاب شده، با استفاده از بررسی سایر مراجع در این حوزه و هم با روش دستی، تنظیم و بررسی تعداد فیلترهای مختلف حاصل شده است. با توجه به اینکه هزینه آموزشی شبکه‌های عصبی بسیار زمان‌بر و پرهزینه می‌باشد، برای انجام سریعتر آزمایشات، از روش کاهش نمونه برداری پایگاه داده آموزشی استفاده شده است یعنی تعداد تصاویر کمتری از پایگاه داده آموزشی مورد بهره برداری قرار گرفته است.

دلیل استفاده از بلوک‌های CBAM در لایه‌های مشخص نیز با بررسی حالت‌های مختلف و در جایگاه‌های مختلف در شبکه حاصل شده که بهترین نتایج در لایه‌های ۲، ۵، ۹ و ۱۲ حاصل شده است.

استفاده بیش از سه لایه بطور موازی نتیجه بهتری حاصل نکرده و از طرفی هزینه محاسباتی بالاتری نیز به همراه دارد. در شکل (۴) تصاویری از خروجی تصویر در هر لایه از دو شبکه موازی مشاهده می‌شود. قسمت (الف) تصاویر خروجی از لایه‌های مختلف شبکه سمت راست و در قسمت (ب) تصاویر خروجی لایه‌های مختلف شاخه موازی سمت چپ را مشاهده می‌کنید.

با توجه به تصویر ورودی، دو مکانیزم توجه، شامل کانال و مکان، توجه را به طور مکمل محاسبه می‌کنند، این دو به ترتیب روی "چه کانالی" و "کجای کانال" متمرکز می‌شوند. با توجه به این، دو ماژول می‌توانند به صورت موازی یا متوالی قرار گیرند که ترتیب متوالی می‌تواند نتیجه بهتری از ترتیب موازی داشته باشد.

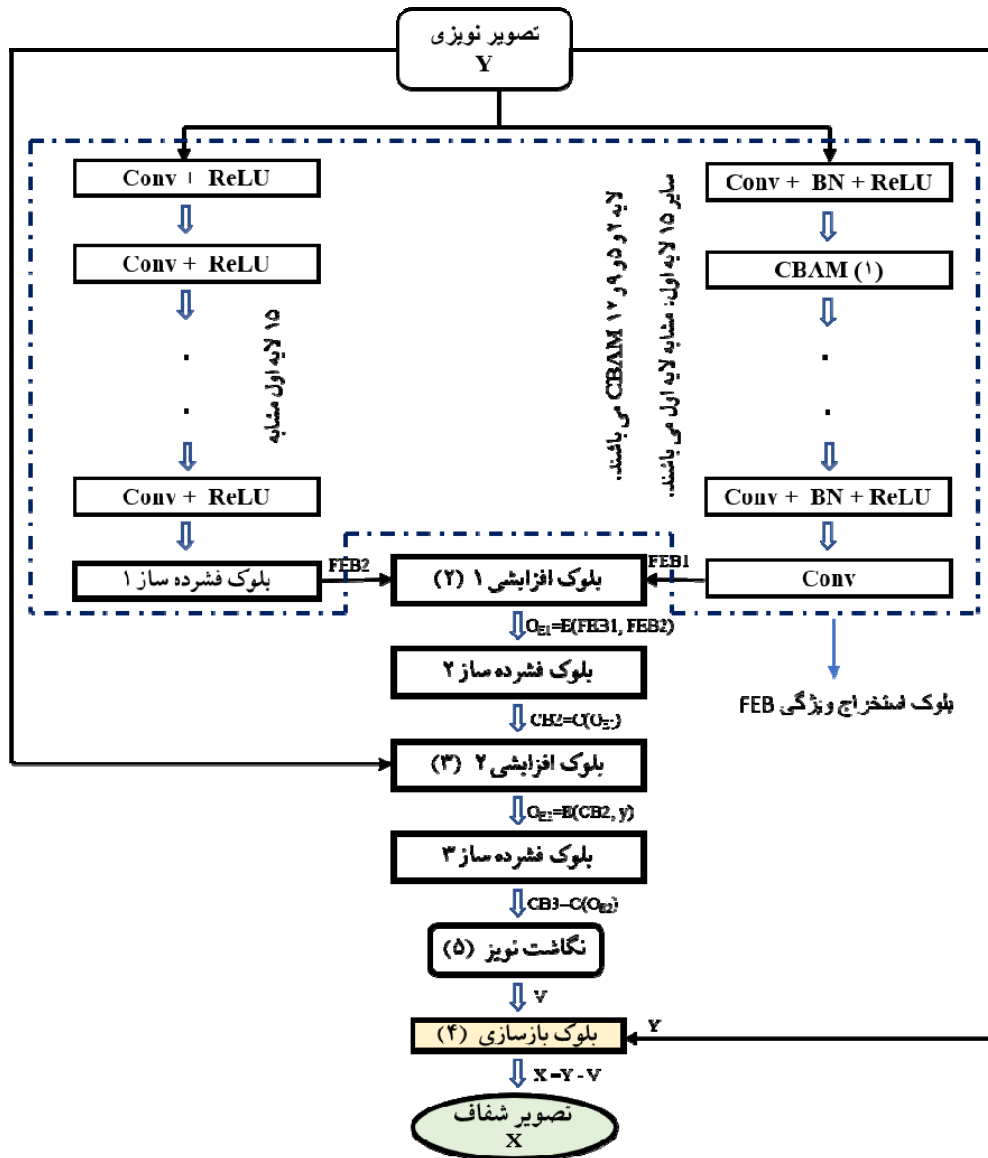
۳-۳ معماری شبکه

روش پیشنهادی در شکل (۳) نشان داده شده و ترکیبی از پنج بخش است: بلوک استخراج ویژگی، بلوک توجه، بلوک افزایشی، بلوک فشرده‌سازی و بلوک بازسازی.


بلوک استخراج ویژگی که با نقطه چین در شکل (۳) مشخص شده است، ویژگی‌های مختلفی را از تصویر ورودی استخراج می‌کند. شامل دو شاخه موازی می‌باشد یکی زیرشبکه سمت راست و دیگری زیرشبکه سمت چپ در ۱۶ لایه، که باعث استخراج ویژگی‌های متنوعی خواهد شد. بلوک توجه در لایه‌های ۲، ۵، ۹ و ۱۲ قرار گرفته است و به جای استفاده مکرر از لایه‌های کانولوشنی از ماژول CBAM استفاده شده تا هم ویژگی‌ها و هم کانال‌ها را مورد توجه قرار دهد که این باعث افزایش توانایی کلی شبکه در نوینزدایی از تصویر می‌گردد. بلوک افزایشی از اتصال ویژگی‌های دو بخش زیرشبکه ایجاد می‌گردد و این به حذف نویزهای ناشناخته در تصاویر، مثل نویز کور و نویزهای حقیقی کمک مفیدی می‌کند، شامل دو بخش می‌باشد، در بخش اول وظیفه اتصال دو زیرشبکه موازی را بر عهده دارد و در بخش دوم اتصال تصویر ورودی اصلی و خروجی از بلوک فشرده‌ساز شماره دو را با همدیگر انجام می‌دهد. بلوک فشرده‌سازی باعث انطباق بین دو بخش از شبکه می‌شود و در کاهش هزینه محاسباتی نقش ویژه‌ای دارد. این بلوک شامل سه بخش می‌باشد، بخش اول در انتهای زیرشبکه دوم و برای انطباق بین ویژگی‌های خروجی از دو زیرشبکه نیاز هست که از این بلوک استفاده شود، در بخش دوم نیز برای انطباق بین تصویر ورودی به بلوک افزایشی دوم، در نهایت برای نگاشت نویز بایستی تعداد کانالها به سه کانال کاهش یابد که بلوک فشرده‌ساز سوم نیاز می‌باشد. بلوک بازسازی در انتهای شبکه قرار دارد و منجر به ایجاد یک تصویر شفاف خواهد شد.

۳-۴- جزئیات شبیه سازی


در این شبکه مطابق شکل (۳) برای لایه‌های اول تا شانزدهم شاخه سمت راست بجز لایه‌های ۲، ۵، ۹ و ۱۲ و همینطور برای لایه‌های اول تا پانزدهم شاخه سمت چپ، از کانولوشن‌هایی با اندازه فیلترهای 3×3 و تعداد ۶۴ فیلتر برای هر لایه استفاده شده است یعنی به عبارتی $64 \times 3 \times 3 \times 64$. برای جلوگیری از تغییر اندازه



شکل (۳): معماری شبکه پیشنهادی



(الف)



شکل (۴): تصاویر لایه های مختلف دو شاخه (الف) شاخه سمت راست (ب) شاخه سمت چپ

۱-۴-۳ بلوک استخراج ویژگی

که در شکل (۶) ملاحظه می شود این بلوک دارای دو ورودی با تعداد فیلترهای یکسان می باشد در نتیجه، خروجی دارای تعداد فیلترهایی برابر با مجموع تعداد فیلترهای دو ورودی خواهد بود. بلوک افزایشی شماره (۱) که وظیفه اتصال خروجی های دو شبکه موازی را بر عهده دارد خروجی آن شامل ۱۲۸ کانال می باشد. بلوک افزایشی شماره (۲) که اتصال خروجی بلوک فشرده ساز شماره (۲) و تصویر ورودی اصلی را برعهده دارد، تعداد کانال های خروجی اش برابر ۶ کانال خواهد بود. خروجی مربوط به هر کدام از این بلوک ها در شکل (۳) نشان داده شده که بصورت زیر می باشند:

$$O_{E1} = E(FEB1, FEB2) \quad (2)$$

$$O_{E2} = E(CB2, Y) \quad (3)$$



شکل (۶): بلوک افزایشی

که E بیان کننده تابعی برای اتصال دو ورودی می باشد، منظور از O_E خروجی بلوک افزایشی بوده، FEB1 و FEB2 هر کدام خروجی های مربوط به دو زیرشبکه بلوک استخراج ویژگی می باشند، CB2 خروجی بلوک فشرده ساز شماره ۲ و Y تصویر نویزی ورودی به شبکه می باشد.

۳-۴-۳ بلوک فشرده ساز

این بلوک برای انطباق طبقات مختلف استفاده می شود و عمل تطبیق را انجام می دهد. عملکرد به این صورت می باشد که اندازه فیلتر بکار رفته $1*1$ بوده و تعداد فیلترها متناسب با تعداد کانال هایی است که قرار است در خروجی وجود داشته باشد، چون در سه طبقه مختلف از این بلوک استفاده شده در طبقه اول تعداد فیلترها برابر ۶۴ بوده، در طبقه دوم تعداد فیلترها برابر با ۳، در طبقه سوم نیز تعداد ۳ می باشد و همانطور که در شکل (۷) مشخص است دارای یک ورودی و یک خروجی می باشد. خروجی هر بلوک در شکل (۳) نیز نشان داده شده است.



شکل (۷): بلوک فشرده ساز


۴-۴-۴ بلوک بازسازی (RB)

در این بلوک از تفاوت بین تصویر نویزی ورودی و خروجی حاصل شده از شبکه که همان نویز می باشد، یک تصویر شفاف حاصل

این بلوک شامل دو شبکه می باشد. شبکه اول شامل سه نوع ماژول می باشد: ماژول اول شامل (Conv + BN + ReLU) و ماژول دوم شامل (CBAM) و ماژول سوم شامل (Conv) می باشد. ماژول اول در لایه های اول، سوم، چهارم، ششم، هفتم، هشتم، نهم، دهم، یازدهم، سیزدهم، چهاردهم و پانزدهم قرار دارد. ماژول دوم در لایه های دوم، پنجم، نهم و دوازدهم قرار دارد. ماژول سوم در لایه شانزدهم می باشد این ماژول ها در شکل (۵) به تفکیک نمایش داده شده اند. اندازه همه فیلترهای ماژول اول $3*3$ بوده و تعداد فیلترها ۶۴ می باشد. در لایه اول تعداد کانال ها برابر با تعداد کانال های تصویر ورودی می باشد که برای تصاویر رنگی برابر سه و برای تصاویر سطح خاکستری یک می باشد. ماژول دوم اثر توجه به ویژگی ها و کانال ها را دارد. ماژول سوم فقط شامل یک لایه کانولوشنی می باشد. در شکل (۳) خروجی نهایی این زیرشبکه با FEB1 نمایش داده شده است و منظور ویژگی های استخراج شده از این زیرشبکه اول می باشد.

شبکه دوم شامل دو ماژول می باشد: ماژول اول شامل (Conv + ReLU) و ماژول دوم شامل بلوک فشرده ساز می باشد. اندازه فیلترهای ماژول اول از لایه ۱ تا ۱۵ همگی $3*3$ و تعداد فیلترها ۶۴ می باشد بجز لایه اول که تعداد فیلترهای ورودی متناسب با تعداد کانال های تصویر ورودی می باشد و متناسب با نوع تصویر خاکستری یا رنگی به ترتیب ۱ یا ۳ انتخاب می گردد. ماژول دوم یک بلوک فشرده ساز مطابق شکل (۷) می باشد در این بلوک به دلیل اندازه فیلتر $1*1$ ، در هزینه های محاسباتی صرفه جویی می گردد، تعداد فیلترها برابر با ۶۴ و با تعداد فیلترهای لایه ۱۶ ام شبکه اول برابر می باشند. خروجی نهایی این زیرشبکه نیز با FEB2 در شکل (۳) مشخص شده است.

تنظیم ابرپارامترها شامل: اندازه فیلترها، تعداد فیلترها و عمق شبکه به صورت تجربی و تا حدی با سعی و خطا تعیین شده اند.




شکل (۵): انواع ماژول های موجود در دو شبکه موازی

۲-۴-۳ بلوک افزایشی

این بلوک از کنار هم قرار دادن خروجی دو شبکه مربوط به بلوک استخراج ویژگی و یا تصویر ورودی و خروجی بلوک فشرده ساز مرحله دوم حاصل می شود و نتیجه آن بالا بردن قابلیت شناسایی نویزهای ناشناخته مانند نویز کور و نویز حقیقی می باشد. همانطور

می‌شود. در شکل (۸) تعداد دو ورودی و یک خروجی برای این بلوک نشان داده شده است. ورودی سمت چپ تصویر نویزی Y و ورودی از بالا، نویز V می‌باشد که خروجی X را مطابق فرمول (۴) خواهد داد.

می‌شود. در شکل (۸) تعداد دو ورودی و یک خروجی برای این بلوک نشان داده شده است. ورودی سمت چپ تصویر نویزی Y و ورودی از بالا، نویز V می‌باشد که خروجی X را مطابق فرمول (۴) خواهد داد.



شکل (۸) : بلوک بازسازی

$$X = Y - V \quad (4)$$

۵-۴-۳ تابع اتلاف

برای محاسبه اتلاف از تابع خطای مجذور میانگین استفاده شده است، مطابق با فرمول (۵) که تابع هدف نیز نامیده می‌شود. $R(Y_j)$ باقیمانده تصویر پیش بینی شده می‌باشد و $(Y_j - X_j)$ معادل برجسب بوده که X_j نمایش دهنده تصویر زام شفاف و Y_j نمایش دهنده تصویر ورودی نویزی می‌باشد.

$$L(\theta) = \frac{1}{2N} \sum_{j=1}^N \|R(Y_j, \theta) - (Y_j - X_j)\|_2^2 \quad (5)$$

که \square پارامترهای مدل آموزش دیده و N تعداد جفت تصاویر نویزی و تمیز را بیان می‌کند. در این شبکه از بهینه ساز Adam استفاده شده است.

۶-۴-۳ نحوه عملکرد شبکه

برای آموزش شبکه نیاز به تصاویر نویزی و تصاویر اصلی بدون نویز به عنوان برجسب می‌باشد، در هر تکرار یک تصویر نویزی به عنوان ورودی به شبکه اعمال می‌شود مطابق شکل (۳) و پس از عبور از لایه‌های مختلف وارد بخش نگاشت نویز می‌گردد، نویز حاصل شده از تصویر نویزی با نویز اصلی اعمالی به شبکه که از اختلاف تصویر نویزی و تصویر اصلی حاصل می‌شود مقایسه می‌شود، این مقایسه توسط تابع اتلاف انجام می‌شود، برای کاهش میزان اتلاف با بهینه‌ساز Adam وزن‌های شبکه اصلاح و این مراحل تکرار می‌شوند تا نتیجه مورد نظر حاصل شود.

۴- پیاده سازی و نتایج شبیه سازی

برای اثبات کارآمدی روش بکار رفته از پایگاه داده‌های مختلفی که شامل انواع نویزهای ترکیبی و حقیقی می‌باشند استفاده شده که در ادامه به تشریح پایگاه داده‌های آموزشی و آزمایشی بکار رفته و جزئیات پیاده‌سازی پرداخته شده است. منظور از نویز ترکیبی همان نویز سفید گاوسی می‌باشد که به تصویر اضافه می‌شود و اصطلاحاً

۱-۴- پایگاه داده آموزشی

پایگاه داده آموزشی مورد استفاده برای تصاویر رنگی، پایگاه داده pristine_images_color[49] می‌باشد که شامل ۳۸۵۹ تصویر با ابعاد مختلف می‌باشد. از ۴۰۰ تصویر اول به ترتیب شماره تصاویر آنها، برای آموزش شبکه جهت حذف نویزهای ترکیبی و کور تصاویر رنگی استفاده شده است.

برای تصاویر سطح خاکستری از پایگاه داده آموزشی pristine_images_gray[49] استفاده شده است. این تصاویر همان تصاویر سطح خاکستری شده پایگاه داده تصاویر رنگی می‌باشند که برای آموزش، مشابه با نوع رنگی از آنها استفاده می‌شود. نمونه ای از این تصاویر پایگاه داده pristine رنگی و خاکستری در شکل (۹) نشان داده شده اند.

داده‌های آموزشی به دو بخش تقسیم می‌شوند: تصاویر با نویز ترکیبی و نویز حقیقی. تصاویر با نویز ترکیبی شامل تصاویر در سطح خاکستری و سطح رنگی می‌باشند. که ۴۰۰ تصویر برای داده‌های نویزی ترکیبی بکار برده شده است. برای اضافه کردن داده های آموزشی: (۱) درونیایی دومکعبی با ضرایب کاهش مقیاس ۰,۷, ۰,۸, ۰,۹, ۱ و اعمال گردید. (۲) همچنین جهت افزایش تنوع نمونه‌های آموزشی هشت نوع دستکاری دیگر روی آنها اعمال شده که شامل: بدون دستکاری (تصاویر اصلی)، چرخش درجهت پاد ساعتگرد با زوایای ۱۸۰, ۹۰ و ۲۷۰ درجه و تصاویر ورق زده شده در جهت افقی و همزمان چرخش پادساعتگرد صفر، ۹۰، ۱۸۰ و ۲۷۰ درجه می‌باشد. برای قویتر کردن مدل آموزشی، هر دستکاری در هر زمان فقط به یک تصویر اعمال می‌شود و هر تصویر چهار بار در هر گام آموزشی استفاده می‌شود.

برای تصاویر با نویز حقیقی نیز از ۱۰۰ تصویر با فرمت jpeg با اندازه ۵۱۲*۵۱۲ به عنوان داده‌های آموزشی استفاده شده، که از ۵ دستگاه دیجیتال مختلف بدست آمده‌اند: Nikon, Canon 80D, Sony A7 II, Canon 600D, D800, Canon 5D Mark II با حسگرهایی با پارامترهای مختلف (بطور مثال ۸۰۰, ۱۶۰۰, ۳۲۰۰, ۶۴۰۰, ۱۲۸۰۰ و ۲۵۶۰۰). از آنجاییکه این تصاویر حقیقی فشرده سازی شده‌اند چالشهای بیشتری را برای حذف نویز تصویر ایجاد می‌کنند.

⁹ Additive White Gaussian Noise

¹⁰ Parallel and Attention Networks

¹¹ Parallel and Attention Networks with blind noise

۲-۴- پایگاه داده آزمایش

طرح پیشنهادی روی ۵ پایگاه داده عمومی شامل: BSD68 [۵۰]، Set12 [۲۳]، CBSD68 [۵۰]، Kodak24 [۵۱]، CC [۵۲]، که پایگاه داده‌های BSD68 و SET12 به ترتیب شامل ۶۸ و ۱۲ تصویر سطح خاکستری از صحنه‌های مختلف و ابعاد هر تصویر این پایگاه داده‌ها به ترتیب ۴۸۱*۳۲۱ و ۲۵۶*۲۵۶ می‌باشد. CBSD68 و Kodak24 به ترتیب شامل ۶۸ و ۲۴ تصویر رنگی طبیعی که ابعاد ۴۸۱*۳۲۱ و ۵۱۲*۵۱۲ می‌باشند. CC شامل ۱۵ تصویر تخریب شده واقعی با ابعاد ۵۱۲*۵۱۲ می‌باشد که با سه دستگاه دیجیتال: Nikon D600، Canon Mark III و Nikon D800 با سه مقدار استاندارد (۱۶۰۰، ۳۲۰۰ و ۶۴۰۰) می‌باشد، تصاویر این پایگاه داده در شکل (۱۰) نشان داده شده‌اند.

۳-۴- جزئیات پیاده سازی

عمق معماری بکار رفته ۱۸ می‌باشد. برای شتاب در آموزش، تصاویر نمونه برداری شده به وصله‌های ۴۱*۴۱ تبدیل می‌شوند تا مدل حذف نویز آموزش داده شود.

در فاز آموزش، تنظیمات پارامتر اولیه به این صورت می‌باشند: نرخ یادگیری 10^{-3} ، 10^{-8} ، اندازه دسته ۱۲۸، $\beta_1 = 0.9$ ، تعداد گام‌های آموزشی ۷۰ و نرخ یادگیری در ۳۰ گام آموزشی دوم یک دهم برابر و در ده گام آموزشی آخر یک صدم برابر می‌شود.

از نسخه پایتون ۳،۷ و پایتورچ ۱،۸،۷ برای آموزش و آزمایش مدل استفاده شده و آزمایشات روی کامپیوتر با تجهیزات Intel CPU Gpu Nvidia Geforce GTX و Ram 32G, Core i7-8500 1060 انجام شده است.

کدهای مقاله در آدرس ذیل در دسترس می‌باشند:

<https://github.com/digital3992/PANet>

۴-۴- تحلیل شبکه

۱-۴-۴- طراحی میدان دید

تقسیم بندی تصویر به وصله می‌تواند هزینه‌های محاسباتی را در مقایسه با یک تصویر کامل کاهش دهد. به ویژه، عموماً اندازه وصله‌ها اندکی بزرگتر از اندازه میدان دید شبکه در نظر گرفته می‌شود. در این شبکه اندازه هر وصله ۴۱*۴۱ در نظر گرفته شده است.

۲-۴-۴- مطالعات فرسایشی

برای مطالعه و بررسی بیشتر روش بکار رفته آزمایشاتی روی حالت‌های مختلف این شبکه، در شش وضعیت مختلف شامل شبکه دوگانه با مکانیزم توجه، شبکه دوگانه بدون مکانیزم توجه، شبکه یگانه با مکانیزم توجه و شبکه یگانه بدون مکانیزم توجه، شبکه سه گانه (منظور استفاده از سه شبکه بصورت موازی می‌باشد) با مکانیزم توجه و شبکه سه گانه بدون مکانیزم توجه مورد بررسی قرار گرفت که نتایج در جدول شماره (۱) بیان گردیده و بیشترین مقدار سیگنال به نویز کسب شده متعلق به دو حالت

شبکه دوگانه با مکانیزم توجه و شبکه سه گانه با مکانیزم توجه می‌باشد اما به دلیل بار محاسباتی بالای شبکه های سه گانه ارجحیت در استفاده از شبکه های دوگانه می‌باشد.

۵-۴- مقایسه نتایج با سایر تکنیک های حذف نویز

در این مقاله، مقایسه آزمایشات با چهار کاربرد در حوزه تصاویر خاکستری، رنگی، تصاویر نویزی حقیقی و نویز کور انجام شده است. از معیار PSNR [۵۳، ۵۴] مطابق فرمول (۶) برای بررسی نسبت سیگنال به نویز در تصویر بر حسب دسی بل استفاده شده است.

$$PSNR = 10 * \lg_{10} \left(\frac{MAX}{MSE} \right) \quad (6)$$

که MAX حداکثر مقدار پیکسل و MSE خطای مجذور میانگین بین یک تصویر شفاف و تصویر شفاف پیش بینی شده می‌باشند. معیار دیگری که برای ارزیابی کمی تصاویر می‌تواند بکار آید معیار SSIM [۵۵] می‌باشد که به آن شاخص شباهت ساختاری نیز گفته می‌شود [۵۶] که نحوه محاسبه مطابق فرمول (۷) می‌باشد.

$$SSIM_{xy} = \frac{(2\mu_x\mu_y + C_1)(2cov(xy) + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (7)$$

مقادیر μ_x و μ_y به ترتیب به معنای میانگین x و y می‌باشند و $cov(x, y)$ کواریانس x و y را بیان می‌کند و σ_x^2 و σ_y^2 به ترتیب مقادیر واریانس x و y را نشان می‌دهند و C_1 و C_2 مقادیر ثابتی می‌باشند که به ترتیب با ۶،۵ و ۵۸،۵ تنظیم شده‌اند.

بررسی بصری تصاویر حذف نویز شده با روش‌های مختلف، برای انواع پایگاه داده انجام شده است.

۱-۴-۵- بررسی نتایج حذف انواع نویز در تصاویر

رنگی و خاکستری

جدول (۲) میانگین PSNR و SSIM روی پایگاه‌های داده CBSD68 و Kodak24، برای تصاویر رنگی در مواجهه با نویزهای ترکیبی و کور، در مقایسه روش پیشنهادی با سایر روش‌های این حوزه را نشان می‌دهد. مطابق با آنچه در نتایج حاصل از این جدول مشاهده می‌شود، روش پیشنهادی در سطوح نویزی مختلفی شامل ۱۰، ۱۵، ۲۵ و ۵۰ مورد بررسی قرار گرفته که در سطح نویز ۱۰ برای پایگاه داده CBSD68 با ۰،۰۱ db اختلاف در رتبه دوم جدول قرار دارد، در پایگاه داده Kodak24 فقط توانسته بالاتر از CBM3D قرار بگیرد. در سطح نویز ۱۵ برای پایگاه داده CBSD68 با مقدار PSNR=۳۳،۸۵ db حدود ۰،۱۳ db کمتر از DnCNN می‌باشد و در معیار SSIM توانسته مقداری بسیار نزدیک و با اختلاف ۰،۰۰۲ با روش DnCNN را کسب کند، همچنین روش پیشنهادی در مقایسه با سایر روش‌ها از قبیل SUNet، FFDNet، IRCNN و CBM3D تقریباً برابر یا بالاتر از آنها می‌باشد.

در سطح نویز ۱۵ برای پایگاه داده Kodak24 اگرچه نتایج در معیار PSNR نسبت به برخی روش‌ها کمی کاهش یافته ولی در

جدول (۴) عملکرد حذف نویز برای تصاویر با نویز حقیقی را نشان می‌دهد که روی پایگاه داده CC اعمال شده است. پایگاه داده CC شامل ۱۵ تصویر مختلف می‌باشد که توسط سه دوربین متفاوت با مشخصات Canon 5D Mark III, Nikon D600, Nikon D800 با تنظیمات مختلفی (به عنوان مثال ۱۶۰۰، ۳۲۰۰ و ۶۴۰۰) عکسبرداری شده‌اند، تصاویر نیز در شکل (۱۰) نشان داده شده‌اند. روش پیشنهادی نتایج بسیار خوبی را حاصل نموده و در رتبه یک از این جدول در مقایسه با سایر روش‌ها قرار دارد، بطور خلاصه مدل حذف نویز پیشنهادی برای کار با نویزهای پیچیده، مثل تصاویر نویزی ترکیبی رنگی، حذف نویز کور و تصاویر نویز حقیقی مناسب می‌باشد و این اهمیت شبکه‌های دوگانه با عمق کم، قابلیت بالای آنها در استخراج انواع ویژگی‌ها و اهمیت مکانیزم توجه به کار رفته را در مقایسه با سایر شبکه‌ها بیشتر نمایان می‌سازد.

۲-۵-۴- پیچیدگی محاسباتی

همانطور که در جدول (۵) دیده می‌شود تعداد پارامترهای روش پیشنهادی مقدار ۱,۰۸۲ میلیون پارامتر می‌باشد که نزدیک به دوبرابر روش DnCNN می‌باشد و اگرچه در اکثر مقایسه‌ها روش پیشنهادی با DnCNN در رقابت می‌باشد ولی در جدول (۴) در مقابله با نویز حقیقی روش پیشنهادی توانسته با اختلاف زیادی حدود ۲,۴۳ دسی بل نتیجه بسیار بهتری کسب کند. تعداد FLOPs^{۱۲} روش پیشنهادی هم نسبت به DnCNN بالاتر بوده ولی از دیگر روش‌های ذکر شده باز به مراتب کمتر می‌باشد، از جمله روش‌های نوین که از ترنسفورمرها استفاده می‌کنند می‌توان به IPT و SUNet اشاره کرد که تعداد پارامترها و فلاپس بسیار بیشتری دارند، با افزایش تعداد فلاپس هزینه محاسباتی افزایش می‌یابد.

معیار SSIM نتایج با اختلاف حداکثر ۰,۰۰۷ نسبت به روش پیشنهادی می‌باشد که آنرا بسیار قابل قبول می‌سازد.

در سطح نویزی ۲۵ در پایگاه داده CBSD68 با اختلاف ۰,۱۱ db روش پیشنهادی رتبه دوم جدول را کسب نموده است و در پایگاه داده Kodak24 رتبه نخست جدول را کسب نموده است. در سطح نویز ۵۰ نیز روش پیشنهادی با اختلاف ۰,۰۴ db در پایگاه داده CBSD68 رتبه دوم را دارد و در پایگاه داده Kodak24 با اختلاف ۰,۳۷ db در رتبه چهارم جدول قرار دارد. اما با معیار SSIM این اختلاف در حد ۰,۰۰۶ می‌باشد.

اگرچه روش پیشنهادی در برخی سطوح نویزی در پایگاه‌های داده مختلف نسبت به برخی روش‌ها از قبیل FFDNet یا DnCNN کاهش دارد اما نقطه قوت این پژوهش در مواجهه با نویزهای حقیقی می‌باشد که در جدول (۵) به آن پرداخته شده است ضمن اینکه روش FFDNet مناسب نویزهای حقیقی و کور نمی‌باشد و روش DnCNN با اینکه ظرفیت مدلسازی بهتری دارد ولی برای حذف نویز تصاویر با سطح نویز کمتر مفید است.

در ادامه جدول (۲) میانگین PSNR و SSIM روی پایگاه داده BSD68 برای تصاویر سطح خاکستری در سطوح نویزی ۱۵، ۲۵ و ۵۰ بررسی شده، که روش پیشنهادی در تمامی سطوح نویزی در رتبه دوم جدول نسبت به سایر روش‌های حذف نویز قرار دارد، نتایج نشان می‌دهد عملکرد روش پیشنهادی در برابر سایر روش‌ها بسیار عملکرد خوب و قابل قبولی در تمامی سطوح نویزی آزمایش شده می‌باشد، به دلیل عدم موجود بودن مقادیر PSNR سایر روش‌ها در سطح نویز ۱۰، محاسبه در این سطح نویز انجام نگردید که در جدول نیز با خط تیره نمایش داده شده است. در سطح نویز ۱۵ با مقدار SNRP=۳۱,۵۴ db و اختلاف ۰,۱۹ db و در معیار SSIM با اختلاف ۰,۰۰۶ بعد از DnCNN قرار گرفته است.

در سطح نویز ۲۵ با مقدار PSNR=۲۸,۹ db و اختلاف ۰,۰۳ db، در معیار SSIM با اختلاف ۰,۰۰۹ رتبه دوم را در جدول دارد.

در سطح نویز ۵۰ با مقدار PSNR=۲۶,۰۶ db و اختلاف ۰,۱۷ db، در معیار SSIM با اختلاف ۰,۰۱ بعد از DnCNN قرار گرفته است. روش پیشنهادی اگرچه در رتبه دوم و با اختلاف بسیار ناچیزی بعد از DnCNN قرار دارد اما مهمترین ویژگی متمایز آن در مواجهه با نویز حقیقی می‌باشد.

جدول (۳) مقدار PSNR و میانگین آن برای تک تک تصاویر موجود در پایگاه داده SET12 را نشان می‌دهد، که شامل ۱۲ تصویر در مقیاس خاکستری می‌باشد، روش‌های مختلف حذف نویز در سطوح مختلف نویز شامل ۱۵، ۲۵ و ۵۰ اعمال شده است، با توجه به پیچیدگی‌های هر تصویر از نظر بافت، نتیجه برای هر تصویر جداگانه بیان شده است. علاوه بر روش پیشنهادی ارائه شده، روش پیشنهادی با نویز کور (PANet_B) نیز در تمامی جداول آورده شده که روش مذکور در برابر نویز کور نیز عملکردی بسیار خوب و نزدیک به نویز ترکیبی کسب نموده است.

¹² Floating Point Operations

جدول (۱): نتایج حذف نویز گاوسین با سطح نویز ۲۵، ارزیابی شده در پایگاه داده SET68

مدل	PSNR
شبکه دوگانه با مکانیزم توجه	۲۸,۹۳
شبکه دوگانه بدون مکانیزم توجه	۲۸,۸۹
شبکه سه گانه با مکانیزم توجه	۲۸,۹۳
شبکه سه گانه بدون مکانیزم توجه	۲۸,۹۰
شبکه یگانه با مکانیزم توجه	۲۸,۸۵
شبکه یگانه بدون مکانیزم توجه	۲۸,۸۳

جدول (۲): میانگین PSNR و SSIM روی پایگاه داده BSD68 و Kodak24 و CBSD68

۵۰=σ		۲۵=σ		۱۵=σ		۱۰=σ		روش	پایگاه داده
PSNR	SSIM	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM		
۲۷,۳۶	۰,۷۶۳	۳۰,۷۱	۰,۸۵۵	۳۳,۵۲	۰,۹۰۳	۳۵,۸۹	۰,۹۵۱	CBM3D[4]	CBSD68
۲۷,۹۶	۰,۷۸۸	۳۱,۱۸	۰,۸۸۱	۳۳,۸۰	۰,۹۲۵	۳۶,۱۰	۰,۹۵۳	FFDNet[7]	
۲۷,۹۲	۰,۷۸۸	۳۱,۳۱	۰,۸۹۰	۳۳,۹۸	۰,۹۲۹	۳۶,۱۲	۰,۹۵۱	DnCNN[6]	
۲۷,۸۶	۰,۷۸۹	۳۱,۱۶	۰,۸۸۱	۳۳,۸۶	۰,۹۲۷	۳۶,۰۶	۰,۹۵۳	IRCNN[15]	
۲۷,۸۵	۰,۷۹۹	۳۱,۰۰	۰,۸۷۸	۳۳,۶۸	۰,۹۲۷	۳۵,۹۴	۰,۹۵۸	SUNet[5]	
۲۷,۹۲	۰,۷۸۸	۳۱,۲۰	۰,۸۸۲	۳۳,۸۵	۰,۹۲۷	۳۶,۱۱	۰,۹۵۳	روش پیشنهادی	
۲۷,۶۵	۰,۷۷۴	۳۱,۰۱	۰,۸۷۷	۳۳,۷۱	۰,۹۲۶	۳۵,۹۷	۰,۹۵۱	PANet_B	
۲۸,۴۶	۰,۷۷۹	۳۱,۶۸	۰,۸۵۶	۳۴,۲۸	۰,۹۰۳	۳۳,۳۲	۰,۹۴۳	CBM3D[4]	
۲۸,۹۹	۰,۷۹۳	۳۲,۱۱	۰,۸۷۹	۳۴,۵۵	۰,۹۲۳	۳۶,۷۰	۰,۹۴۶	FFDNet[7]	
۲۹,۰۲	۰,۷۹۰	۳۲,۰۳	۰,۸۷۸	۳۴,۷۳	۰,۹۲۱	۳۶,۵۸	۰,۹۴۵	DnCNN[6]	
۲۸,۸۱	۰,۷۹۰	۳۲,۰۳	۰,۸۷۶	۳۴,۵۶	۰,۹۱۸	۳۶,۷۰	۰,۹۴۵	IRCNN[15]	
۲۹,۵۴	۰,۸۱۰	۳۲,۰۸	۰,۸۸۲	۳۴,۴۷	۰,۹۲۲	۳۶,۷۹	۰,۹۵۳	SUNet[5]	
۲۸,۶۵	۰,۷۸۷	۳۲,۱۲	۰,۸۷۸	۳۴,۴۰	۰,۹۱۶	۳۶,۵۵	۰,۹۴۵	روش پیشنهادی	
۲۸,۴۰	۰,۷۷۱	۳۱,۶۲	۰,۸۶۶	۳۴,۲۰	۰,۹۱۴	۳۶,۴۰	۰,۹۴۲	PANet_B	
۲۵,۶۲	۰,۶۸۷	۲۸,۵۷	۰,۸۰۱	۳۱,۰۷	۰,۸۷۲	-	-	BM3D[4]	BSD68
۲۵,۸۷	۰,۶۹۸	۲۸,۸۳	۰,۸۰۹	۳۱,۳۷	۰,۸۷۶	-	-	WNNM[8]	
۲۵,۶۷	۰,۶۹۴	۲۸,۶۸	۰,۸۰۲	۳۱,۲۱	۰,۸۷۴	-	-	EPLL[10]	
۲۵,۹۷	۰,۷۰۳	۲۸,۹۲	۰,۸۱۲	۳۱,۴۲	۰,۸۸۲	-	-	TNRD[17]	
۲۶,۲۳	۰,۷۱۵	۲۹,۲۳	۰,۸۲۱	۳۱,۷۳	۰,۸۹۰	-	-	DnCNN[6]	
۲۶,۰۶	۰,۷۰۵	۲۸,۹۳	۰,۸۱۲	۳۱,۵۴	۰,۸۸۴	-	-	روش پیشنهادی	
۲۶,۰۲	۰,۶۹۷	۲۸,۹۲	۰,۸۰۸	۳۱,۳۲	۰,۸۷۶	-	-	PANet_B	

جدول (۳) : مقدار و میانگین PSNR با روشهای مختلف روی تصاویر پایگاه داده SET12


میانگین	Couple	Man	Boat	Barbara	Lena	Parrot	Airplane	Monarc h	starfish	Peppers	House	C.man	تصاویر
۱۵=σ													سطح نویز
۳۲,۳۷	۳۲,۱۰	۳۱,۹۲	۳۲,۱۳	۳۳,۱۰	۳۴,۲۶	۳۱,۳۷	۳۱,۰۷	۳۱,۸۵	۳۱,۱۴	۳۲,۶۹	۳۴,۹۳	۳۱,۹۱	BM3D[4]
۳۲,۷۰	۳۲,۱۷	۳۲,۱۱	۳۲,۲۷	۳۳,۶۰	۳۴,۲۷	۳۱,۶۲	۳۱,۳۹	۳۲,۷۱	۳۱,۸۲	۳۲,۹۹	۳۵,۱۳	۳۲,۱۷	WNNM[8]
۳۲,۱۴	۳۱,۹۳	۳۲,۰۰	۳۱,۹۳	۳۱,۳۸	۳۳,۹۲	۳۱,۴۲	۳۱,۱۹	۳۲,۱۰	۳۱,۱۳	۳۲,۶۴	۳۴,۱۷	۳۱,۸۵	EPLL[10]
۳۲,۳۲	۳۱,۹۸	۳۲,۰۸	۳۲,۰۱	۳۱,۹۲	۳۴,۰۶	۳۱,۳۷	۳۱,۳۳	۳۲,۳۳	۳۱,۵۵	۳۲,۸۵	۳۴,۳۹	۳۱,۹۵	CSF[9]
۳۲,۵۰	۳۲,۱۱	۳۲,۲۳	۳۲,۱۴	۳۲,۱۳	۳۴,۲۴	۳۱,۶۳	۳۱,۴۶	۳۲,۵۶	۳۱,۷۵	۳۳,۰۴	۳۴,۵۳	۳۲,۱۹	TNRD[17]
۳۲,۷۷	۳۲,۴۶	۳۲,۴۱	۳۲,۳۸	۳۲,۵۴	۳۴,۶۲	۳۱,۸۱	۳۱,۵۷	۳۲,۶۶	۳۱,۹۹	۳۳,۲۵	۳۵,۰۷	۳۲,۴۳	FFDNet[7]
۳۲,۸۲	۳۲,۴۱	۳۲,۳۸	۳۲,۳۶	۳۲,۶۱	۳۴,۵۴	۳۱,۸۹	۳۱,۷۱	۳۳,۲۰	۳۲,۱۴	۳۳,۱۸	۳۵,۰۳	۳۲,۳۸	SANet[20]
۳۲,۷۲	۳۲,۴۳	۳۲,۳۷	۳۲,۴۱	۳۲,۴۹	۳۴,۵۶	۳۱,۶۲	۳۱,۶۱	۳۲,۹۳	۳۱,۹۴	۳۳,۲۱	۳۵,۰۳	۳۲,۰۴	PSN-U[21]
۳۲,۶۴	۳۲,۲۶	۳۲,۲۵	۳۲,۲۹	۳۲,۰۱	۳۴,۳۲	۳۱,۷۴	۳۱,۶۱	۳۲,۹۴	۳۱,۹۳	۳۳,۲۴	۳۴,۶۹	۳۲,۴۰	روش پیشنهادی
۳۲,۳۷	۳۲,۰۴	۳۲,۰۸	۳۲,۱۶	۳۱,۵۳	۳۴,۱۹	۳۱,۳۸	۳۱,۴۱	۳۲,۶۲	۳۱,۷۱	۳۲,۹۳	۳۴,۶۵	۳۱,۸۰	PANet-B
۲۵=σ													سطح نویز
۲۹,۹۷	۲۹,۷۱	۲۹,۶۱	۲۹,۹۰	۳۰,۷۱	۳۲,۰۷	۲۸,۹۳	۲۸,۴۲	۲۹,۲۵	۲۸,۵۶	۳۰,۱۶	۳۲,۸۵	۲۹,۴۵	BM3D[4]
۳۰,۲۶	۲۹,۸۲	۲۹,۷۶	۳۰,۰۳	۳۱,۲۴	۳۲,۲۴	۲۹,۱۵	۲۸,۶۹	۲۹,۸۴	۲۹,۰۳	۳۰,۴۲	۳۳,۲۲	۲۹,۶۴	WNNM[8]
۲۹,۶۹	۲۹,۵۳	۲۹,۶۶	۲۹,۷۴	۲۸,۶۱	۳۱,۷۳	۲۸,۹۵	۲۸,۶۱	۲۹,۳۹	۲۸,۵۱	۳۰,۱۷	۳۲,۱۷	۲۹,۲۶	EPLL[10]
۳۰,۰۳	۲۹,۷۳	۲۹,۸۸	۲۹,۹۷	۲۹,۵۴	۳۲,۲۵	۲۹,۲۵	۲۸,۸۲	۲۹,۶۱	۲۸,۸۲	۳۰,۳۰	۳۲,۵۶	۲۹,۶۱	MLP[24]
۲۹,۸۴	۲۹,۵۳	۲۹,۷۱	۲۹,۷۶	۲۹,۰۳	۳۱,۷۹	۲۸,۹۰	۲۸,۷۲	۲۹,۶۲	۲۸,۸۰	۳۰,۳۲	۳۲,۳۹	۲۹,۴۸	CSF[9]
۳۰,۰۶	۲۹,۷۱	۲۹,۸۷	۲۹,۹۱	۲۹,۴۱	۳۲,۰۰	۲۹,۱۸	۲۸,۸۸	۲۹,۸۵	۲۹,۰۲	۳۰,۵۷	۳۲,۵۳	۲۹,۷۲	TNRD[17]
۳۰,۴۴	۳۰,۲۰	۳۰,۱۱	۳۰,۲۵	۳۰,۰۱	۳۲,۵۷	۲۹,۴۴	۲۹,۰۴	۳۰,۰۸	۲۹,۳۲	۳۰,۹۳	۳۳,۲۸	۳۰,۱۰	FFDNet[7]
۳۰,۳۷	۳۰,۰۵	۳۰,۰۰	۳۰,۱۲	۳۰,۰۰	۳۲,۳۵	۲۹,۳۴	۲۹,۰۸	۳۰,۲۷	۲۹,۳۱	۳۰,۸۳	۳۳,۰۵	۳۰,۰۴	SANet[20]
۳۰,۳۷	۳۰,۱۲	۳۰,۰۵	۳۰,۲۵	۲۹,۹۴	۳۲,۴۵	۲۹,۲۵	۲۹,۰۶	۳۰,۱۷	۲۹,۳۰	۳۰,۹۰	۳۳,۲۳	۲۹,۷۹	PSN-U[21]
۳۰,۰۰	۲۹,۶۷	۲۹,۷۰	۲۹,۸۹	۲۹,۰۶	۳۲,۰۰	۲۹,۰۲	۲۸,۸۲	۲۹,۹۴	۲۹,۱۱	۳۰,۴۷	۳۲,۷۹	۲۹,۵۸	روش پیشنهادی
۳۰,۱۰	۲۹,۷۵	۲۹,۸۰	۳۰,۰۳	۲۹,۰۶	۳۲,۱۵	۲۹,۱۲	۲۸,۹۲	۳۰,۰۸	۲۹,۰۶	۳۰,۶۳	۳۲,۹۳	۲۹,۶۲	PANet-B
۵۰=σ													سطح نویز
۲۶,۷۲	۲۶,۴۶	۲۶,۸۱	۲۶,۷۸	۲۷,۲۲	۲۹,۰۵	۲۵,۹۰	۲۵,۱۰	۲۵,۸۲	۲۵,۰۴	۲۶,۶۸	۲۹,۶۹	۲۶,۱۳	BM3D[4]
۲۷,۰۵	۲۶,۶۴	۲۶,۹۴	۲۶,۹۷	۲۷,۷۹	۲۹,۲۵	۲۶,۱۴	۲۵,۴۲	۲۶,۳۲	۲۵,۴۴	۲۶,۹۵	۳۰,۳۳	۲۶,۴۵	WNNM[8]
۲۶,۴۷	۲۶,۳۰	۲۶,۷۹	۲۶,۷۴	۲۴,۸۳	۲۸,۶۸	۲۵,۹۵	۲۵,۳۱	۲۵,۹۴	۲۵,۱۲	۲۶,۸۰	۲۹,۱۲	۲۶,۱۰	EPLL[10]
۲۶,۷۸	۲۶,۶۷	۲۷,۰۶	۲۷,۰۳	۲۵,۲۴	۲۹,۳۲	۲۶,۱۲	۲۵,۵۶	۲۶,۲۶	۲۵,۴۳	۲۶,۶۸	۲۹,۶۴	۲۶,۳۷	MLP[24]
۲۶,۸۱	۲۶,۵۰	۲۶,۹۸	۲۶,۹۴	۲۵,۷۰	۲۸,۹۳	۲۶,۱۶	۲۵,۵۹	۲۶,۳۱	۲۵,۴۲	۲۷,۱۰	۲۹,۴۸	۲۶,۶۲	TNRD[17]
۲۷,۰۹	۲۶,۸۰	۲۷,۱۱	۲۷,۲۰	۲۶,۳۷	۲۹,۲۲	۲۶,۱۸	۲۵,۷۱	۲۶,۶۴	۲۵,۵۲	۲۷,۲۷	۲۹,۹۳	۲۶,۹۲	SANet[20]
۲۷,۳۰	۲۷,۰۴	۲۷,۲۳	۲۷,۲۷	۲۶,۵۶	۲۹,۵۴	۲۶,۶۲	۲۵,۸۹	۲۶,۹۳	۲۵,۶۳	۲۷,۵۳	۳۰,۲۱	۲۷,۲۱	PSN-U[21]
۲۶,۸۸	۲۶,۵۷	۲۶,۹۷	۲۷,۰۲	۲۵,۲۰	۲۹,۰۲	۲۶,۱۹	۲۵,۵۷	۲۶,۵۵	۲۵,۴۸	۲۷,۲۵	۲۹,۸۳	۲۶,۹۶	روش پیشنهادی
۲۶,۹۱	۲۶,۶۰	۲۶,۹۷	۲۷,۰۶	۲۵,۳۷	۲۹,۱۰	۲۶,۱۹	۲۵,۵۸	۲۶,۵۷	۲۵,۴۵	۲۷,۲۴	۲۹,۹۱	۲۶,۸۸	PANet-B

جدول (۴) : مقدار و میانگین PSNR روی تصاویر با نویز حقیقی


تنظیمات دوربین	GAT-BM3D[18]	CBM3D[4]	TID[13]	CSF[9]	DnCNN[6]	MWDCNN[2]	روش پیشنهادی
Canon 5D ISO=3200	۳۱,۲۳	۳۹,۷۶	۳۷,۲۲	۳۵,۶۸	۳۷,۲۶	۳۶,۹۷	۳۶,۳۵
	۳۰,۵۵	۳۶,۴۰	۳۴,۵۴	۳۴,۰۳	۳۴,۸۷	۳۶,۰۱	۳۵,۰۲
	۲۷,۷۴	۳۶,۳۷	۳۴,۲۵	۳۲,۶۳	۳۴,۰۹	۳۴,۸۰	۳۵,۳۸
Nikon D600 ISO=3200	۲۸,۵۵	۳۴,۱۸	۳۲,۹۹	۳۱,۷۸	۳۳,۶۲	۳۳,۹۱	۳۶,۴۷
	۳۲,۰۱	۳۵,۰۷	۳۴,۲۰	۳۵,۱۶	۳۴,۴۸	۳۴,۸۸	۳۷,۹۸
	۳۹,۷۸	۳۷,۱۳	۳۵,۵۸	۳۹,۹۸	۳۵,۴۱	۳۷,۰۲	۳۸,۱۳
Nikon D800 ISO=1600	۳۲,۲۴	۳۶,۸۱	۳۴,۴۹	۳۴,۸۴	۳۷,۹۵	۳۷,۹۳	۳۶,۶۸
	۳۳,۸۶	۳۷,۷۶	۳۵,۱۹	۳۸,۴۲	۳۶,۰۸	۳۷,۴۹	۳۷,۵۵
	۳۳,۹۰	۳۷,۵۱	۳۵,۲۶	۳۵,۷۹	۳۵,۴۸	۳۸,۴۴	۳۶,۶۲
Nikon D800 ISO=3200	۳۶,۴۹	۳۵,۰۵	۳۳,۷۰	۳۸,۳۶	۳۴,۰۸	۳۷,۱۰	۳۶,۹۵
	۳۲,۹۱	۳۴,۰۷	۳۱,۰۴	۳۵,۵۳	۳۳,۷۰	۳۶,۷۲	۳۷,۷۱
	۴۰,۲۰	۳۴,۴۲	۳۳,۰۷	۴۰,۰۵	۳۳,۳۱	۳۷,۲۵	۳۶,۰۸
Nikon D800 ISO=6400	۲۹,۸۴	۳۱,۱۳	۲۹,۴۰	۳۴,۰۸	۲۹,۸۳	۳۲,۲۴	۳۴,۷۵
	۲۷,۹۴	۳۱,۲۲	۲۹,۸۶	۳۲,۱۳	۳۰,۵۵	۳۲,۵۶	۳۴,۲۵
	۲۹,۱۵	۳۰,۹۷	۲۹,۲۱	۳۱,۵۲	۳۰,۰۹	۳۲,۷۶	۳۵,۱۸
میانگین	۳۲,۴۳	۳۵,۱۹	۳۳,۳۶	۳۵,۳۳	۳۳,۸۶	۳۵,۷۴	۳۶,۳۴

جدول (۵) : مقایسه تعداد پارامترها

روش	تعداد پارامترها	GFLOPs
IPT[3]	۱۱۴M	۳۳
SUNet[5]	۹۹M	۳۰
DnCNN[6]	۰,۵۶M	۰,۹۴
RED30[14]	۴,۱۳M	۱۰,۳۳
روش پیشنهادی	۱,۰۸M	۲,۱۹



شکل (۹): نمونه ای از تصاویر پایگاه داده prinstone رنگی و خاکستری



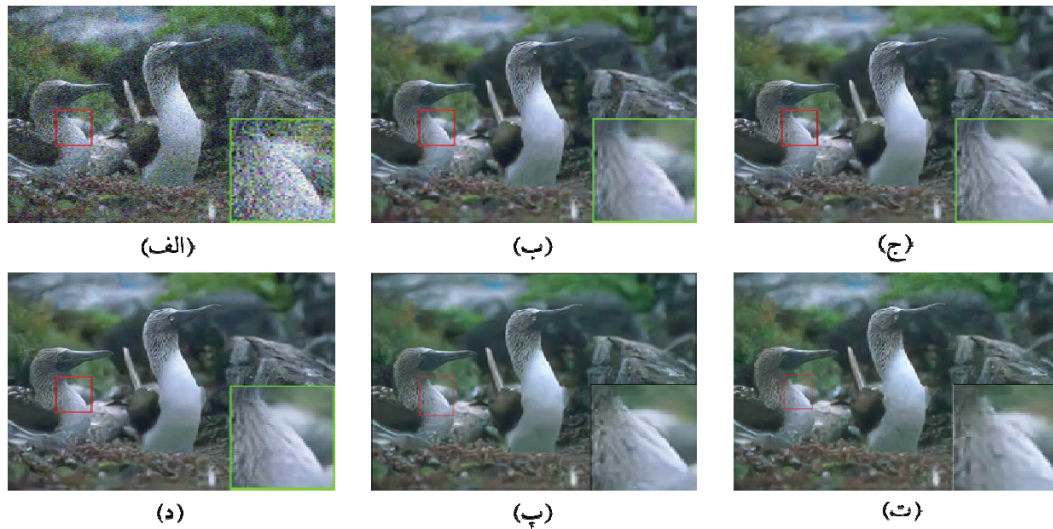
شکل (۱۰): تصاویر پایگاه داده CC

با مقدار PSNR بدست آمده 32.56 db نشان می‌دهد، (د) با مقدار DnCNN با مقدار 33.39 db، (ف) FFDNet با 32.94 db، (ر) IRCNN با مقدار 33.20 db، (س) روش پیشنهادی با نویز کور که 32.50 db و (ش) روش پیشنهادی با نویز مشخص می‌باشد که 33.29 db نشان داده شده است، در تمامی این روش‌ها بجز مورد (د) روش پیشنهادی در بالاترین رتبه می‌باشد. در شکل (۱۳) که تصویر هواپیما از پایگاه داده BSD68 می‌باشد با سطح نویز ۲۵ که در قسمت (الف) تصویر نویزی دیده می‌شود، در (ب) تصویر اصلی بدون نویز، (ر) اثر حذف نویز با روش TNRD با مقدار PSNR برابر 37.83 db، روش DnCNN در (ف) با بالاترین مقدار یعنی 38.35 db، سایر روش‌ها مثل (ج) EPLL مقدار 37.21 db، (د) WNNM با مقدار 37.26 db نشان داده شده است، در این نمونه تصویر، روش پیشنهادی (س) مقدار 38.21 db در نویز مشخص و برای نویز کور هم همانطور که در (ش) آمده مقدار 38.03 db نمایش داده شده است که فقط حدود 0.14 db از DnCNN مقدار کمتری داشته و به لحاظ بصری نیز قابل قبول می‌باشد.


۳-۵-۴- بررسی بصری تصاویر حذف نویز شده

همانگونه که در شکل (۱۱) دیده می‌شود اثر حذف نویز بر روی یک نمونه تصویر رنگی از پایگاه داده CBSD68 با سطح نویز ۳۵ اعمال شده که در بخش (الف) تصویر نویزی قابل مشاهده است و روش‌های مختلف حذف نویز شامل BM3D در (ب) با مقدار PSNR 30.52 db، روش‌های IRCNN و FFDNet در (ج) و (د) نیز با مقدار یکسان 31.00 db میزان حذف نویز یکسانی از تصویر پرنده را نشان می‌دهند که با بررسی تصویر حذف نویز شده به روش پیشنهادی و سایر تصاویر، نتیجه می‌شود که روش پیشنهادی در (پ) با توجه به مقدار 30.98 db که حاصل شده است از نظر بصری نیز بسیار قابل قبول بوده و می‌توان از آن برای سایر کاربردهای پردازشی بهره برد، در تصویر (ت) اثر حذف نویز با روش حذف نویز کور حدود 0.2 db کمتر از مقدار با نویز مشخص می‌باشد و در کل نتایج در حد قابل قبولی می‌باشند. شکل (۱۲) مربوط به یک تصویر قایق از پایگاه داده Kodak24 می‌باشد که بخش (الف) تصویر آغشته به نویز با سطح ۳۵ را نشان می‌دهد، (ب) تصویر اصلی می‌باشد، (ج) روش CBM3D


در شکل (۱۴) نیز اثر حذف نویز در یکی از تصاویر پایگاه داده SET12 (تصاویر سطح خاکستری) تصویر ستاره دریایی، با روش‌های مختلفی نشان داده شده است، در قسمت (الف) تصویر نویزی مشاهده می‌شود، به ترتیب در (ب) حذف نویز به روش BM3D که مقدار PSNR برابر 31.14 db می‌باشد، در (ج) و (د) به ترتیب روش‌های IRCNN و FFDNet با مقدار 31.93 db، (پ) روش پیشنهادی PANet با مقدار 31.93 db، (ت) روش پیشنهادی PANet_B برای نویز کور که مقدار 31.71 db را نشان می‌دهد، که روش پیشنهادی از نظر بصری قابل قبول بوده و ساختار و جزئیات را نیز به خوبی حفظ می‌کند.




شکل (۱۱): مقایسه بصری تصویر رنگی با نویز گاوسی و سطح نویز ۳۵ از پایگاه داده CBSD68 با روشهای مختلف. (الف) تصویر نویزی (ب) BM3D/30.52db (ج) IRCNN/31.00db (د) FFDNet/31.00db (پ) PANet/30.98db (ت) PANet_B/30.79db



شکل (۱۲): مقایسه بصری تصویر رنگی با نویز گاوسی و سطح نویز ۳۵ روی یک تصویر از پایگاه داده Kodak24 با چندین روش: (الف) تصویر نویزی (ب) تصویر اصلی (ج) CBM3D/32.56db (د) DnCNN 33.39db (ه) FFDNet/32.94db (و) PANet/33.29db (ز) IRCNN/33.20db (س) PANet_B/32.50db



شکل (۱۳): مقایسه بصری تصویر رنگی با نویز گاوسی و سطح نویز ۲۵ روی یک تصویر از پایگاه داده BSD68 با چندین روش مختلف: (الف) تصویر نویزی (ب) تصویر اصلی (ر TNRD 37.83db (ف DnCNN 38.35db (ج EPLL 37.21db (د WNNM 37.26db (س PANet/38.21db (ش PANet_B/38.03db



شکل (۱۴): مقایسه بصری تصویر خاکستری با نویز گاوسی و سطح نویز ۱۵ از پایگاه داده SET12 با روشهای مختلف. (الف) تصویر نویزی (ب) BM3D/31.14db (ج IRCNN/32.02db (د FFDNet/32.02db (پ PANet/31.93db (ت PANet_B/31.71db

۵- نتیجه گیری

در این مقاله، یک روش جدید برای حذف نویز از تصویر ارائه گردید. روش پیشنهادی دو شبکه بطور موازی برای استخراج ویژگی‌های گوناگون به کار برد، تا توانایی ارائه ویژگی‌های آموزش دیده را برای عمل حذف نویز افزایش دهد. مکانیزم توجه بکار رفته در این روش باعث شد عملکرد حذف نویز با استخراج ویژگی‌های محلی و سراسری و اتصال آنها بهتر عمل کند و ویژگی‌های برجسته‌تری را بدست آورد تا جزئیات دقیقتری را برای تصاویر با نویز پیچیده بازیابی کند. همچنین با کمک بلوک‌های فشرده‌ساز افزونگی اطلاعات، کاهش یافته، به نحوی که هزینه محاسبات و حافظه مصرفی کاهش می‌یابد. آزمایشات انجام شده، کیفیت بصری بالا و قدرت بالای روش پیشنهادی در حذف نویز حقیقی نسبت به سایر روشها و راندمان محاسباتی را اثبات می‌کنند. در آینده با تنظیم خودکار ابرپارامترهای شبکه‌های عصبی نیز می‌توان به دقت و کارایی بالاتری در حوزه حذف نویز دست یافت که امروزه نیز با ساخت خودکار شبکه‌های عصبی برای برخی کارهای خاص موفقیت‌هایی نیز کسب شده است. لذا با توسعه روش پیشنهادی می‌توان آن را برای سایر کارهای بینایی سطح پایین مورد استفاده قرار داد.

مراجع:

- Schmidt, U. and S. Roth. *Shrinkage fields for effective image restoration*. in *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2014.
- Zoran, D. and Y. Weiss. *From learning models of natural image patches to whole image restoration*. in *2011 international conference on computer vision*. 2011. IEEE.
- He, W., et al., *Hyperspectral image denoising using local low-rank matrix recovery and global spatial-spectral total variation*. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2018. **11**(3): p. 713-729.
- He, W., et al., *Hyperspectral image denoising via noise-adjusted iterative low-rank matrix approximation*. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2015. **8**(6): p. 3050-3061.
- Luo, E., S.H. Chan, and T.Q. Nguyen, *Adaptive image denoising by targeted databases*. *IEEE transactions on image processing*, 2015. **24**(7): p. 2167-2181.
- Mao, X., C. Shen, and Y.-B. Yang, *Image restoration using very deep convolutional encoder-decoder networks with symmetric skip connections*. *Advances in neural information processing systems*, 2016. **29**.
- Zhang, K., et al. *Learning deep CNN denoiser prior for image restoration*. in *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2017.
- Pires, R.G., et al. *Image denoising using attention-residual convolutional neural networks*. in *2020 33rd SIBGRAPI Conference on Graphics, Patterns and Images (SIBGRAPI)*. 2020. Ieee.
- Chen, Y. and T. Pock, *Trainable nonlinear reaction diffusion: A flexible framework for fast and effective image restoration*. *IEEE transactions on pattern analysis and machine intelligence*, 2016. **39**(6): p. 1256-1272.
- Makitalo, M. and A. Foi, *Optimal inversion of the generalized Anscombe transformation for Poisson-Gaussian noise*. *IEEE transactions on image processing*, 2012. **22**(1): p. 91-103.
- Pan, J., et al. *Learning dual convolutional neural networks for low-level vision*. in *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2018.
- Zhang, L., et al., *A separation-aggregation network for image denoising*. *Applied Soft Computing*, 2019. **83**: p. 105603.
- Aljadaany, R., D.K. Pal, and M. Savvides. *Proximal splitting networks for image restoration*. in *International Conference on Image Analysis and Recognition*. 2019. Springer.
- Malfait, M. and D. Roose, *Wavelet-based image denoising using a Markov random field a priori model*. *IEEE Transactions on image processing*, 1997. **6**(4): p. 549-565.
- Mairal, J., et al. *Non-local sparse models for image restoration*. in *2009 IEEE 12th international conference on computer vision*. 2009. IEEE.
- Woo, S., et al. *Cbam: Convolutional block attention module*. in *Proceedings of the European conference on computer vision (ECCV)*. 2018.
- Tian, C., et al., *Multi-stage image denoising with the wavelet transform*. *Pattern Recognition*, 2023. **134**: p. 109050.
- Chen, H., et al. *Pre-trained image processing transformer*. in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2021.
- Dabov, K., et al., *Image denoising by sparse 3-D transform-domain collaborative filtering*. *IEEE Transactions on image processing*, 2007. **16**(8): p. 2080-2095.
- Fan, C.-M., T.-J. Liu, and K.-H. Liu, *SUNet: Swin Transformer UNet for Image Denoising*. arXiv preprint arXiv:2202.14009, 2022.
- 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.
- Zhang, K., W. Zuo, and L. Zhang, *FFDNet: Toward a fast and flexible solution for CNN-based image denoising*. *IEEE Transactions on Image Processing*, 2018. **27**(9): p. 4608-4622.
- Gu, S., et al. *Weighted nuclear norm minimization with application to image denoising*. in *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2014.

41. Cao, C., et al. *Look and think twice: Capturing top-down visual attention with feedback convolutional neural networks*. in *Proceedings of the IEEE international conference on computer vision*. 2015.
42. Jaderberg, M., K. Simonyan, and A. Zisserman, *Spatial transformer networks*. *Advances in neural information processing systems*, 2015. 28.
43. Miech, A., I. Laptev, and J. Sivic, *Learnable pooling with context gating for video classification*. arXiv preprint arXiv:1706.06905, 2017.
44. Bluche, T., *Joint line segmentation and transcription for end-to-end handwritten paragraph recognition*. *Advances in neural information processing systems*, 2016. 29.
45. Ba, J., V. Mnih, and K. Kavukcuoglu, *Multiple object recognition with visual attention*. arXiv preprint arXiv:1412.7755, 2014.
46. Bahdanau, D., K. Cho, and Y. Bengio, *Neural machine translation by jointly learning to align and translate*. arXiv preprint arXiv:1409.0473, 2014.
47. Gregor, K., et al. *Draw: A recurrent neural network for image generation*. in *International conference on machine learning*. 2015. PMLR.
48. Xu, K., et al. *Show, attend and tell: Neural image caption generation with visual attention*. in *International conference on machine learning*. 2015. PMLR.
49. Chen, C., et al. *Deep boosting for image denoising*. in *Proceedings of the European Conference on Computer Vision (ECCV)*. 2018.
50. Roth, S. and M.J. Black, *Fields of experts*. *International Journal of Computer Vision*, 2009. 82(2): p. 205–229.
51. Franzen, R., *Kodak lossless true color image suite*. source: <http://r0k.us/graphics/kodak>, 1999. 4(2).
52. Nam, S., et al. *A holistic approach to cross-channel image noise modeling and its application to image denoising*. in *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2016.
53. Huang, D.-A., et al., *Self-learning based image decomposition with applications to single image denoising*. *IEEE Transactions on multimedia*, 2013. 16(1): p. 83–93.
54. Zhang, K., W. Zuo, and L. Zhang. *Learning a single convolutional super-resolution network for multiple degradations*. in *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2018.
55. Wang, Z., et al., *Image quality assessment: from error visibility to structural similarity*. *IEEE transactions on image processing*, 2004. 13(4): p. 600–612.
56. Geng, M., et al., *Content-noise complementary learning for medical image denoising*. *IEEE Transactions on Medical Imaging*, 2021. 41(2): p. 407–419.
24. Ahn, N., B. Kang, and K.-A. Sohn. *Fast, accurate, and lightweight super-resolution with cascading residual network*. in *Proceedings of the European conference on computer vision (ECCV)*. 2018.
25. Xu, J., et al. *Multi-channel weighted nuclear norm minimization for real color image denoising*. in *Proceedings of the IEEE international conference on computer vision*. 2017.
26. Zhang, Y., et al., *Residual non-local attention networks for image restoration*. arXiv preprint arXiv:1903.10082, 2019.
27. Hu, J., L. Shen, and G. Sun. *Squeeze-and-excitation networks*. in *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2018.
28. Chen, Y., et al., *A²-nets: Double attention networks*. *Advances in neural information processing systems*, 2018. 31.
29. LeCun, Y., et al., *Gradient-based learning applied to document recognition*. *Proceedings of the IEEE*, 1998. 86(11): p. 2278–2324.
30. He, K., et al. *Deep residual learning for image recognition*. in *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2016.
31. Szegedy, C., et al. *Inception-v4, inception-resnet and the impact of residual connections on learning*. in *Thirty-first AAAI conference on artificial intelligence*. 2017.
32. Xie, S., et al. *Aggregated residual transformations for deep neural networks*. in *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2017.
33. Zagoruyko, S. and N. Komodakis, *Wide residual networks*. arXiv preprint arXiv:1605.07146, 2016.
34. Simonyan, K. and A. Zisserman, *Very deep convolutional networks for large-scale image recognition*. arXiv preprint arXiv:1409.1556, 2014.
35. Szegedy, C., et al. *Going deeper with convolutions*. in *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2015.
36. Chollet, F. *Xception: Deep learning with depthwise separable convolutions*. in *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2017.
37. ن. جعفری نویمی پور، رتبه‌بندی و and نباهت، م. ف. مدرس خیابانی انتخاب فیلتر مناسب کاهش نویز گاوسی با روش تاپسیس. مجله ماشین ۸. ۲۰۲۱. (4): p. 37–50.
38. Ioffe, S. and C. Szegedy. *Batch normalization: Accelerating deep network training by reducing internal covariate shift*. in *International conference on machine learning*. 2015. PMLR.
39. Mnih, V., N. Heess, and A. Graves, *Recurrent models of visual attention*. *Advances in neural information processing systems*, 2014. 27.
40. Wang, F., et al. *Residual attention network for image classification*. in *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2017.



مرتضی یوسفی در سال ۱۳۸۵ مدرک کارشناسی خود را در رشته مهندسی برق - الکترونیک از دانشگاه آزاد اسلامی واحد زاهدان اخذ کرده است. در سال ۱۳۹۲ مدرک کارشناسی ارشد خود را در رشته مهندسی برق الکترونیک از دانشگاه سیستان و بلوچستان اخذ و هم اکنون در حال تحصیل می باشد. زمینه های مورد علاقه ایشان هوش مصنوعی و پردازش تصاویر دیجیتال می باشد.



وحید مهرداد مدرک کارشناسی و کارشناسی ارشد خود را به ترتیب در سالهای ۱۳۸۶ و ۱۳۸۸ در رشته مهندسی برق-الکترونیک از دانشگاه شهید رجایی تهران اخذ کرد. همچنین مدرک دکترای خود را در رشته مهندسی برق-مخابرات سیستم در سال ۱۳۹۴ از دانشگاه صنعتی سهند تبریز دریافت کرد. زمینه های پژوهشی مورد علاقه ایشان پردازش تصویر، پردازش مدل های سه بعدی، ماشین بینایی و شناسایی الگو بوده و در حال حاضر عضو هیئت علمی با مرتبه استادیار در دانشکده فنی مهندسی دانشگاه لرستان است.