

## Water-HybNet: یک شبکه عصبی عمیق ترکیبی برای بهبود کیفیت تصاویر زیر آب

مهدی هاشم‌زاده\*

دانشیار دانشکده فناوری اطلاعات و مهندسی کامپیوتر دانشگاه شهید مدنی آذربایجان، تبریز، ایران hashemzadeh@azaruniv.ac.ir

امیررضا عباسی

کارشناس ارشد مهندسی کامپیوتر، دانشکده فناوری اطلاعات و مهندسی کامپیوتر دانشگاه شهید مدنی آذربایجان، تبریز، ایران  
amirtr764@gmail.com

جلیل قویدل نیچران

استادیار دانشکده فناوری اطلاعات و مهندسی کامپیوتر دانشگاه شهید مدنی آذربایجان، تبریز، ایران  
j.ghavidel@azaruniv.ac.ir

### چکیده

با کاربرد مورد هدف، و نیز بهره‌گیری از ترکیب مناسبی از کانال‌های تاثیرگذار تصویر در استخراج نقشه اطمینان، نوآوری‌های اصلی این پژوهش هستند. Water-HybNet بر روی مجموعه داده استاندارد UIEB، شامل ۹۵۰ تصویر واقعی از زیر آب، آزمایش شده و با استفاده از معیارهای مرجع کامل PSNR، MSE و SSIM با دیگر روش‌های به‌روز مقایسه می‌شود. در کنار نتایج بصری که نشان دهنده بهبود قابل ملاحظه در ساختار و بافت تصاویر خروجی در مقایسه با روش‌های موجود است، در ارزیابی کمی نتایج نیز این سامانه در معیار PSNR، MSE و SSIM به ترتیب امتیازهای ۱۹/۶۵، ۰/۷۵۶ و ۰/۸۲۸۴ را کسب می‌کند که بالاترین امتیاز کسب شده در مقایسه با سایر روش‌ها است. به طوری که بهبود ۴ درصدی در تمامی معیارهای مورد مقایسه نسبت به موفق‌ترین روش مبتنی بر یادگیری عمیق را دارد و بهبود ۱۱ درصدی در معیار PSNR، بهبود ۶ درصدی در معیار SSIM و بهبود ۴۹ درصدی در معیار

تصاویر زیر آب علی‌رغم این که می‌توانند کاربردهای صنعتی و علمی ارزشمندی داشته باشند، اغلب کیفیت نامطلوبی دارند، به طوری که اکثر عملیات پردازش تصویر و بینایی ماشین روی آن‌ها همواره با چالش مواجه است. در این پژوهش، سامانه‌ای با عنوان Water-HybNet برای بهبود کیفیت تصاویر زیر آب معرفی می‌شود. برای این سامانه یک شبکه عصبی عمیق ترکیبی، جهت یادگیری استخراج یک نقشه اطمینان کارآمد در فرایند بهبود کیفیت تصاویر، طراحی شده است. به منظور تولید یک نقشه اطمینان مطلوب، علاوه بر تصویر خام ورودی، از کانال‌های تعادل سفید، متعادل‌سازی هیستوگرام و تصحیح گاما نیز استفاده می‌شود. همچنین برای اصلاح و بهبود ورودی‌های شبکه، از واحدهای پردازشی کوچکی برای کاهش هاله‌ها و مصنوعات موجود در تصاویر استفاده می‌شود. طراحی معماری Water-HybNet، منطبق

\* نویسنده مسئول

MSE نسبت به موفق‌ترین روش کلاسیک موجود را کسب می‌کند.

**واژه‌های کلیدی:** شبکه‌های عصبی عمیق، افزایش کیفیت تصویر، شبکه عصبی هم‌آمیختگی<sup>۱</sup>، تصاویر زیر آب، یادگیری عمیق.

#### ۱- مقدمه

تصویربرداری از زیر آب یکی از ابزارهای مهم و مورد علاقه در شاخه‌های مختلف فناوری و تحقیقات علمی مرتبط با اشیای زیر آب، مانند بازرسی از سازه‌ها و کابل‌ها، تشخیص اشیاء، کنترل وسایل نقلیه، تحقیقات زیست‌شناسی دریایی و باستانشناسی، نظارت دریایی، ردیابی اهداف و حفاظت از محیط زیست است [۱]. یک تصویر واضح پیش‌شرط اساسی درک سناریوهای دنیای واقعی در محیط کدر زیر آب است، اما تصاویر زیر آب دارای مشکلاتی از جمله روشنایی غیریکنواخت<sup>۲</sup>، جذب<sup>۳</sup> رنگ، ظاهر مه‌آلود<sup>۴</sup>، پراکندگی نور<sup>۵</sup>، روشنایی مصنوعی<sup>۶</sup> و تغییر رنگ<sup>۷</sup> هستند، که به طور جدی بر عمل اکتشاف در محیط زیر آب تأثیر می‌گذارند. از میان مشکلات فوق «جذب رنگ» و «پراکندگی نور» دو مسئله مهم در تصویربرداری نوری زیر آب هستند [۲].

پدیده جذب رنگ ناشی از وابستگی حرکت نور در آب به طول موج طیف رنگی است که باعث می‌شود تصاویر تهیه شده در زیر آب، از لحاظ تباین<sup>۸</sup> و دقت رنگ کیفیت مناسبی نداشته باشند و اطلاعات مهمی از تصویر حذف گردد. همچنین در اثر پراکندگی نور، جهت انتشار نور توسط ذرات معلق در آب دچار تغییر می‌شود، این پدیده منجر به ظاهر مه‌آلود و تخریب تباین شده و اجسامی که فاصله نسبی آن‌ها از دوربین زیاد است به شکل مه‌آلود و

کم‌نور در تصویر ثبت می‌شوند، هاله‌های نور غیرطبیعی نیز به دلیل پراکندگی نور در تصاویر زیر آب ایجاد می‌شوند [۲].

روش‌های پردازش تصویر متفاوتی برای افزایش کیفیت تصاویر زیر آب ارائه شده‌اند که می‌توان آن‌ها را به دو دسته کلی طبقه‌بندی کرد: (۱) روش‌های ترمیم تصویر و (۲) روش‌های بهبود تصویر [۳]. ترمیم تصویر روی مرمت تصاویر ورودی با استفاده از یک مدل ساخت یافته بر روی تصویر اصلی تمرکز دارد. در حالی که روش‌های بهبود تصویر از معیارهای کیفی برای تولید تصاویری با کیفیت بالا استفاده می‌کنند [۳]. در بخش بعدی، هر یک از این دسته روش‌ها و راهکارهای موجود در هر دسته بررسی می‌شوند. نتایج تحقیقات و کارهای پیشین نشان می‌دهد که به‌طور کلی روش‌های ترمیم تصویر ممکن است پوشش‌های رنگی را نادیده گرفته یا در مهار نوفه موفق نباشند [۳]. همچنین اکثر روش‌های بهبود تصویر نیز نیازمند سیستم‌های سخت‌افزاری پیچیده و گران هستند و انرژی زیادی مصرف می‌کنند و با وجود بهبودهایی که بر روی تصویر ایجاد می‌کنند، همچنان در حذف اثر پراکندگی یا برطرف کردن مشکلات رنگ ناتوان هستند [۳].

در طی دهه گذشته، فناوری یادگیری عمیق موفقیت‌های چشم‌گیری در کاربردهای مختلف یادگیری ماشین به ویژه در حوزه پردازش تصویر و بینایی ماشین از خود نشان داده است. این فناوری در زمینه بخش‌بندی تصویر، تشخیص هدف و مه‌زدایی<sup>۹</sup> تصویر و دیگر کاربردها به کرات استفاده شده است. در حوزه بهبود تصاویر زیر آب نیز برخی روش‌های مبتنی بر یادگیری عمیق ارائه شده‌اند [۴-۸]. نتایج این پژوهش‌ها نشان می‌دهد که تصاویر بهبود یافته با روش‌های یادگیری عمیق در مقایسه با روش‌های قبلی از کیفیت بهتری برخوردارند. اگرچه در اغلب این روش‌ها، تصاویر حاصل شده دارای کنتراست و اعوجاج رنگ پایینی هستند، و این مشکلات با توسعه مداوم یادگیری عمیق تا حدودی حل شده است [۹]. با این حال، این روش‌ها

1- convolution  
2- Nonuniform Illumination  
3- Absorption  
4- Turbid  
5- Light Scattering  
6- Artificial Lighting  
7- Color Change  
8- Contrast

9- Dehaze

نیازمند دستگاه‌های سخت‌افزاری قدرتمند و مجموعه داده آموزشی با تعداد نمونه کافی نیز هستند. همچنین طراحی یک معماری مناسب یادگیری عمیق یک چالش اساسی است. داده‌های آموزشی مناسب یکی از نیازهای اساسی روش‌های مبتنی بر یادگیری عمیق هستند و فقدان مجموعه داده مناسب در اوایل دهه اخیر استفاده از این روش‌ها را در زمینه بهبود تصاویر زیر آب با چالش مواجه کرده بود، اما در سال‌های اخیر با ارائه مجموعه داده‌هایی نظیر UIEB در مرجع [۸] تا حدودی این مشکل مرتفع شده است. در این مرجع، با استفاده از این مجموعه تصاویر، یک مطالعه جامع در مورد وضعیت الگوریتم‌های مختلف تصاویر زیر آب از نظر کیفی و کمی انجام شده است. ولی همچنان لازم است یک معماری کارآمد از شبکه‌های عصبی عمیق متناسب با کاربرد مورد هدف طراحی شود.

در این پژوهش، یک معماری ترکیبی جدید و کارآمد با عنوان Water-HybNet برای بهبود کیفیت تصاویر زیر آب معرفی می‌شود که علاوه بر استفاده از داده‌های آموزشی مناسب، دارای یک ساختار چندگانه برای اصلاح و بازگرداندن جزئیات و رنگ طبیعی به تصاویر زیر آب است. Water-HybNet شامل یک معماری شبکه عصبی عمیق چندگانه است که از آن برای یادگیری استخراج یک نقشه اطمینان<sup>۱۰</sup> برای بهبود کیفیت تصویر استفاده می‌کند. نقشه اطمینان دانش حاصل از اطلاعات پیشین و تکرار و اجرای یک الگوریتم است. در روش پیشنهادی نیز، نقشه اطمینان شامل مهم‌ترین ویژگی‌های استخراج شده از تصویر ورودی است که تاثیرگذار در کیفیت تصویر خروجی باشند. معماری پیشنهادی علاوه بر تصویر خام ورودی، از کانال‌های تعادل سفید، متعادل‌سازی هیستوگرام و تصحیح گاما<sup>۱۱</sup> (GC) نیز استفاده میکند تا یک نقشه اطمینان مطلوب را تولید کند. همچنین برای اصلاح و بهبود ورودی‌های شبکه، از واحدهای پردازشی کوچکی برای کاهش هاله‌ها و مصنوعات موجود در تصاویر استفاده می‌کند. طراحی

10- Confidence map  
11- Gamma Correction

ترکیبی معماری Water-HybNet، منطبق با کاربرد مورد هدف و همچنین بهره‌گیری از ترکیب مناسبی از کانال‌های تاثیرگذار تصویر برای استخراج نقشه اطمینان، منتج به یک روش کارآمد بهبود کیفیت تصاویر زیر آب شده است، که می‌تواند سرآغاز پژوهش‌های بیشتر در این حوزه نیز باشد. Water-HybNet بر روی مجموعه داده UIEB، شامل ۹۵۰ تصویر واقعی از زیر آب، آزمایش شده و با استفاده از معیارهای مرجع کامل<sup>۱۲</sup> PSNR [۱۰]،<sup>۱۳</sup> SSIM [۱۱] و<sup>۱۴</sup> MSE [۱۰] با دیگر روش‌های به‌روز مقایسه می‌شود. در ارزیابی کمی نتایج، سامانه Water-HybNet در معیارهای PSNR، MSE و SSIM به ترتیب امتیازهای ۱۹/۶۵، ۰/۷۵۶ و ۰/۸۲۸۴ را کسب می‌کند که نسبت به موفق‌ترین روش مبتنی بر یادگیری عمیق (یعنی Water-Net [۸]) در تمامی معیارهای مورد مقایسه بهبود حدوداً ۴ درصدی و نسبت به موفق‌ترین روش کلاسیک (یعنی Fusion-based [۱۲]) بهبود ۱۱ درصدی در معیار PSNR، بهبود ۴۹ درصدی در معیار MSE، و بهبود ۶ درصدی در معیار SSIM به‌دست آورده است.

در ادامه، در بخش ۲ کارهای پیشین انجام شده در حوزه افزایش کیفیت تصاویر زیر آب به اجمال مرور و بررسی می‌شوند، در بخش ۳ جزئیات طراحی و پیاده‌سازی روش پیشنهادی ارائه می‌شود، در بخش ۴، نتایج آزمایش‌های انجام شده برای ارزیابی روش پیشنهادی و مقایسه آن با سایر روش‌ها ارائه می‌گردد، و نهایتاً در بخش ۵ نتیجه‌گیری و کارهای آتی بحث می‌شوند.

## ۲- کارهای مرتبط

در این بخش مروری بر کارهای گذشته در حوزه بهبود کیفیت تصاویر زیر آب انجام می‌شود. همان‌طور که در بخش قبلی ذکر شد روش‌های افزایش کیفیت تصاویر زیر آب را می‌توان به دو دسته، روش‌های ترمیم یا بازیابی تصویر و روش‌های بهبود تصویر، طبقه‌بندی کرد [۳].

12- Peak signal-to-noise ratio  
13- Structural similarity index measure  
14- Mean squared error

در ادامه، هر یک از این دو دسته روش معرفی شده و روش‌های موجود در هر دسته مرور می‌شوند.

## ۲-۱- روش‌های ترمیم تصویر

روش‌های ترمیم تصویر با مطالعه ساز و کار فیزیکی تخریب تصاویر زیر آب، یک مدل فیزیکی مناسب برای بهبود آن‌ها ایجاد می‌کنند. این روش‌ها شامل روش‌های تصویربرداری نوری<sup>۱۵</sup>، روش‌های مبتنی بر ویژگی‌های پولاریزاسیون<sup>۱۶</sup> و روش‌های مبتنی بر دانش پیشین<sup>۱۷</sup> است. هو و همکاران [۱۳] مدل تصویربرداری نوری را با یک روش سنتی ترمیم تصویر ترکیب کردند. روش آن‌ها بر این فرض استوار بود که تار شدن تصاویر زیر آب به دلیل پراکندگی نور اجسام در آب و ذرات معلق ایجاد می‌شود. این روش بر اساس برآورد پارامترهای پراکندگی نور، تصویر زیر آب را با روش واهم‌میختی<sup>۱۸</sup> بازیابی می‌کند. ون و همکاران [۱۴] یک مدل جدید تصویربرداری نوری زیر آب ارائه کردند و میزان پراکندگی و نور پس‌زمینه را تخمین زدند. این روش قادر به بازیابی تصاویر نزدیک به صحنه است، ولی تأثیر پراکندگی زیر آب و فاصله منبع نور زیر آب تا دوربین را بر روی فاصله تصویربرداری در نظر نمی‌گیرد.

تصویربرداری پولاریزاسیون به دلیل مزایای اجتناب از پراکندگی و جذب نور، برای ترمیم تصویر زیر آب مناسب بوده است و در سال‌های اخیر به طور گسترده‌ای برای ترمیم تصاویر زیر آب استفاده شده‌اند [۱۵]. هو و همکاران [۱۶] یک روش ترمیم تصویر زیر آب بر اساس تصحیح عبور با تغییر در پولاریزاسیون پیشنهاد کردند. این روش می‌تواند به طور مؤثر کیفیت تصاویر زیر آب را بهبود بخشد. با اینحال، روش‌های مبتنی بر ویژگی‌های پولاریزاسیون نیاز به سخت‌افزار تخصصی و دو یا چند تصویر با درجات مختلف پولاریزاسیون دارند. متأسفانه این سیستم‌های سخت‌افزار بسیار پیچیده و گران قیمت

بوده و انرژی زیادی نیز مصرف می‌کنند [۱۵].

از جمله روش‌های مبتنی بر دانش پیشین، هی و همکاران [۱۷] پیشنهاد کردند که کانال تاریک پیشین<sup>۱۹</sup> (DCP) برای ترمیم تصویر تخریب شده با مه استفاده شود [۱۸]. آن‌ها به این نکته پی بردند که برای هر ناحیه محلی از یک تصویر بدون مه، حداقل یک کانال رنگی با مقادیر پیکسل نزدیک به صفر وجود دارد. پنگ و همکاران [۱۹] یک کانال تاریک تعمیم یافته (GDCP) برای بازیابی تصویر پیشنهاد کردند که تصحیح رنگ تطبیقی را در مدل شکل‌گیری تصویر گنجانده است. گالدران و همکاران [۲۰] یک روش بازسازی خودکار تصاویر قرمز در زیر آب را پیشنهاد کردند که میرایی ۲۰ کانال قرمز و تأثیر منبع نور مصنوعی بر روی تخمین انتقال را کاهش داده است. برمن و همکاران [۲۱] با تخمین نسبت‌های میرایی کانال‌های رنگی آبی-قرمز و آبی-سبز، مشکل ترمیم تصویر زیر آب را به یک تصویر فاقد مه کاهش دادند. نتایج تجزیه و تحلیل روش‌های مبتنی بر دانش پیشین نشان می‌دهد که اگر چه این روش‌ها به طور مؤثر کیفیت تصاویر را بهبود می‌بخشند، اما نیازمند استفاده از کانال تاریک پیشین، خط مه یا خط رنگ هستند. متأسفانه دانش پیشین به طور مستقیم نتیجه بازیابی را تعیین می‌کند. در نتیجه کسب دانش قبلی برای این روش‌ها ضروری است [۹].

## ۲-۲- روش‌های بهبود تصویر

روش‌های بهبود تصویر، به جای مطالعه مستقیم فیزیک تخریب تصویر در محیط پیچیده زیر آب، بیشتر بر روی تصویر تخریب شده تمرکز می‌کنند. این روش‌ها شامل رویکردهای کلاسیک از قبیل روش‌های مبتنی بر حوزه فرکانس<sup>۲۱</sup>، روش‌های مبتنی بر حوزه فضایی<sup>۲۲</sup>، روش‌های مبتنی بر ثبات رنگ<sup>۲۳</sup>، روش‌های مبتنی بر همجوشی<sup>۲۴</sup> و رویکردهای مبتنی بر یادگیری عمیق<sup>۲۵</sup>

19- Dark Channel Prior  
20- Attenuation  
21- Frequency domain  
22- Spatial domain  
23- Color Constancy  
24- Fusion  
25- Deep learning

15- Optical Imaging-Base  
16- Polarization Characteristics  
17- Prior Knowledge-Base  
18- Deconvolution

هستند [۹]. روش‌های مبتنی بر حوزه فرکانس برای بهبود تصاویر، آن‌ها را با هم‌آمیزی یا تبدیل فضایی پردازش می‌کنند. سان و همکاران [۲۲] روش نوفه‌زدایی تصویر زیر آب بر اساس تجزیه موجک و فیلتر بالا گذر، پیشنهاد کردند و نوفه پس‌پراکندگی زیر آب را بر اساس آن حذف کردند. روش‌های مبتنی بر حوزه فرکانس به طور مؤثر نوفه را حذف می‌کنند اما در مورد افزایش کنتراست و تصحیح رنگ تصاویر نسبت به سایر روش‌ها نمی‌توانند نتایج مطلوبی به دست آورند. در نتیجه این روش‌ها کمتر مورد مطالعه قرار گرفته‌اند [۹]. روش حوزه فضایی بر اساس نگاشت سطح خاکستری کار می‌کند که می‌تواند با تغییر محدوده دینامیکی تصویر، کنتراست و جزئیات تصاویر را افزایش دهد. فرآیند افزایش حوزه فضایی همان متعادل‌سازی هیستوگرام<sup>۲۶</sup> (HE) است [۲۳]. از آنجا که این روش برای همه پیکسل‌ها پردازش یکسان انجام می‌دهد، معمولاً ویژگی‌های محلی را نادیده می‌گیرد. از این‌رو، ابتدا جزئیات تصویر اصلی را قبل از اجرای متعادل‌سازی هیستوگرام ذخیره می‌کنند و سپس این جزئیات به فرآیند متعادل‌سازی هیستوگرام اضافه می‌شود [۹].

لی و همکاران [۲۴] یک روش بهبود تصویر زیر آب را بر اساس اصل حداقل از دست دادن اطلاعات و توزیع هیستوگرام پیشنهاد کردند. پنگ و همکاران [۲۵] نیز یک روش تخمین عمق بر اساس تاروی تصویر و جذب نور پیشنهاد کردند که در یک مدل تشکیل تصویر زیر آب برای بهبود تصاویر زیر آب استفاده می‌شود. برخی از روش‌های دیگر نیز از مدل رتینکس<sup>۲۷</sup> استفاده می‌کنند. فو و همکاران [۲۶] یک روش مبتنی بر رتینکس برای بهبود تصویر زیر آب پیشنهاد کردند که شامل تصحیح رنگ، تجزیه لایه و بهبود است. از تعادل سفید<sup>۲۸</sup> (WB) بیشتر برای حل مشکل پوشش رنگی اشیاء در شرایط مختلف نوری استفاده می‌شود. این روش شامل لبه خاکستری، سایه‌های خاکستری، حداکثر RGB، محیط خاکستری و

26- Histogram Equalization

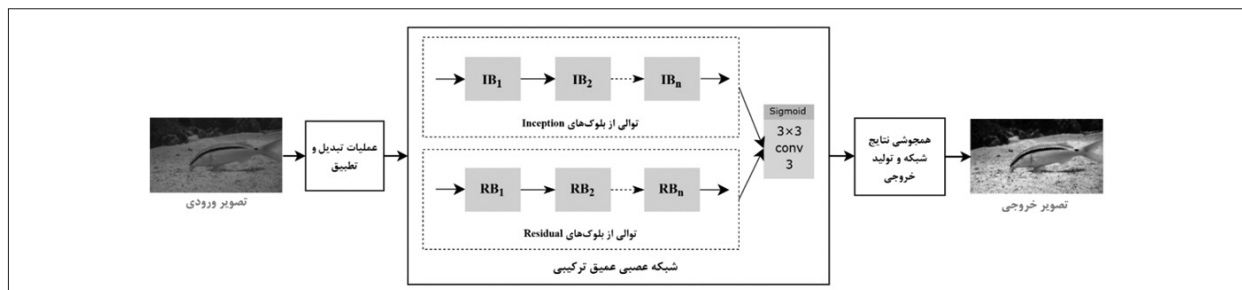
27- Retinex

28- White Balance

لبه خاکستری وزن‌دار است. این روش‌ها کیفیت بصری تصویر را در صورت کافی نبودن نور، بهبود می‌بخشند. تجزیه و تحلیل این دسته از روش‌های بهبود تصویر نشان می‌دهد که استفاده از رتینکس به تنهایی باعث بهبود اندکی در کیفیت تصاویر زیر آب می‌شود. بنابراین فضای رنگی RGB به فضای رنگی LAB یا HSV تبدیل شده و با کشش کنتراست، متعادل‌سازی هیستوگرام، تصحیح رنگ و سایر روش‌ها تصویر زیر آب بهبود می‌یابد.

روش‌های مبتنی بر همجوشی نیز بیشتر از نظر اصلاح رنگ، افزایش جزئیات، کشش کنتراست، تعادل رنگ و سایر جنبه‌ها مورد توجه هستند. قوانین همجوشی بیشتر بر اساس هرم گاوسی یا هرم لاپلاسی [۱۲، ۲۷] استوار هستند. یک روش ترکیبی توسط آنکوتی و همکاران [۱۲] پیشنهاد شده است که ابتدا عملیات تعادل سفید، تصحیح رنگ و افزایش کنتراست را بر روی تصویر ورودی اعمال می‌کند و از خروجی این سه عمل به عنوان اجزای عملیات همجوشی تصویر استفاده می‌کند. در نهایت با استفاده از نقشه‌های وزنی و عملیات همجوشی، تصویر بهبود یافته حاصل می‌شود. نتایج تجزیه و تحلیل برای روش‌های مبتنی بر همجوشی عملکرد موفق این روش در کاهش نوفه و بازیابی لبه‌ها را نشان می‌دهد. با این حال روش‌های مبتنی بر همجوشی نیازمند به دست آوردن تصاویر همجوشی متعدد و وزن‌های همجوشی هستند که محاسبه آنها مشکل است [۹].

فناوری یادگیری عمیق به دلیل ساختار شبکه عصبی عمیق، قابلیت استخراج ویژگی بهتری دارد. بنابراین به‌طور گسترده در زمینه بخش‌بندی تصویر، تشخیص هدف و مه‌زدایی تصویر استفاده می‌شود [۲۸-۳۲]. وانگ و همکاران [۴] روش بهبود تصویر زیر آب را بر اساس شبکه عصبی هم‌آمیزی (CNN) پیشنهاد کردند که روش‌نمایی و کنتراست تصویر زیر آب را بهبود می‌بخشد. لی و همکاران [۷] یک روش شبکه عصبی هم‌آمیزی تصاویر عمیق زیر آب بر اساس صحنه‌های زیر آب طراحی کردند. این شبکه در



شکل ۱: نمای کلی روش پیشنهادی

علاوه بر تصویر خام ورودی، برخی تصاویر تبدیل شده (یا تطبیق شده) از تصویر ورودی برای ورود به شبکه عصبی فراهم شود. تصاویر حاصل وارد «شبکه عصبی عمیق ترکیبی» می‌شوند، که از چندین بلوک متوالی شبکه Inception [۳۴] و چندین بلوک متوالی شبکه Residual [۳۵] تشکیل شده است. این شبکه عصبی عمیق ترکیبی برای استخراج یک نقشه اطمینان مناسب برای بهبود کیفیت تصویر ورودی آموزش داده شده است. نقشه اطمینان شامل مهم‌ترین ویژگی‌های استخراج شده از تصویر ورودی است که در کیفیت تصویر خروجی تأثیرگذار هستند. شبکه عصبی طراحی شده چندین نقشه اطمینان تولید می‌کند (با استفاده از تصاویر تعادل سفید، تصحیح گاما، و متعادل‌سازی هیستوگرام) که در مرحله «همجوشی نتایج شبکه و تولید خروجی» با همدیگر ترکیب شده و تصویر خروجی را تولید می‌کنند. به هنگام عمل همجوشی و تولید خروجی، از واحدهای پردازشی کوچکی برای کاهش هاله‌ها و مصنوعات موجود در تصاویر نیز استفاده می‌شود. در ادامه، جزئیات مربوط به هر یک از مراحل ذکر شده ارائه می‌شود.

### ۳-۱- عملیات تبدیل و تطبیق

به دلیل محیط پیچیده زیر آب و شرایط نوری خاص آن، تاکنون الگوریتم جامعی برای انواع گوناگون تصاویر زیر آب ارائه نشده است. از این‌رو، روش‌های مبتنی بر همجوشی [۱۲] به نتایج مناسبی دست یافته‌اند. این روش‌ها از ورودی‌های مشتق شده توسط چندین عملیات پیش‌پردازش و بهره‌گیری از یک راهبرد همجوشی سود

صحنه‌های مختلف زیر آب به خوبی عمل می‌کند، همچنین به راحتی برای فیلم‌های زیر آب و بهبود کیفیت قاب به قاب نیز توسعه یافته است. گائو و همکاران [۶] یک الگوریتم بلوک متراکم چند مقیاسی (MSDB) به نام DenseGAN را معرفی کردند که از اتصالات متراکم، یادگیری باقیمانده و شبکه چند مقیاسی برای بهبود تصاویر زیر آب استفاده می‌کند. مولد در ابتدا از دو توالی هم‌آمیخت، نرمال‌سازی دسته‌ای (BN) و Leaky ReLU (LReLU) و سپس دو بلوک BN، MSDB و LReLU تشکیل می‌شود. در پایان نیز یک لایه واهم‌آمیخت و یک لایه TanH وجود دارد. اخیراً، یک مدل انتقال رنگ زیر آب با نظارت ضعیف [۵] (یعنی Water CycleGAN) بر اساس شبکه‌های متخاضم CycleConsistent [۳۳] پیشنهاد شد. این مدل شبکه با بهره‌مندی از معماری شبکه متخاضم، باعث بهبود در عملکرد شبکه می‌شود. لی و همکاران با الهام از روش‌های بهبود تصویر زیر آب مبتنی بر همجوشی یک شبکه عصبی کانولوشنی به نام Water-Net برای بهبود تصویر زیر آب پیشنهاد کردند [۸]، که یک شبکه عصبی تمام هم‌آمیختی ReLU چند مقیاسی است که از ۱۴ لایه هم‌آمیختی ReLU به غیر از آخرین لایه تشکیل می‌شود.

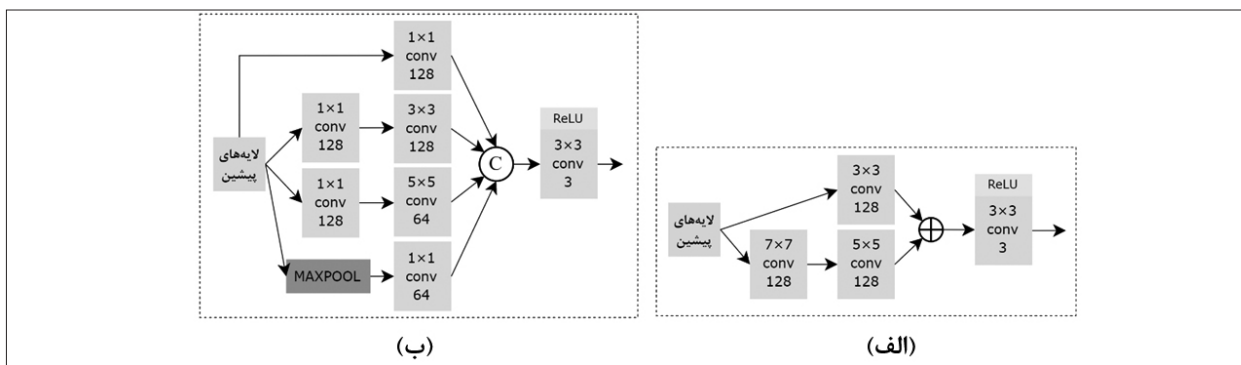
### ۳- روش پیشنهادی

در این پژوهش، یک مدل ترکیبی مبتنی بر CNN به نام Water-HybNet برای بهبود تصاویر زیر آب پیشنهاد می‌شود. نمای کلی روش پیشنهادی در شکل (۱) نشان داده شده است. در روش پیشنهادی، ابتدا برخی «عملیات تبدیل و تطبیق» بر روی تصویر ورودی انجام می‌شود تا





شکل ۲: عملیات تبدیل و تطبیق. (الف) تصویر خام ورودی، (ب) تعادل سفید، (ج) تصحیح گاما، و (د) متعادل سازی هیستوگرام



شکل ۳: ساختار بلوک‌های (الف) Residual (RB) و (ب) Inception (IB)

متشکل از چندین بلوک متوالی از شبکه‌های Inception و Residual است که کانال‌های مذکور به صورت جداگانه این شبکه را تغذیه می‌کنند. بلوک Inception از چهار لایه هم‌آمیختگی با اندازه  $1 \times 1$ ، دو لایه هم‌آمیختگی با اندازه  $5 \times 5$  و  $3 \times 3$  به همراه یک لایه MaxPool  $3 \times 3$  تشکیل شده است که در انتها بعد از اتصال این لایه‌ها با یکدیگر از یک لایه هم‌آمیختگی با اندازه  $3 \times 3$  به همراه فعال‌ساز ReLU عبور می‌کند. دو نوع مختلف از واحد Inception وجود دارد [۳۶]: مدل ساده و مدل کاهش ابعاد، که در شبکه Water-HybNet از مدل کاهش ابعاد استفاده شده است. شبکه Residual نیز از سه لایه هم‌آمیختگی با اندازه  $3 \times 3$ ،  $5 \times 5$  و  $7 \times 7$  به همراه یک لایه هم‌آمیختگی  $3 \times 3$  با فعال‌ساز ReLU تشکیل شده است. خروجی این دو شبکه بعد از عبور از یک لایه هم‌آمیختگی  $3 \times 3$  نقشه‌های اطمینان Water-HybNet را تولید می‌کند. ساختار بلوک‌های Inception و Residual در شکل (۳) نشان داده شده است.

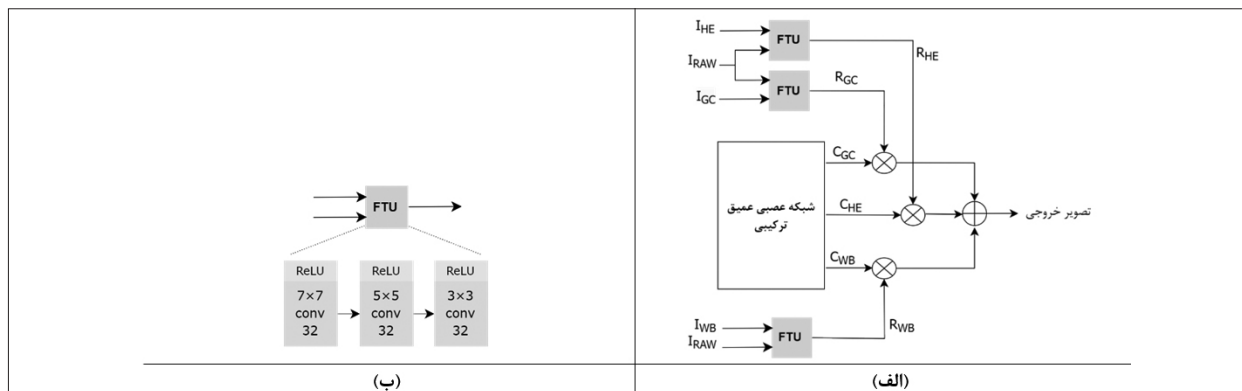
### ۳-۳- همجوشی نتایج شبکه و تولید خروجی

همان‌طور که در شکل (۴-الف) نشان داده شده است بعد از تولید سه نقشه اطمینان  $C_{WB}$ ،  $C_{HE}$  و  $C_{GC}$  توسط شبکه عصبی عمیق ترکیبی، سه واحد تبدیل ویژگی به

می‌برند. در Water-HybNet نیز از این راهبرد استفاده می‌شود. رویکرد پیشنهادی علاوه بر تصویر ورودی، از سه تصویر مشتق شده از آن نیز استفاده می‌کند، بر اساس ویژگی‌های تخریب تصویر زیر آب، سه کانال ورودی شبکه به ترتیب با اعمال الگوریتم‌های تعادل سفید (WB)، متعادل‌سازی هیستوگرام (HE) و تصحیح گاما (GC) روی تصویر ورودی تبدیل و تولید می‌شوند و کانال چهارم تصویر خام ورودی است. تعادل سفید برای تصحیح رنگ‌ها در نظر گرفته می‌شود، و متعادل‌سازی هیستوگرام و تصحیح گاما به ترتیب برای بهبود کنتراست و روشن کردن مناطق تاریک مفید هستند. نمونه‌ای از کانال‌های ایجاد شده از تصویر ورودی در شکل (۲) نمایش داده شده است.

### ۳-۲- شبکه عصبی عمیق ترکیبی

Water-HybNet از یک معماری ترکیبی برای یادگیری سه نقشه اطمینان برای تولید یک تصویر بهبود یافته استفاده می‌کند. این نقشه‌های اطمینان را از تصاویر تعادل سفید، تصحیح گاما، و متعادل‌سازی هیستوگرام تولید می‌کند. همان‌طور که در شکل (۱) نمایش داده شده است، معماری پیشنهادی شامل یک شبکه عصبی عمیق ترکیبی



شکل ۴: (الف) همجوشی نتایج شبکه با واحدهای FTU و تولید خروجی نهایی و (ب) یک واحد FTU

داده شده است. همچنین از عملگر چرخش و دوران تصویر برای به دست آوردن هفت نسخه افزوده شده<sup>۳۰</sup> از داده‌های آموزشی اصلی استفاده شده است. برای کاهش مصنوعات ناشی از توابع زیان<sup>۳۱</sup> مبتنی بر انطباق پیکسل<sup>۳۲</sup> مانند  $L_1$  و  $L_2$ ، تابع زیان ادراکی<sup>۳۳</sup> به عنوان تابع زیان برای یادگیری تابع نگاشت<sup>۳۴</sup> بهبود تصویر استفاده می‌شود [۸]. زیان ادراکی می‌تواند نتایج بصری مناسب و واقعی ایجاد کند که به طور گسترده در ترمیم تصویر و تلفیق شبکه‌ها مانند فراتفکیک‌پذیری تصویر استفاده می‌شود. زیان ادراکی را بر اساس خروجی لایه‌های فعال‌سازی ReLU (یعنی لایه 5\_relu<sub>5</sub>) شبکه ۱۹ لایه‌ای VGG از پیش آموزش دیده شده، مطابق با رابطه (۲) تعریف می‌کنیم [۳۷]. در رابطه (۲)،  $\phi_j(x)$  نشان دهنده آمین لایه هم‌آمیختی (بعد از فعال‌ساز) شبکه VGG از پیش آموزش دیده با مجموعه داده ایمیج نت<sup>۳۵</sup> است [۳۸]. زیان ادراکی به صورت فاصله بین نمایش ویژگی‌های تصویر بهبود یافته  $I_{en}$  و تصویر مرجع  $I_{gt}$  بیان می‌شود:

$$L_j^\phi = \frac{1}{C_j H_j W_j} \sum_{i=1}^N \|\phi_j(I_{en}^i) - \phi_j(I_{gt}^i)\| \quad (2)$$

که در آن مقدار  $N$  اندازه دسته در روند آموزش است. ابعاد نقشه‌های ویژگی آمین لایه کانولوشن در شبکه VGG را نشان می‌دهد.  $C_j$ ،  $H_j$  و  $W_j$  به ترتیب تعداد، ارتفاع و عرض نقشه ویژگی هستند.

نام FTU در این نقشه‌های اطمینان ضرب و با خروجی آنها با هم جمع می‌شود. ورودی‌های FTU شامل تصویر خام به همراه یکی از کانال‌های HE، WB و GC است. واحدهای FTU شامل سه لایه هم‌آمیختی با اندازه  $7 \times 7$ ،  $5 \times 5$  و  $3 \times 3$  هستند. هدف از به کار بردن FTU به منظور کاهش لایه‌های رنگی، پالایش<sup>۳۹</sup> و رفع اختلالات ایجاد شده توسط فرایندهای HE، WB و GC در مرحله تبدیل و تطبیق ورودی است. نمونه‌ای از واحدهای FTU در شکل (۴-ب) نشان داده شده است. مطابق رابطه (۱)، خروجی سه واحد FTU در نقشه‌های اطمینان متناظر ضرب میشوند و نتایج حاصلی با یکدیگر جمع می‌شوند:

(۱)

$$I_{en} = R_{WB} \odot C_{WB} + R_{HE} \odot C_{HE} + R_{GC} \odot C_{GC}$$

که در آن  $I_{en}$  نشان دهنده نتیجه بهبود یافته نهایی بوده و علامت  $\odot$  نشان‌دهنده تولید عنصری ماتریس‌ها است.  $R_{WB}$ ،  $R_{HE}$  و  $R_{GC}$  به ترتیب نتایج پالایش شده الگوریتم‌های HE، WB و GC توسط واحدهای FTU هستند.  $C_{WB}$ ،  $C_{HE}$  و  $C_{GC}$  نیز نقشه‌های اطمینان آموخته شده هستند.

### ۳-۴- آموزش شبکه

برای آموزش مدل پیشنهادی یک مجموعه تصادفی شامل ۸۰۰ جفت از تصاویر مجموعه داده UIEB [۸] مورد استفاده قرار گرفتند. به منظور پائین آوردن بار محاسباتی، ابعاد تصاویر آموزشی به اندازه  $112 \times 112$  تغییر اندازه

30- Augmented  
31- Loss Function  
32- Pixel-Wise  
33- Perceptual  
34- Mapping Function  
35- ImageNet

29- Refine



#### ۴- آزمایش‌ها و نتایج

در این بخش، ابتدا مجموعه تصاویر استفاده شده در آزمایش‌ها معرفی می‌شود. سپس معیارهای ارزیابی برای سنجش کارایی روش پیشنهادی و مقایسه آن با دیگر روش‌ها تعریف می‌شوند. نهایتاً، نتایج آزمایش‌های انجام شده برای ارزیابی روش پیشنهادی ارائه شده و با روش‌های مختلف بهبود کیفیت تصاویر زیر آب به صورت کمی و کیفی مقایسه می‌شوند.

#### ۴-۱- مجموعه تصاویر

برای آموزش و آزمون Water-HybNet از مجموعه تصاویر UIEB [۸] استفاده می‌شود. این مجموعه شامل ۹۵۰ تصویر واقعی زیر آب است که ۸۹۰ تصویر با مرجع کامل و ۶۰ تصویر دیگر، که مرجع رضایت‌بخشی ندارند، به عنوان تصاویر چالش برانگیز معرفی شده‌اند. برای آموزش Water-HybNet از ۸۰۰ تصویر تصادفی این مجموعه استفاده می‌شود و ۱۵۰ تصویر باقی‌مانده برای آزمون سامانه استفاده می‌شوند.

#### ۴-۲- معیارهای ارزیابی

به منظور ارزیابی کمی عملکرد روش پیشنهادی، معیارهای مرجع کامل<sup>۳۶</sup> SSIM، PSNR و MSE بر روی مجموعه داده‌های آزمون استفاده می‌شوند. این معیارها بر اساس روابط ذیل محاسبه می‌شوند:

$$PSNR = 20 \log_{10} \left( \frac{\max(Y(i,j))}{MSE} \right) \quad (۳)$$

$$SSIM(I, \hat{I}) = \left( \frac{2\mu_I \mu_{\hat{I}} + C_1}{\mu_I^2 + \mu_{\hat{I}}^2 + C_1} \right)^\alpha \cdot \left( \frac{2\sigma_I \sigma_{\hat{I}} + C_2}{\sigma_I^2 + \sigma_{\hat{I}}^2 + C_2} \right)^\beta \cdot \left( \frac{\sigma_{I\hat{I}} + C_3}{\sigma_I \sigma_{\hat{I}} + C_3} \right)^\gamma \quad (۴)$$

$$MSE = \frac{1}{MN} \sum_{n=0}^M \sum_{m=1}^N [\hat{g}(x,y) - g(x,y)]^2 \quad (۵)$$

معیار PSNR نشان دهنده نسبت حداکثر توان سیگنال (داده) به توان نویز موجود در تصویر است که توسط رابطه (۳) تعریف می‌شود. در این رابطه،  $Y(i,j)$  نشان دهنده تصویر ورودی است. محدوده این معیار بین صفر تا ۱۰۰ است. معیار SSIM دو تصویر  $\hat{I}$  و  $I$  مطابق رابطه

36- Full-reference Metrics

(۴) تعریف می‌شود. در این رابطه،  $\mu_I$  و  $\sigma_I$  به ترتیب میانگین و انحراف معیار تصویر اصلی، و  $\mu_{\hat{I}}$  و  $\sigma_{\hat{I}}$  میانگین و انحراف معیار تصویر فشرده شده است.  $\sigma_{I\hat{I}}$  همبستگی متقابل بین دو تصویر  $\hat{I}$  و  $I$  بوده و پارامترهای  $\alpha$ ،  $\beta$  و  $\gamma$  برای وزن‌دهی هر تابع استفاده می‌شوند. پارامترهای  $C_1$ ،  $C_2$  و  $C_3$  ثابت‌های کوچک و مثبتی هستند که برای جلوگیری از ناپایداری محاسباتی، زمانی که مخرج کسر عدد کوچکی است به کار می‌روند. برای این پارامترها اغلب برای سادگی، مقدار یک در نظر گرفته می‌شود. محدوده معیار SSIM بین صفر و یک است. خطای میانگین مربعات (MSE) بین دو تصویر  $g(x,y)$  و  $\hat{g}(x,y)$  به صورت رابطه (۵) تعریف می‌شود. در روابط فوق،  $M$  و  $N$  نشان دهنده ابعاد تصویر،  $i$  و  $j$  موقعیت مکانی هر پیکسل،  $X$  تصویر ورودی و  $Y$  تصویر خروجی را نمایش می‌دهد.

نتایج ارزیابی کیفیت تصاویر مرجع کامل با استفاده از تصاویر مرجع تا حدود زیادی می‌تواند عملکرد واقعی روش پیشنهادی را تعیین کند. امتیاز بالا برای PSNR و امتیاز پایین برای MSE نشان دهنده این است که تصاویر خروجی به تصاویر مرجع نزدیکتر هستند. در حالی که امتیاز بالاتر برای SSIM به معنی این است که خروجی از نظر ساختار و بافت تصویر شبیه به تصویر مرجع است.

#### ۴-۳- پیاده‌سازی

Water-HybNet با زبان برنامه‌نویسی پایتون و با استفاده از کتابخانه یادگیری عمیق تنسورفلو<sup>۳۷</sup> نسخه ۱،۱۵ در محیط برنامه‌نویسی کولب<sup>۳۸</sup> برنامه‌نویسی و اجرا شده است. در حین آموزش شبکه عصبی، از روش یادگیری دسته‌های با اندازه دسته ۱۶ استفاده شده است. همچنین از بهینه‌ساز آدام<sup>۳۹</sup> با پارامترهای پیش‌فرض برای بهینه‌سازی شبکه بهره گرفته شده است. نرخ یادگیری<sup>۴۰</sup> به مقدار  $1e^{-3}$  مقداردهی و در هر ده هزار تکرار، ۰/۱ سرعت یادگیری کاهش داده می‌شود. جزئیات پیکربندی

37- Tensorflow  
38- Colab  
39- Adam  
40- Learning Rate

جدول ۱: جزئیات پیکربندی شبکه عصبی عمیق ترکیبی استفاده شده در Water-HybNet

پارامتر	مرحله آموزش	مرحله آزمون
تعداد لایه	۲ لایه Inception ۳ لایه Residual	۲ لایه Inception ۳ لایه Residual
تعداد دوره	۸۰	۸۰
تعداد دسته	۱۶	۱۶

شبکه عصبی عمیق ترکیبی پیشنهادی، شامل تعداد لایه‌ها و دوره‌های آموزشی شبکه و تعداد دسته، در جدول (۱) خلاصه شده است.

#### ۴-۱- آزمایش ۱: مقایسه کیفی نتایج روش پیشنهادی با روش‌های کلاسیک بهبود تصاویر زیر آب


در این بخش، نتایج روش پیشنهادی بر روی مجموعه تصاویر UIEB با روش‌های کلاسیک از جمله Fusion-based [۱۲]، Retinex-based [۲۶]، GDCP [۱۹]، Histogram-prior [۲۴] و Blurriness-based [۲۵] مقایسه می‌شود. برای بررسی کارایی روش‌ها در شرایط مختلف، تصاویر موجود در مجموعه آزمون به سه دسته تقسیم می‌شوند: (۱) تصاویر مایل به سبز/آبی، (۲) تصاویر رو به جلو<sup>۱</sup>، و (۳) تصاویر با صحنه‌های با پس پراکندگی<sup>۲</sup> زیاد. در آب‌های آزاد، ابتدا نور قرمز به دلیل طول موج بلندتر ناپدید می‌شود و به دنبال آن نور سبز و سپس نور آبی [۳۹]. این ترتیب میرایی، منجر به تصاویر مایل به رنگ سبز یا مایل به رنگ آبی می‌شود. نمونه‌هایی از این تصاویر در سطر «تصویر خام» در شکل (۵) نشان داده شده است. از تصاویر رو به جلو نیز که دارای جزئیات بیشتر از محیط زیر آب و همچنین تصاویر با پس پراکندگی زیاد که شامل تصاویری با فاصله بیشتر دوربین با صحنه و کنتراست کم و دارای مه هستند، برای مقایسه استفاده شده است. نمونه‌ای از این تصاویر در سطر «تصویر خام» در شکل (۶) نشان داده شده است.

شکل (۵) نتایج عملکرد Water-HybNet را به صورت کیفی (بصری) با پنج روش دیگر بر روی برخی تصاویر مایل به رنگ سبز یا مایل به رنگ آبی مقایسه می‌کند.

41- forward looking  
42- Backscatter

نتایج مربوط به روش‌های دیگر از مراجع مربوطه آورده شده‌اند. همان‌طور که در این شکل مشاهده می‌شود، روش‌های Fusion-based و Histogram-prior به دلیل الگوریتم‌های تصحیح رنگ نادرست و توزیع هیستوگرام پیشین دچار انحراف رنگ مایل به قرمز شده‌اند و در برخی از تصاویر دچار اشباع بیش از حد رنگ شده‌اند. پدیده انحراف رنگ نیز به صورت قابل توجهی بر کیفیت بصری تصاویر زیر آب تاثیر می‌گذارد و حذف آن دشوار است. روش Retinex-based انحراف رنگ را به خوبی حذف کرده است. روش GDCP لایه‌های رنگ را بیشتر کرده و تصاویر تیره‌تر شده‌اند. روش Blurriness-based مثبت ناچیزی روی تصویر دارد و تصاویر خروجی آن مایل به رنگ آبی/سبز هستند. در مقابل، روش پیشنهادی عملکرد مطلوبی داشته و توانسته رنگ‌های اضافی را از تصویر حذف کند و تصاویر خروجی آن در مقایسه با تصاویر مرجع شباهت بصری بیشتری دارند.

شکل (۶) نتایج Water-HybNet را به صورت کیفی با پنج روش دیگر بر روی برخی تصاویر رو به جلو (تصاویر ستون اول و دوم) و برخی تصاویر با پس پراکندگی زیاد (تصاویر ستون سوم و چهارم) مقایسه می‌کند. نتایج مربوط به روش‌های دیگر از مراجع مربوطه آورده شده‌اند. همان‌طور که مشاهده می‌شود، در تصاویر رو به جلو، روش‌های Fusion-based و Retinex-based به طور قابل توجهی اثر مه را از تصویر زیر آب حذف می‌کنند. در حالی که در روش Blurriness-based تا حدودی مه باقی مانده است. در روش GDCP کنتراست و رنگ تصاویر در بعضی تصاویر به هم خورده و تصاویر بیش‌اندازه روشن شده‌اند، و در روش Histogram-prior نیز تصاویر خروجی مایل به رنگ آبی و تیره هستند. اما در روش پیشنهادی تصاویر تولیدی طبیعی‌تر هستند و جزئیات به طور کامل قابل تفکیک است و کنتراست تصاویر نیز قابل قبول است. در مواردی نیز تیرگی برخی نقاط در تصویر تقویت شده است.

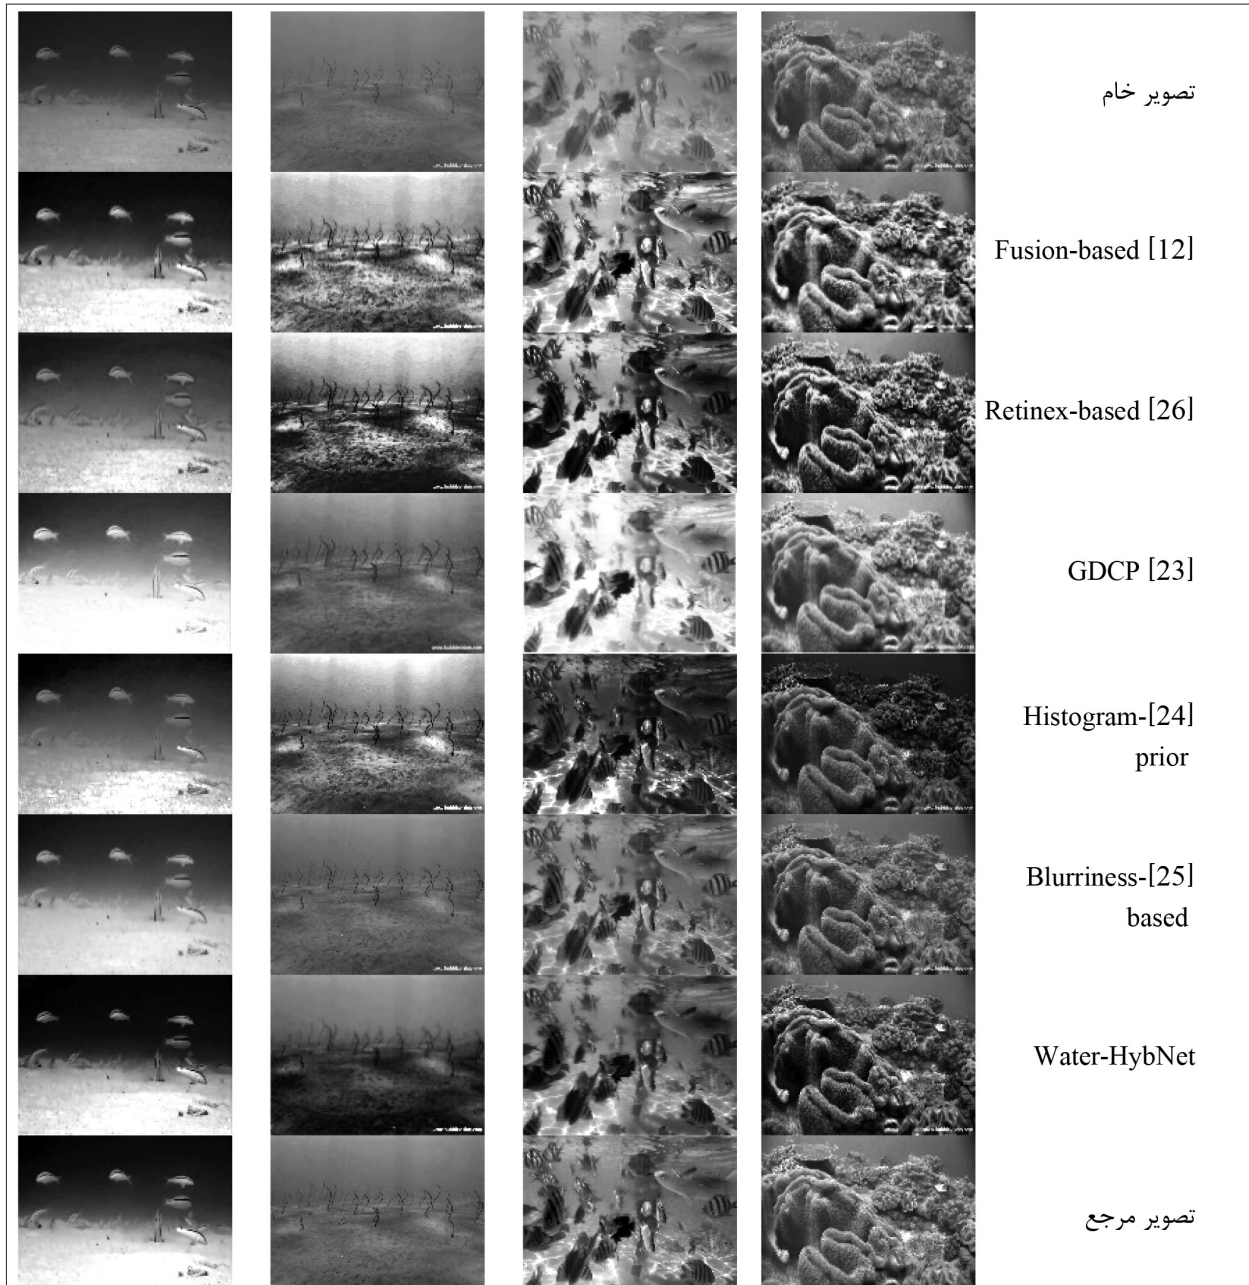


شکل ۵: مقایسه بصری نتایج روش‌های مختلف بر روی تصاویر زیر آب مایل به رنگ سبز/ آبی

به دلیل مدل‌های فیزیکی نادرست و فرضیات مورد استفاده در آن نمی‌تواند اثر پس پراکندگی را حذف کند. در روش Retinex-based، Fusion-based و Histogram-prior نیز با وجود افزایش جزئیات، تصاویر حالت غیر طبیعی پیدا کرده‌اند. در روش Blurriness-based نیز با وجود عملکرد مناسب در تصاویر با پس پراکندگی زیاد در برخی تصاویر هاله‌های نور همچنان وجود دارد. در تصاویر حاصل از Water-HybNet اگرچه در برخی موارد تیرگی کل تصویر

پس پراکندگی زیاد کنتراست تصاویر را کاهش می‌دهد و پوشش مه‌آلود در تصویر زیر آب ایجاد می‌کند. اثر پس پراکندگی به فاصله بین دوربین و صحنه نیز مربوط می‌شود. برای صحنه‌های با پس پراکندگی کم، حذف این اثر نسبتاً آسان است. در مقابل پس پراکندگی زیاد به طور قابل توجهی کیفیت بصری تصاویر زیر آب را کاهش می‌دهد. همان‌طور که در شکل (۶) قابل مشاهده است، تصاویر خروجی روش GDCP دارای هاله‌های نور است و





شکل ۶: مقایسه بصری نتایج روش‌های مختلف بر روی تصاویر زیر آب رو به جلو (ستون اول و دوم) و تصاویر با پس‌پراکندگی زیاد (تصاویر ستون سوم و چهارم)

Retinex-based و Blurriness-based در برخی تصاویر قادر به حذف مه نیستند و رنگ‌ها اغراق‌آمیز است اما این روش‌ها نیز در تصاویر با شرایط خاص تا حدودی موثر هستند. در واقع ایجاد روشی جامع که در تمامی شرایط اثربخشی بسیار خوب داشته باشد مشکل است. اما رویکرد پیشنهادی در بهبود و ترمیم اکثر تصاویر زیر آب مؤثر واقع شده و اثر بخشی لازم را داشته است. استفاده از رویکرد همجوشی و عملیات پیش‌پردازش متناسب با ویژگی‌های

وجود دارد، ولی همچنان جزئیات حفظ گردیده و نسبت به سایر روش‌ها عملکرد مناسبی دارد.

به‌طور کلی، با در نظر گرفتن نتایج حاصل در عموم تصاویر بررسی شده، می‌توان گفت Water-HybNet در مقایسه با روش‌های کلاسیک بهبود تصاویر عملکرد مناسبی بر روی انواع مختلف تصاویر زیر آب از خود نشان داده و تصاویر حاصل در اکثر موارد بسیار شبیه به تصاویر مرجع هستند. اگر چه روش‌های Fusion-based

تخریب تصویر زیر آب و به کارگیری الگوریتم‌های تعادل سفید، تصحیح گاما و متعادل‌سازی هیستوگرام باعث شده‌اند Water-HybNet بتواند در مقایسه با سایر روش‌های کلاسیک، در تصاویر مایل به رنگ‌های اضافی، رنگ‌های آبی و سبز را از تصاویر حذف کند و همچنین جزئیات بیشتر و هاله‌های مه کمتری در تصاویر رو به جلو و تصاویر با پس‌پراکندگی زیاد مشاهده شود.

#### ۴-۵- آزمایش ۲: مقایسه کیفی نتایج روش پیشنهادی با روش‌های مبتنی بر یادگیری عمیق

در این بخش، نتایج روش پیشنهادی، علاوه بر روش‌های قبلی با روش‌های مبتنی بر یادگیری عمیق موجود نیز مقایسه می‌شوند. این روش‌ها شامل Water CycleGAN [۵]، Dense GAN [۶] و Water-Net [۸] هستند. نتایج این آزمایش در شکل (۷) ارائه شده است. همچنین در این مقایسه از تصاویر چالش‌برانگیز مجموعه داده (تصاویر فاقد مرجع) نیز استفاده شده است (ستون چهارم و پنجم). همانگونه که در این شکل مشاهده می‌شود، Water-HybNet توانسته است مه را از همه تصاویر تا حدود زیادی حذف کند و هاله‌های رنگی را از بین ببرد و جزئیات بهتر و کامل‌تری نسبت به سایر روش‌ها ارائه دهد. در حالی که تصاویر خروجی روش‌های دیگر دارای رنگ‌های اضافی هستند. روش‌های مبتنی بر یادگیری عمیق مانند Dense GAN و Water CycleGAN نیز توانسته‌اند رنگ‌های غیرطبیعی تصاویر خام را حذف کنند. ولی در مقابل رنگ‌های غیر طبیعی دیگری به تصویر اضافه کرده و جزئیات در برخی از نواحی تصویر تار شده است. نتایج رویکرد پیشنهادی در مقایسه با Water-Net نیز از لحاظ رنگ‌ها متعادل‌تر بوده و کیفیت بصری بهتر و ظاهر طبیعی‌تر دارد. در کنار به کارگیری عملیات همجوشی و عملیات پیش‌پردازش مناسب، استفاده از معماری Inception Residual و در بلوک‌های متوالی به شکل ترکیبی برای به دست آوردن نقشه‌های اطمینان مناسب باعث شده‌اند روش پیشنهادی در رقابت با دیگر روش‌های مبتنی

بر یادگیری عمیق نیز بتواند عملکرد بهتری را از خود نشان دهد.







































#### ۴-۶- آزمایش ۳: مقایسه کمی نتایج روش پیشنهادی با روش‌های کلاسیک و مبتنی بر یادگیری عمیق

در این آزمایش، نتایج حاصل از روش‌های مختلف بر روی تصاویر آزمون را به صورت کمی مقایسه می‌کنیم. همان‌طور که در بخش ۴-۲ مطرح شد، برای این منظور از معیارهای مرجع SSIM، PSNR و MSE استفاده می‌کنیم. نتایج این آزمایش در جدول (۲) گزارش شده است. نتایج مربوط به دیگر روش‌ها از مراجع مربوطه نقل قول شده‌اند. برای مقایسه عادلانه نتایج، شیوه انجام آزمایش‌ها، تصاویر آزمایشی و تعداد نمونه‌های آزمایشی در کلیه روش‌ها و همچنین تابع زیان، بهینه‌ساز شبکه، نرخ یادگیری و تعداد دسته در روش‌های مبتنی بر یادگیری عمیق مورد مقایسه یکسان در نظر گرفته شده است. همانگونه که در این جدول مشاهده می‌شود، Water-HybNet هم در مقایسه با روش‌های کلاسیک و هم در مقایسه با روش‌های یادگیری عمیق نتایج قابل قبولی ارائه کرده است و توانسته در ارزیابی کمی نتایج در هر سه معیار مورد ارزیابی بالاترین امتیاز را کسب کند.

با مقایسه نتایج گزارش شده در جدول (۲)، مشاهده می‌شود Water-HybNet نسبت به روش Water-Net، که در واقع موفق‌ترین روش مبتنی بر یادگیری عمیق است، در هر ۳ معیار مرجع کامل حدود ۴ درصد بهبود عملکرد دارد. همچنین نسبت به روش Fusion-Based (موفق‌ترین روش کلاسیک) در معیار PSNR ۱۱ درصد، در معیار MSE ۴۹ درصد و در معیار SSIM ۶ درصد بهبود حاصل کرده است.

در خصوص علت برتری Water-HybNet در مقایسه با روش‌های کلاسیک و روش‌های مبتنی بر یادگیری عمیق، علاوه بر موارد ذکر شده در تحلیل نتایج آزمایش‌های قبلی، نکته بارز دیگری که می‌توان گفت عبارتست از به کارگیری ترکیبی شبکه‌های Inception و Residual در معماری آن.



				تصویر خام
				Fusion-based [12]
				Retinex-based [26]
				Dense GAN [6]
				Histogram-prior [24]
				Blurriness-based [25]
				Water CycleGAN [5]
				Water-Net [8]
				Water-HybNet
فقد تصویر مرجع	فقد تصویر مرجع			تصویر مرجع

شکل ۷: مقایسه بصری نتایج Water-HybNet با سایر روش‌های کلاسیک و مبتنی بر یادگیری عمیق



جدول ۲: ارزیابی کمی کیفیت تصاویر تولیدی به وسیله روش‌های مختلف با معیارهای MSE، PSNR و SSIM بر روی مجموعه تصاویر آزمون

روش	↓ MSE (×103)	↑ PSNR	↑ SSIM
Fusion-based[12]	۱/۱۲۸۰	۱۷/۶۰۷۷	۰/۷۷۲۱
Retinex-based[26]	۱/۲۹۲۴	۱۷/۰۱۶۸	۰/۶۰۷۱
Histogram-prior[24]	۱/۷۰۱۹	۱۵/۸۲۱۵	۰/۵۳۹۶
Blurriness-based[25]	۱/۹۱۱۱	۱۵/۳۱۸۰	۰/۶۰۲۹
Water CycleGAN[5]	۱/۷۲۹۸	۱۵/۷۵۰۸	۰/۵۲۱۰
Dense GAN[6]	۱/۲۱۵۲	۱۷/۲۸۴۳	۰/۴۴۲۶
Water-Net[8]	۰/۷۹۷۶	۱۹/۱۳۰۰	۰/۷۹۷۱
Water-HybNet	۰/۷۵۶۰	۱۹/۶۵۰۰	۰/۸۲۸۴

مطابق شکل (۱) و شکل (۳)، در شبکه Inception چندین استخراج کننده ویژگی (لایه‌هایی که مقادیر ورودی را دریافت کرده، و به داده برای محاسبات تبدیل می‌کنند) وجود دارند. در شبکه‌های در حال یادگیری که باید از گزینه‌های مختلفی برای حل وظایف استفاده کنند، این نوع لایه‌بندی، به طور غیرمستقیم به عملکرد بهتر شبکه کمک می‌کند. استفاده از بلوک‌های Residual نیز باعث شده‌اند هر سطح از بلوک‌های Residual اطلاعات بیشتری برای استفاده داشته باشد که این عامل نیز باعث بهبود کارایی شبکه می‌شود.

## ۵- نتیجه‌گیری و کارهای آینده

در این مقاله، یک سامانه مبتنی بر شبکه عصبی عمیق ترکیبی به نام Water-HybNet برای بهبود کیفیت تصاویر زیر آب ارائه شد. ساختار شبکه پیشنهادی، دارای یک معماری چندگانه شامل نقشه‌های اطمینان، شبکه‌های Inception و Residual بود. معماری پیشنهادی دارای چندین ورودی بود که به بلوک‌های Residual و Inception به منظور تولید نقشه‌های اطمینان وارد می‌شدند. سپس واحدهای بازتعریف شده از ورودی (FTU) در این نقشه‌های اطمینان ضرب شده و عملیات همجوشی انجام می‌شد تا تصویر خروجی بهبود یافته حاصل شود. روش پیشنهادی قادر بود کیفیت و وضوح طیف وسیعی از

تصاویر زیر آب را به طور قابل ملاحظه‌ای افزایش دهد. استفاده از عملیات تبدیل و تطبیق و به کارگیری واحدهای Residual و Inception برای تولید نقشه‌های اطمینان و انجام عملیات همجوشی نقشه‌های اطمینان باعث ایجاد بهبود قابل ملاحظه در نتایج کمی و کیفی در مقایسه با روش‌های دیگر شد. در مجموع با توجه به نتایج به دست آمده، مشاهده شد که رویکرد پیشنهادی می‌تواند به خوبی رنگ‌های اضافی تصاویر خام را اصلاح کرده و رنگ‌های طبیعی با کنتراست مناسب را به تصاویر بازگرداند. همچنین در تصاویر خروجی جزئیات بیشتری نسبت به روش‌های دیگر قابل مشاهده می‌شود.

همچنان نیاز به مطالعه و پژوهش‌های آتی در این زمینه وجود دارد. به عنوان کارهای آینده می‌توان اندازه مجموعه تصاویر آموزشی و تعداد نقشه‌های اطمینان را افزایش داد. همچنین می‌توان معماری شبکه Water-HybNet را تعمیم داد و از شبکه Inception با معماری متفاوت و Residual چند مقایسی برای فیلتر ویژگی‌ها استفاده نمود.

## مراجع

- [1] S. Anwar and C. Li, "Diving deeper into underwater image enhancement: A survey," *Signal Processing: Image Communication*, vol. 89, p. 115978, 2020.
- [2] R. Schettini and S. Corchs, "Underwater image processing: state of the art of restoration and image enhancement methods," *EURASIP journal on advances in signal processing*, vol. 2010, pp. 1-14, 2010.
- [3] M. Dubreuil, P. Delrot, I. Leonard, A. Alfalou, C. Brosseau, and A. Dogariu, "Exploring underwater target detection by imaging polarimetry and correlation techniques," *Applied optics*, vol. 52, no. 5, pp. 997-1005, 2013.
- [4] Y. Wang, J. Zhang, Y. Cao, and Z. Wang, "A deep CNN method for underwater image enhancement," in *2017 IEEE International Conference on Image Processing (ICIP)*, 2017: IEEE, pp. 1382-1386.
- [5] C. Li, J. Guo, and C. Guo, "Emerging from water: Underwater image color correction based on weakly supervised color transfer," *IEEE Signal processing letters*, vol. 25, no. 3, pp. 323-327, 2018.
- [6] Y. Guo, H. Li, and P. Zhuang, "Underwater image enhancement using a multiscale dense generative adversarial network," *IEEE Journal of Oceanic Engineering*, vol. 45, no. 3, pp. 862-870, 2019.
- [7] C. Li, S. Anwar, and F. Porikli, "Underwater scene prior inspired deep underwater image and video enhancement," *Pattern Recognition*, vol. 98, p. 107038, 2020.
- [8] C. Li et al., "An underwater image enhancement benchmark dataset and beyond," *IEEE Transactions on Image Processing*, vol.

- [25] Y.-T. Peng and P. C. Cosman, "Underwater image restoration based on image blurriness and light absorption," *IEEE transactions on image processing*, vol. 26, no. 4, pp. 1579-1594, 2017.
- [26] X. Fu, P. Zhuang, Y. Huang, Y. Liao, X.-P. Zhang, and X. Ding, "A retinex-based enhancing approach for single underwater image," in *2014 IEEE International Conference on Image Processing (ICIP)*, 2014: IEEE, pp. 4572-4576.
- [27] C. O. Ancuti, C. Ancuti, C. De Vleeschouwer, and P. Bekaert, "Color balance and fusion for underwater image enhancement," *IEEE Transactions on image processing*, vol. 27, no. 1, pp. 379-393, 2017.
- [28] N. Farajzadeh and M. Hashemzadeh, "A deep neural network based framework for restoring the damaged persian pottery via digital inpainting," *Journal of Computational Science*, vol. 56, p. 101486, 2021/11/01/ 2021, doi: <https://doi.org/10.1016/j.jocs.2021.101486>.
- [29] N. Farajzadeh, N. Sadeghzadeh, and M. Hashemzadeh, "A fully-convolutional residual encoder-decoder neural network to localize breast cancer on histopathology images," *Computers in Biology and Medicine*, vol. 147, p. 105698, 2022/08/01/ 2022, doi: <https://doi.org/10.1016/j.combiomed.2022.105698>.
- [30] N. Farajzadeh, N. Sadeghzadeh, and M. Hashemzadeh, "PMG-Net: Persian music genre classification using deep neural networks," *Entertainment Computing*, vol. 44, p. 100518, 2023/01/01/ 2023, doi: <https://doi.org/10.1016/j.entcom.2022.100518>.
- [31] M. Hashemzadeh, N. Farajzadeh, and M. Heydari, "Smoke detection in video using convolutional neural networks and efficient spatio-temporal features," *Applied Soft Computing*, p. 109496, 2022/08/13/ 2022, doi: <https://doi.org/10.1016/j.asoc.2022.109496>.
- [32] A. Hosseini, M. Hashemzadeh, and N. Farajzadeh, "UFS-Net: A unified flame and smoke detection method for early detection of fire in video surveillance applications using CNNs," *Journal of Computational Science*, vol. 61, p. 101638, 2022/05/01/ 2022, doi: <https://doi.org/10.1016/j.jocs.2022.101638>.
- [33] J.-Y. Zhu, T. Park, P. Isola, and A. A. Efros, "Unpaired image-to-image translation using cycle-consistent adversarial networks," in *Proceedings of the IEEE international conference on computer vision*, 2017, pp. 2223-2232.
- [34] C. Szegedy, S. Ioffe, V. Vanhoucke, and A. A. Alemi, "Inception-v4, inception-resnet and the impact of residual connections on learning," in *Thirty-first AAAI conference on artificial intelligence*, 2017.
- [35] S. Zagoruyko and N. Komodakis, "Wide residual networks," *arXiv preprint arXiv:1605.07146*, 2016.
- [36] M. Moniruzzaman, S. M. S. Islam, P. Lavery, and M. Benamoun, "Faster r-cnn based deep learning for seagrass detection from underwater digital images," in *2019 Digital Image Computing: Techniques and Applications (DICTA)*, 2019: IEEE, pp. 1-7.
- [37] K. Simonyan and A. Zisserman, "Very deep convolutional networks for large-scale image recognition," *arXiv preprint arXiv:1409.1556*, 2014.
- [38] J. Deng, W. Dong, R. Socher, L.-J. Li, K. Li, and L. Fei-Fei, "Imagenet: A large-scale hierarchical image database," in *2009 IEEE conference on computer vision and pattern recognition*, 2009: Ieee, pp. 248-255.
- [39] D. Akkaynak, T. Treibitz, T. Shlesinger, Y. Loya, R. Tamir, and D. Iluz, "What is the space of attenuation coefficients in underwater computer vision?," in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2017, pp. 4931-4940.
- [9] W. Zhang, L. Dong, X. Pan, P. Zou, L. Qin, and W. Xu, "A survey of restoration and enhancement for underwater images," *IEEE Access*, vol. 7, pp. 182259-182279, 2019.
- [10] H. Marmolin, "Subjective MSE measures," *IEEE transactions on systems, man, and cybernetics*, vol. 16, no. 3, pp. 486-489, 1986.
- [11] Z. Wang, A. C. Bovik, H. R. Sheikh, and E. P. Simoncelli, "Image quality assessment: from error visibility to structural similarity," *IEEE transactions on image processing*, vol. 13, no. 4, pp. 600-612, 2004.
- [12] C. Ancuti, C. O. Ancuti, T. Haber, and P. Bekaert, "Enhancing underwater images and videos by fusion," in *2012 IEEE conference on computer vision and pattern recognition*, 2012: IEEE, pp. 81-88.
- [13] W. Hou, D. J. Gray, A. D. Weidemann, G. R. Fournier, and J. Forand, "Automated underwater image restoration and retrieval of related optical properties," in *2007 IEEE international geoscience and remote sensing symposium*, 2007: IEEE, pp. 1889-1892.
- [14] H. Wen, Y. Tian, T. Huang, and W. Gao, "Single underwater image enhancement with a new optical model," in *2013 IEEE International Symposium on Circuits and Systems (ISCAS)*, 2013: IEEE, pp. 753-756.
- [15] T. W. Cronin and J. Marshall, "Patterns and properties of polarized light in air and water," *Philosophical Transactions of the Royal Society B: Biological Sciences*, vol. 366, no. 1565, pp. 619-626, 2011.
- [16] H. Hu, L. Zhao, B. Huang, X. Li, H. Wang, and T. Liu, "Enhancing visibility of polarimetric underwater image by transmittance correction," *IEEE Photonics Journal*, vol. 9, no. 3, pp. 1-10, 2017.
- [17] K. He, J. Sun, and X. Tang, "Guided image filtering," *IEEE transactions on pattern analysis and machine intelligence*, vol. 35, no. 6, pp. 1397-1409, 2012.
- [18] J.-M. Guo, J.-y. Syue, V. R. Radzicki, and H. Lee, "An efficient fusion-based defogging," *IEEE Transactions on Image Processing*, vol. 26, no. 9, pp. 4217-4228, 2017.
- [19] Y.-T. Peng, K. Cao, and P. C. Cosman, "Generalization of the dark channel prior for single image restoration," *IEEE Transactions on Image Processing*, vol. 27, no. 6, pp. 2856-2868, 2018.
- [20] A. Galdran, D. Pardo, A. Picón, and A. Alvarez-Gila, "Automatic red-channel underwater image restoration," *Journal of Visual Communication and Image Representation*, vol. 26, pp. 132-145, 2015.
- [21] D. Berman, D. Levy, S. Avidan, and T. Treibitz, "Underwater single image color restoration using haze-lines and a new quantitative dataset," *IEEE transactions on pattern analysis and machine intelligence*, 2020.
- [22] S. Feifei, Z. Xuemeng, and W. Guoyu, "An approach for underwater image denoising via wavelet decomposition and high-pass filter," in *2011 Fourth International Conference on Intelligent Computation Technology and Automation*, 2011, vol. 2: IEEE, pp. 417-420.
- [23] M. Abdullah-Al-Wadud, M. H. Kabir, M. A. A. Dewan, and O. Chae, "A dynamic histogram equalization for image contrast enhancement," *IEEE Transactions on Consumer Electronics*, vol. 53, no. 2, pp. 593-600, 2007.
- [24] C.-Y. Li, J.-C. Guo, R.-M. Cong, Y.-W. Pang, and B. Wang, "Underwater image enhancement by dehazing with minimum information loss and histogram distribution prior," *IEEE Transactions on Image Processing*, vol. 25, no. 12, pp. 5664-5677, 2016.