

استفاده از ShuffleNet برای طراحی یک مدل بخش‌بندی معنایی عمیق به منظور تشخیص نشت نفت در تصاویر رادار روزنه مصنوعی

نسترن آقائی^۱ غلامرضا اکبری زاده^۲ عبدالنبی کوثریان^۳

۱- دانشجوی دکتری- گروه برق، دانشکده مهندسی، دانشگاه شهید چمران اهواز، اهواز، ایران
n-Aghayi@stu.scu.ac.ir

۲- دانشیار- گروه برق، دانشکده مهندسی، دانشگاه شهید چمران اهواز، اهواز، ایران
g.akbari@scu.ac.ir

۳- استاد- گروه برق، دانشکده مهندسی، دانشگاه شهید چمران اهواز، اهواز، ایران
a.kosarian@scu.ac.ir

چکیده: بخش‌بندی معنایی عمیق تصاویر به‌عنوان راه حلی یکپارچه در آنالیز تصاویر مبتنی بر طبقه‌بندی تک‌تک پیکسل‌های تصویر بوده و بخصوص در کاربردهایی مانند شناسایی نشت نفت در آب‌های آزاد که در آن مرز اشیا و نواحی به‌طور مشخص قابل تفکیک نیستند، مورد توجه قرار می‌گیرد. به منظور کنترل هرچه بیشتر آلودگی و مخاطرات زیست محیطی ناشی از نشت نفت، ارائه روش‌هایی با دقت بیشتر از اهمیت ویژه‌ای برخوردار است. تصاویر رادار روزنه مصنوعی در این زمینه بسیار پرکاربرد بوده و با چالش‌هایی از جمله نویز اسپکل و نیز تشخیص نواحی لکه‌نفتی و شبه‌لکه نفتی مواجه هستند. بکارگیری روش‌های نوین یادگیری عمیق می‌تواند در کاهش دخالت سلیقه انسانی در تصمیم‌گیری کمک کند. در این مقاله از روش مخلوط کردن کانال‌های ویژگی در شبکه‌های کانولوشنی عمیق، بلوک‌های آتروس و بخش‌های رمزگشایی استفاده شده است که علاوه بر کاهش پیچیدگی‌های محاسباتی، نتایج بخش‌بندی لکه‌های نفتی به‌مراتب بهتر از سایر روش‌ها می‌دهد. معماری شبکه ارائه شده مبتنی بر معماری Vgg16 می‌باشد. دقت کلی، صحت، همپوشانی بر واحد، IoU وزن‌دار و امتیاز BF به‌عنوان پارامترهای ارزیابی در نظر گرفته شده‌اند. در روش ارائه شده دقت بخش‌بندی لکه‌های نفتی و شبه‌لکه‌های نفتی به‌ترتیب به میزان ۷/۸٪ و ۷/۳٪ نسبت به روش‌های پیشین بهبود یافته است.

واژه‌های کلیدی: مخلوط کردن کانال، شافل‌نت، یادگیری عمیق، بخش‌بندی معنایی، شناسایی لکه‌های نفتی، تصاویر رادار روزنه مصنوعی

نوع مقاله: پژوهشی

DOI: 10.52547/jiaeee.19.3.131

تاریخ ارسال مقاله: ۱۴۰۰/۰۸/۱۷

تاریخ پذیرش مشروط مقاله: ۱۴۰۱/۱۲/۰۴

تاریخ پذیرش مقاله: ۱۴۰۱/۰۲/۱۷

نام نویسنده‌ی مسئول: دکتر غلامرضا اکبری زاده

نشانی نویسنده‌ی مسئول: ایران - خوزستان - اهواز - دانشگاه شهید چمران اهواز - دانشکده‌ی مهندسی - گروه برق

۱- مقدمه

استفاده از الگوریتم‌های مبتنی بر یادگیری و بهینه سازی و همچنین به کارگیری انواع شبکه‌های عصبی مصنوعی به منظور حل مسایل غیر خطی رشد روزافزون داشته است [۴-۱]. در این راستا الگوریتم‌های یادگیری عمیق در بسیاری از کاربردها [۵، ۶] می‌توانند به عنوان جایگزینی برای الگوریتم‌های یادگیری ماشین کلاسیک [۷، ۸] مورد استفاده قرار گیرند. از جمله این کاربردها می‌توان به مسایل پردازش تصاویر شامل بخش‌بندی، استخراج ویژگی و طبقه‌بندی آن‌ها اشاره نمود [۹-۱۰]. بخش‌بندی معنایی تصاویر برگرفته از ادراک صحنه بوده و به معنای طبقه‌بندی تک تک پیکسل‌های تصویر یا مرز بندی دقیق اجسام موجود در آن است. معماری اصلی بخش‌بندی تصاویر اغلب شامل رمزگذارها و رمزگشاها است. در واقع رمزگذارها با بکارگیری انواع مختلف فیلترها برای استخراج ویژگی‌های تصویر، و رمزگشاها به منظور ایجاد خروجی بخش‌بندی بر اساس ویژگی‌های استخراج شده از تصویر عمل می‌کنند. در استخراج ویژگی نمونه‌برداری کاهشی و برای دستیابی به خروجی هم سایز با ورودی نمونه‌برداری افزایشی مورد استفاده قرار می‌گیرد [۶].

سنسورهای رادار روزنه مصنوعی (SAR^1)، از انواع سنسورهای راداری اکتیو به شمار می‌آیند و در زمینه تصویربرداری نسبت به سنسورهای پسیو مزایای قابل توجهی دارند [۱۱]. از جمله می‌توان به قابلیت تصویربرداری شبانه‌روزی و در هر شرایط آب و هوایی، اخذ تصاویر از مناطق وسیع و قدرت تفکیک پذیری بالا اشاره نمود. از این تصاویر به‌طور گسترده در کاربردهای سنجش از دور و به‌خصوص در شناسایی لکه‌های نفتی در آب‌های آزاد استفاده می‌شود. با این حال به دلیل وجود نویز اسپکل، وجود مرزهای ضعیف و نامشخص، مات شدگی لبه‌ها، کنتراست پایین و شدت روشنایی ناهمگن در این تصاویر، بخش‌بندی و تشخیص دقیق مرزها یک چالش جدی است [۱۲، ۱۳].

نشت نفت و مشتقات آن در آب‌های آزاد به دلایلی همچون تصادف تانکرها و کشتی‌های نفتکش و یا تخلیه غیر قانونی مواد نفتی و سوختی کشتی‌ها در آب رخ می‌دهد. در سال‌های اخیر با افزایش مبادلات تجاری بین‌المللی و حمل و نقل دریایی، احتمال وقوع آلودگی‌های نفتی نیز افزایش یافته است. بنابراین شناسایی هر چه سریع‌تر نواحی آلوده از اهمیت ویژه زیست محیطی و اقتصادی برخوردار است [۱۴-۱۶]. در نواحی نشت نفت، دامنه امواج مویرگی و گرانشی سطح دریا تضعیف شده و به تبع آن انرژی امواج منعکس شده به سمت رادار کاهش می‌یابد؛ بنابراین پیکسل‌های مربوط به این نواحی در تصاویر SAR به صورت نواحی تیره ظاهر می‌شوند [۱۷]. علاوه بر این، پدیده‌های دیگری با منشأ مختلف مانند نواحی با وزش باد آرام یا نواحی پوشیده شده از جلبک وجود دارند که در این تصاویر مناطق تاریک مشابه با لکه‌های نفتی ایجاد می‌کنند. این پدیده‌ها که

باعث افزایش هشدارهای اشتباه می‌شود، شبه‌لکه‌های نفتی نامیده می‌شوند [۱۸]. بر اساس الگوریتم‌های کلاسیک یادگیری ماشین، شناسایی لکه‌های نفتی در تصاویر SAR شامل سه مرحله اصلی است: مشخص نمودن نواحی تیره در تصاویر (بخش‌بندی)، استخراج ویژگی از آن نواحی، و طبقه‌بندی آن‌ها به لکه‌های نفتی و شبه‌لکه‌های نفتی. هر یک از این مراحل به تفصیل در شناسایی نواحی آلوده به نفت مورد توجه و بررسی محققان بسیاری قرار گرفته‌اند [۱۹-۲۴]. در سال‌های اخیر مطالعات بسیاری در زمینه شناسایی لکه‌های نفتی مبتنی بر یادگیری عمیق و شبکه‌های عصبی عمیق صورت گرفته است، که از آن جمله می‌توان به موارد ذیل اشاره کرد:

در پژوهشی که در سال ۲۰۲۰ انجام شد [۲۵]، نویسندگان یک شبکه عصبی کانولوشنی عمیق ($DCNN^2$)، به نام شبکه نشت نفت ($OSCNet^3$)، برای تشخیص نشت نفت در تصاویر SAR پیشنهاد دادند. معماری شبکه $OSCNet$ مبتنی بر VGG-16 بوده و با تنظیم پارامترها بر مجموعه داده‌های نواحی تیره در تصاویر SAR به‌دست آمده است. این شبکه با ۱۲ لایه وزنی یک شبکه نسبتاً عمیق بوده و با کمک مجموعه داده‌های بزرگی با بیش از ۲۰۰۰ ناحیه تیره در تصویر SAR برای تشخیص نشت نفت آموزش داده شده است. نتایج آزمایشات بیانگر بهبود عملکرد طبقه‌بندی شبکه $OSCNet$ در مقایسه با روش‌های یادگیری ماشین سنتی با استخراج ویژگی دستی است. همچنین استفاده از عملیات افزونی داده‌ها تأثیر بسزایی در جلوگیری از بیش‌برازش و بهبود عملکرد طبقه‌بندی دارد. به منظور مقایسه $OSCNet$ با سایر طبقه‌بندهای عمیق با رویکرد تشخیص نشت نفت در تصاویر SAR با توجه به وجود اختلاف در مجموعه داده‌ها، مقایسه عددی صورت نگرفته است.

در [۲۶] نویسندگان با بیان اینکه سنسورهای نوری و مایکروویو هوابرد و ماهواره‌ای ممکن است تحت تأثیر وجود شبه‌لکه‌های نفتی قرار گرفته و منجر به هشدارهای اشتباه شوند، ضمن تأکید بر اهمیت تمایز نواحی نشت نفت و شبه‌لکه‌های نفتی به بیان برخی محدودیت‌های مدل‌های یادگیری ماشین سنتی در طبقه‌بندی مستقیم با چارچوب‌های آموزشی یکپارچه ابتدا به انتها پرداخته و اذعان داشتند که استخراج ویژگی‌های قدرتمند توسط مدل‌های یادگیری عمیق با قابلیت یادگیری یکپارچه و مستقل، دقت تشخیص را به‌طور چشمگیری افزایش می‌دهد. آن‌ها به منظور پیش‌بینی مسیر نشت نفت، مدل‌های ریاضی مبتنی بر روش لاگرانژی را با دقت بیشتر در زمان واقعی بهبود بخشیدند؛ اما تکنیک سنجش از دور مناسبی برای تشخیص نشت نفت و شبه‌لکه‌های نفتی ارائه نگردید.

در سال ۲۰۱۸، یک روش دو مرحله‌ای از شبکه عصبی کانولوشن (CNN^4) برای شناسایی کشتی‌ها و لکه‌های نفتی با استفاده از تصاویر رادار هوابرد ($SLAR^5$) [۲۷] ارائه گردید. معماری دو مرحله‌ای متشکل از سه جفت CNN است که هر جفت برای تشخیص یکی از کلاس‌ها (کشتی، نشت نفت و ساحل) آموزش داده شده است. در هر

در [۳۴] نویسندگان از شبکه‌های عصبی عمیق در شناسایی لکه‌های نفتی استفاده کردند. بر این اساس تشخیص خودکار نشت نفت و بهره‌گیری از یک سیستم نظارتی مداوم زمان عملیات شناسایی را کاهش می‌دهد. در این مقاله یک شبکه CNN عمیق معرفی شده که بر اساس تصاویر SAR اخذ شده از ماهواره sentinel-1 توسط ESA^۹ و مبتنی بر سوابق EMSA^{۱۰} برای حوادث آلودگی دریایی آموزش داده شده است.

نویسندگان در [۳۵] به تاثیر شباهت بصری لکه‌های نفتی و شبه لکه‌های نفتی بر قابلیت اطمینان فرایند تشخیص در تصاویر SAR اشاره کرده و یک مدل تشخیص نشت نفت عمیق با استفاده از مدل بخش‌بندی نمونه مبتنی بر ماسک-ناحیه ای ارائه دادند. مدل فوق با استفاده از انتقال یادگیری از ResNet101 [۳۶] در COCO به عنوان ستون فقرات در ترکیب با معماری شبکه هرمی (FPN^{۱۱}) برای استخراج ویژگی در ۳۰ تکرار با نرخ یادگیری ۰,۰۰۱ انجام شده است. پارامترهای ارزیابی مدل دقت، فراخوانی، میزان همپوشانی واحد (IoU^{۱۲})، مقیاس F1 و صحت می‌باشد.

در [۳۷] تصاویر SAR به عنوان منبع ارزشمندی از اطلاعات برای تشخیص نشت نفت دریایی به‌شمار آمده و الگوریتم‌های بخش-بندی با قابلیت شناسایی مناطق احتمالی نشت نفت در فرایند آنالیز این تصاویر حائز اهمیت بیان شده است. این مقاله به کاربرد الگوریتم-های خوشه‌بندی، رگرسیون لجستیک و شبکه عصبی کانولوشن در تشخیص نشت نفت در تصاویر ماهواره‌ای Envisat و Sentinel-1 پرداخته است. با توجه به عدم تعادل در تعداد نمونه‌های کلاس‌ها، معیارهای مبتنی بر منحنی‌های دقت-فراخوانی در طبقه‌بندی به‌کار گرفته شده‌اند. علی‌رغم تاثیر روش‌های رگرسیون لجستیک و الگوریتم-های خوشه‌بندی در بخش‌بندی تصاویر، ترکیبی از روش‌های کانولوشنی و شبکه‌های عصبی با زمان محاسباتی کم قادر به ارائه نتایج بهتری هستند. در این مقاله از ادغام یک شبکه عصبی متقاطع در یک سیستم پشتیبانی تصمیم‌گیری به منظور تسریع در آنالیز و تصمیم-گیری در زمان حادثه استفاده شده است.

در سال ۲۰۲۰ دانگ می‌سونگ و همکارانش [۳۸]، یک روش جدید به منظور شناسایی نشت نفت در تصاویر PolSAR مبتنی بر استخراج ویژگی چند لایه عمیق به کمک CNN ارائه نمودند. در این روش داده‌های PolSAR به یک بلوک داده ۹ کاناله به‌عنوان ورودی CNN تبدیل شده و برای استخراج خودکار دو ویژگی سطح بالا از داده‌های اصلی به یک معماری ۵ لایه ای CNN اعمال می‌شوند. ویژگی‌ها پس از کاهش ابعاد از طریق آنالیز مولفه اصلی (PCA^{۱۳}) ادغام شده و به یک ماشین بردار پشتیبان با هسته عملکرد شعاعی (RBF-SVM^{۱۴}) برای طبقه بندی وارد می‌شوند. سه مجموعه داده SAR کاملاً قطبی از RADARSAT-2 جهت آموزش و ارزیابی مورد استفاده قرار گرفته است.

شاخه، CNN اول عمل تشخیص نواحی درشت و CNN دوم عمل محلی‌سازی دقیق پیکسل‌های متعلق به هر کلاس را انجام می‌دهد. پس از طبقه‌بندی، به منظور حذف نواحی تیره خیلی کوچک از فیلتر مورفولوژیکی انبساط استفاده شده است.


به منظور غلبه بر محدودیت‌ها و چالش‌های شناسایی لکه‌های نفتی در تصاویر SAR، در [۲۸] رویکرد کارامدی از بخش‌بندی معنایی با شبکه‌های عصبی کانولوشنی عمیق ارائه گردید. همچنین یک مجموعه داده تصویری SAR به عنوان مجموعه داده معیار برای بررسی عملکرد مدل‌های بخش‌بندی در کاربردهای خاص در دسترس عموم قرار داده شد. در ارزیابی ارائه شده توسط نویسندگان DeepLabv3+ [۲۹] به عنوان روشی که عملکرد بالایی از نظر دقت مجموعه تست و زمان آشکارسازی موثر نشت نفت دارد معرفی شده است.

مقاله مروری در سال ۲۰۲۰ توسط ژئوفانگ لی و همکارانش [۳۰] منتشر گردید. در این مقاله عنوان شده است که با ورود سنجنش از دور اقیانوسی به جرگه مسائل با حجم بالای اطلاعات، روزانه در کل دنیا حجم بالایی از اطلاعات جمع‌آوری می‌شود و استخراج اطلاعات دقیق و کاربردی با به‌کارگیری الگوریتم‌های یادگیری عمیق امکان‌پذیر است. در این مقاله، ابتدا دو چارچوب یادگیری عمیق که در طبقه‌بندی تصاویر سنجنش از دور اقیانوسی به‌کار رفته‌اند بررسی شده و سپس چگونگی تاثیر آن‌ها بر هشت کاربرد معمولی از جمله امواج داخلی اقیانوس، امواج گردابی، نشت نفت، سیلاب در ساحل، یخ دریا، جلبک سبز، کشتی و صخره‌های مرجانی ارائه شده است.

در [۳۱] نویسندگان یک چارچوب نظارت مداوم با قابلیت تشخیص خودکار آلودگی‌های ناشی از نشت نفت را به‌عنوان یک سیستم هشدار دهنده اولیه برای به حداقل رساندن آسیب‌های زیست محیطی ارزشمند دانستند. آن‌ها با استفاده از مزایای شبکه‌های عصبی کانولوشنی عمیق یک سیستم هشدار اولیه برای شناسایی آلودگی نشت نفت و بخش‌بندی معنایی تصاویر SAR به مناطقی از جمله نشت نفت، شبه‌لکه نفتی، مناطق خشکی، سطح دریا و کشتی‌ها ارائه دادند. مجموعه داده مورد استفاده در این مقاله از مرکز دسترسی آزاد Copernicus تهیه و به صورت دستی حاشیه نویسی شده است.

در سال ۲۰۱۷ مقاله‌ای مبتنی بر بخش‌بندی تصاویر قطبی رادار روزنه مصنوعی (PolSAR^{۱۵}) که ابزاری برجسته در تشخیص و طبقه-بندی نشت نفت است توسط چن، لی، سان و ژنگ [۳۲] ارائه گردید. در این مقاله، الگوریتم‌های یادگیری عمیق از جمله رمزگذار خودکار انباشته (SAE^{۱۶}) و شبکه باور عمیق (DBN^{۱۷}) [۳۳] برای بهینه‌سازی مجموعه ویژگی‌های قطبشی و کاهش ابعاد آن از طریق لایه‌های بدون نظارت از پیش آموزش یافته، به‌کارگرفته شده‌اند. نتایج ارائه شده عملکرد بهتر شبکه‌های عمیق نسبت به دستگاه بردار پشتیبانیو شبکه-های عصبی سنتی در طبقه‌بندی نشت نفت را نشان می‌دهد.

۱ قابل مشاهده است [۳۹] که می‌توان گفت تاکنون به ندرت در شناسایی لکه‌های نفتی مورد استفاده قرار گرفته است. در نشان دادن برتری ShuffleNet نسبت به معماری‌های دیگر می‌توان به عملکرد بهتر آن در مقایسه با MobileNet اشاره کرد، بطوریکه خطای آن در سطح 40MFLOPS برای مجموعه داده ImageNet-top-1 حدود $7/8\%$ پایینتر است [۳۹].



شکل (۱): طرح کلی مخلوط کردن کردن کانال و کانولوشن گروهی [۳۹]

همانطور که در شکل ۱ قابل مشاهده است، در صورتیکه هر کانولوشن فقط بر روی گروه کانال ورودی مربوطه اعمال شود هزینه محاسبات به میزان قابل توجهی کاهش می‌یابد. در عین حال، اگر چندین کانولوشن گروهی به صورت پشت‌پای با هم قرار بگیرند، با توجه به اینکه خروجی‌های یک کانال خاص کسری از کانال‌های ورودی است، در صورتیکه خروجی‌های یک گروه خاص فقط به ورودی‌های همان گروه مربوط شوند جریان اطلاعات بین گروه‌های کانال وجود نداشته و بنابراین نتایج خوبی حاصل نمی‌شود. با برقراری امکان دسترسی کانولوشن گروهی به ورودی‌های گروه‌های مختلف، کانال‌های ورودی و خروجی کاملاً با هم مرتبط خواهند شد. بنابراین می‌توان با بخش‌بندی نقشه ویژگی استخراج شده از لایه گروه‌های قبلی به چندین زیر گروه و اعمال ترکیبی از آن‌ها به عنوان ورودی لایه بعدی، ارتباط کامل کانال‌های ورودی و خروجی را برقرار نمود. در واقع در صورت داشتن یک لایه کانولوشن با g گروه که هر یک از گروه‌ها n کانال دارد، شاهد خروجی با $g \times n$ کانال هستیم و پس از مخلوط شدن کانال‌های مذکور از آن به عنوان ورودی لایه بعدی استفاده می‌شود. این فرایند حتی در شرایطی که تعداد گروه‌های دو لایه کانولوشن یکسان نباشد نیز بسیار کارآمد است و می‌توان آن را در ساختارهای شبکه برای آموزش‌های یکپارچه به کار برد [۳۹].

۲-۲- شبکه ShuffleNet

ShuffleNet مبتنی بر عملکرد مخلوط کردن کانال و با کاربرد استفاده در شبکه‌های کوچک طراحی شده است [۳۹] که در آن اساس کار استفاده از ساختار تکرار شونده بلوک باقیمانده (شکل ۲-الف) [۴۸] است. در شاخه باقیمانده از یک لایه کانولوشن گروهی نقطه‌ای 1×1 ، کانال مخلوط کردن ویژگی، لایه کانولوشن عمقی 3×3 [۳۹] و در انتها به منظور بازیابی ابعاد کانال مطابق با مسیر میانبر از یک لایه

در این مقاله مدلی جدید از شبکه‌های کانولوشنی عمیق بر پایه بلوک‌های مخلوط کننده کانال‌های ویژگی، بلوک‌های آتروس و ترکیبی از لایه‌های دیکانولوشن و کانولوشن ترانهاده در بخش رمزگشایی به منظور شناسایی لکه‌های نفتی در تصاویر SAR ارائه گردید. در ادامه این مقاله، بررسی مدل‌های مورد استفاده در بخش ۲، روش پیشنهادی در بخش ۳، بحث و ارزیابی مدل‌ها در بخش ۴ و نتیجه‌گیری در بخش ۵ ارائه شده است.

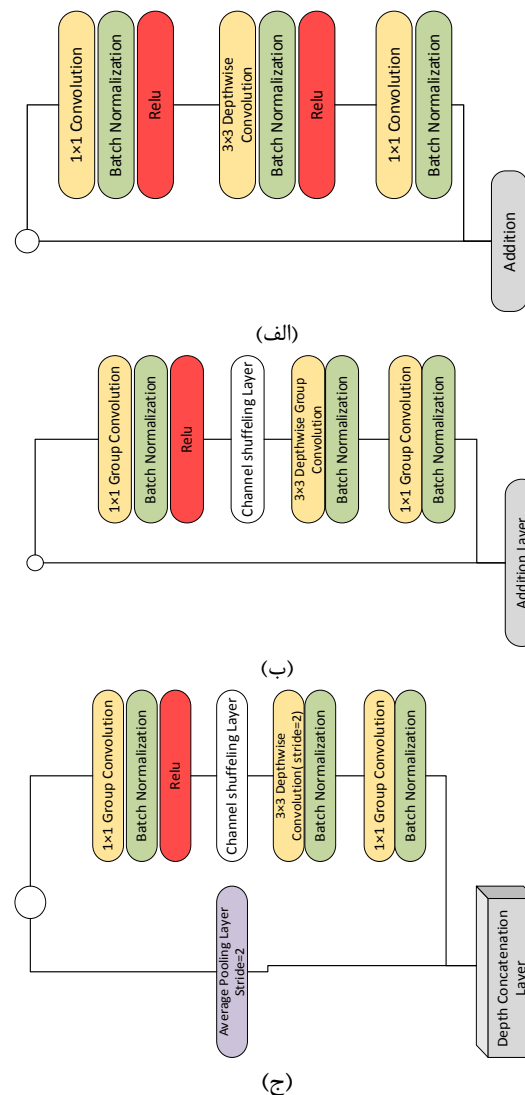
۲- مواد و روش‌ها

۲-۱- الگوریتم‌های تحت بررسی

در به کارگیری شبکه‌های عصبی عمیق، شبکه‌های عصبی با تعداد لایه‌های بیشتر در حل مسائل تشخیصی و طبقه‌بندی مورد توجه واقع می‌شوند که مستلزم استفاده از سخت‌افزار بهتر، زمان و پیچیدگی‌های محاسباتی بیشتر است. با توجه به محدودیت‌های محاسباتی برخی از سیستم‌های پردازشی تعبیه شده بر دستگاه‌های متحرک مانند هواپیماهای بدون سرنشین، تلفن‌های همراه، تجهیزات سنجش از دور و غیره که مبتنی بر سیستم عامل‌های تلفن همراه هستند، تمرکز بر شبکه‌هایی با حجم محاسباتی کمتر، به لحاظ هزینه و زمان انجام محاسبات از اهمیت بالایی برخوردار است [۳۹]. اغلب شبکه‌های عصبی کانولوشنی از یک ساختار یکسان و تکرار شونده تشکیل شده‌اند و ویژگی‌ها با استفاده از فیلترهای عمیق با سایز کانولوشنی مختلف استخراج می‌شوند. شایان ذکر است به دلیل استفاده از کانولوشن‌های 1×1 متعدد، معماری‌هایی مانند Xception [۴۰] و ResNeXt [۴۱] از لحاظ هزینه و محاسبات در شبکه‌های کوچک کارایی کمتری دارند؛ زیرا استفاده از کانولوشن‌های نقطه‌ای با سایز 1×1 ، منجر به محدود شدن کانال‌ها و عدم دستیابی به دقت مورد نظر می‌شود. استفاده از کانولوشن‌های گروهی در لایه‌های 1×1 می‌تواند به رفع اشکال فوق کمک کند. کانولوشن گروهی و کانولوشن تفکیک‌پذیر عمقی از مفاهیم مورد توجه محققان یادگیری عمیق هستند. که به منظور کاهش پیچیدگی‌های محاسباتی از آن‌ها استفاده می‌شود. این کانولوشن‌های گروه‌بندی شده با اثر بخشی بالا در تقسیم ویژگی‌ها در هر گروه، برای اولین بار در AlexNet [۴۲] و سپس به منظور توزیع مدل بر روی دو GPU در ResNeXt [۴۱] مورد استفاده قرار گرفته‌اند. کانولوشن قابل تفکیک عمقی نیز که در Xception [۴۰] معرفی شده و تعمیم یافته کانولوشن‌های تفکیک‌پذیر سری Inception [۴۳] می‌باشند. استفاده از این نوع کانولوشن در شبکه MobileNet [۴۴] نیز به عنوان مدلی با سطوح وزنی پایین، نتایج چشمگیری داشته است. استفاده همزمان از هر دو نوع کانولوشن مذکور در شبکه ShuffleNet [۳۹، ۴۵] بکار گرفته شده‌اند. در واقع ShuffleNet به رمزگذاری اطلاعات بیشتر کمک کرده و به‌خصوص برای عملکرد در شبکه‌های بسیار کوچک از اهمیت ویژه‌ای برخوردار است. عملیات مخلوط کردن کانال به صورت تصادفی و به دنبال آن استفاده از یک لایه کانولوشن گروهی در شکل

کانولوشن گروهی نقطه‌ای عمل می‌کند ($g=1$). در عمل مدل‌های کوچکتر تمایل بیشتری به استفاده از کانولوشن گروهی دارند زیرا تجمع گروهی کانال‌های نقشه ویژگی و بنابراین رمز گذاری بیشتری را برای یک محدوده پیچیدگی خاص ممکن می‌سازد. عملیات نقطه شناور یا FLOP (تعداد عملیات ضرب و جمع) معیاری غیر مستقیم، تقریبی و پر کاربرد برای اندازه‌گیری پیچیدگی محاسباتی است [۳۹] که نسبت به معیار مستقیم مانند سرعت یا تأخیر کمتر مورد توجه قرار گرفته است، زیرا ممکن است شبکه‌هایی با FLOP های یکسان سرعت متفاوتی داشته باشند [۴۵].

کانولوشن گروهی نقطه‌ای 1×1 استفاده شده است [۳۹] (شکل ۲ ب). در مواردی که ShuffleNet با گام بیشتر از یک اعمال می‌شود، از یک لایه ادغام بر اساس میانگین با سایز 3×3 در مسیر میانبر و همچنین از بلوک اتصال کانال استفاده می‌شود. در این صورت بزرگنمایی ابعاد کانال را با هزینه محاسباتی کمتری آسان می‌کند. در واقع ShuffleNet بر تنظیم کانولوشن‌های گروهی نقطه‌ای و عملکرد مختلط کانال، استوار است. اگر $g=1$ باشد، کانولوشن گروهی نقطه‌ای محسوب نشده و ShuffleNet مانند شبکه "Xception" عمل می‌کند. مدل‌هایی با تعداد گروه‌های ($g>1$) همواره بهتر از مدل‌های بدون



شکل (۲): بلوک‌های شافل نت [۳۹]: (الف): زیرساخت بلوک با کانولوشن عمقی. (ب) بلوک شافل نت با کانولوشن گروهی نقطه‌ای. (ج) بلوک شافل نت با گام ۲

1×1 با تعداد n_1 کانال ورودی و n_2 کانال خروجی در فضای ویژگی با ابعاد $h \times w$ تعداد FLOP ها از رابطه ۱ و هزینه دسترسی به حافظه (MAC) از رابطه ۲ قابل محاسبه هستند.


$$FLOP = hwn_1n_2 \quad (1)$$

هزینه دسترسی به حافظه یا تعداد عملیات دسترسی به حافظه (MAC^*) و میزان موازی کاری در مدل‌ها بر سرعت آن‌ها موثر است. با یکسان سازی عرض کانال می‌توان هزینه دسترسی به حافظه را به حداقل رساند [۴۵]. در این صورت با فرض داشتن یک لایه کانولوشن

عملگر Relu دنبال می‌شوند. به منظور ثابت ماندن تعداد کانال‌ها، پس از عملیات کانولوشن شاخه‌ها به هم متصل می‌شوند. سپس عملیات "مخلوط کردن کانال" [۳۹] برای فعال کردن جریان اطلاعاتی با بلوک‌های بعدی مورد استفاده قرار می‌گیرد. در این ساختار لایه عملیات "add" موجود در ShuffleNetv1 [۳۹] دیگر وجود ندارد. همچنین سه عملیات پی در پی، "Concat"، "Shuffle Channel" و "Split Channel"، در یک عملیات واحد ادغام می‌شوند. برای نمونه برداری مکانی، می‌توان اپراتور تقسیم کانال را حذف و تعداد کانال‌های خروجی را دو برابر نمود. شبکه ShuffleNetv2 از دقت بالایی برخوردار است زیرا راندمان بالا در هر بلوک ساختمانی امکان استفاده از کانال‌های ویژگی بیشتر و ظرفیت شبکه بزرگتر را فراهم می‌کند. همچنین در صورتی که کانال‌های ویژگی مساوی تقسیم شوند، استفاده مجدد از ویژگی‌ها صورت می‌گیرد [۴۵]. از معماری‌های مختلف شافل‌نت می‌توان در طراحی شبکه‌های عصبی عمیق جدیدتر استفاده نمود.

۲-۳- بلوک‌های ادغام هرم فضایی آتروس

در SPPNet مفهوم ادغام هرمی فضایی (SPP)^{۱۷} برای جمع‌آوری اطلاعات چند مقیاس از یک نقشه ویژگی معرفی شد که با حذف محدودیت ثابت بودن اندازه شبکه، از مفاهیم مهم و کاربردی در شبکه‌های عصبی عمیق به‌شمار می‌رود. با اضافه کردن یک لایه SPP در ورودی آخرین لایه کانولوشنی (مراحل عمیق‌تر شبکه) ویژگی‌های لایه SPP تجمیع شده و خروجی‌هایی با طول ثابت ایجاد می‌شود. همچنین در این حالت نیاز به برش یا تغییر دادن ورودی مرتفع می‌گردد [۴۷]. ادغام هرم فضایی آتروس (ASPP)^{۱۸} یک ماژول بخش-بندی معنایی با تنظیم نرخ اتساع کانولوشن اولیه است که مقدار وزن آن در فضای بیشتر پخش شده و با استفاده از چندین لایه موازی با نرخ نمونه‌برداری متفاوت پیاده‌سازی می‌گردد. ویژگی‌های سطح تصویر نیز برای ترکیب اطلاعات کلی زمینه با استفاده از لایه ادغام مبتنی بر میانگین کلی در آخرین لایه ویژگی شبکه استفاده می‌شود [۴۷، ۲۹]. شکل ۴ مفهوم کلی بلوک ASPP را نشان می‌دهد [۲۹].



شکل (۴): مفهوم کلی بلوک ASPP [۲۹]

همانطور که مشاهده می‌شود ورودی با فیلترهای ۳×۳ را می‌توان با نرخ اتساع مختلف مثلاً ۱، ۶، ۱۲، ۱۸ و یا ۲۴ جمع نمود. شایان ذکر است که خروجی‌ها اندازه یکسانی دارند و توسط بلوک‌های تجمیع عمقی^{۱۹} به هم می‌پیوندند. خروجی کانولوشن ۱×۱ نیز به خروجی

$$MAC = hw(n_1 + n_2) + n_1 n_2 \quad (۲)$$

بنابراین:

$$MAC \geq 2\sqrt{hwFLOP} + \frac{FLOP}{hw} \quad (۳)$$


با توجه به روابط فوق، به لحاظ تئوری در شرایطی که تعداد کانال‌های ورودی و خروجی برابر باشند، حداقل مقدار MAC به دست می‌آید و بنابراین سرعت ارزیابی شبکه سریعتر است، اما در عمل ممکن است به دلیل ناکافی بودن حافظه پنهان دستگاه، MAC از مقدار تئوری منحرف گردد. در حالت استفاده از یک کانولوشن گروهی ۱×۱ با تعداد گروه‌های n_g ، رابطه ۱ و ۲ را می‌توان به صورت زیر نوشت [۴۲]:

بطوریکه با فرض ثابت بودن ورودی hwn_1 و هزینه محاسباتی $FLOP$ افزایش n_g منجر به افزایش MAC و کاهش سرعت اجرا می‌شود. بنابراین دقت در انتخاب تعداد گروه بر حسب کاربرد مساله از اهمیت ویژه‌ای برخوردار است. در مجموع، استفاده از کانولوشن‌های متعادل با عرض کانال برابر در شبکه، آگاهی از هزینه استفاده از کانولوشن‌های گروهی و کاهش عملگرهایی که MAC بالایی دارند و GPU را اشغال می‌کنند مانند Relu از موارد حائز اهمیت در طراحی شبکه‌های کانولوشنی مدرن هستند. بر اساس موارد مطرح شده معماری‌های مختلف شبکه شافل نت [۳۶، ۴۲، ۴۳]، قابل استفاده و ارزیابی است، به عنوان مثال همانطور که در شکل ۳ قابل مشاهده است [۴۵]، در ابتدای هر واحد از یک عملگر ساده جدا کننده کانال استفاده شده است که ورودی کانال‌های ویژگی را به دو شاخه با تعداد کانال‌های متفاوت تقسیم نماید.

$$FLOP = \frac{hwn_1 n_2}{n_g} \quad (۴)$$

$$MAC = hw(n_1 + n_2) + \frac{n_1 n_2}{n_g} = hwn_1 + \quad (۵)$$

$$\frac{FLOP \times n_g}{n_1} + \frac{FLOP}{hw}$$



شکل (۳): بلوک‌های شافل‌نت ورژن ۲ با به‌کارگیری جداکننده

کانال [۴۵]

عملیات جداسازی در کانال دو گروه ایجاد می‌کند، بنابراین کانولوشن‌های ۱×۱ در این طرح از نوع گروهی نبوده و هر دو توسط

۴-۲- پارامترهای ارزیابی

به منظور ارزیابی و مقایسه روش های بخش بندی تصویر بر اساس یک مجموعه داده مشخص، معیار های متداول ذیل مورد بررسی قرار می گردد.

• دقت کلی (Global Accuracy)

دقت کلی معیاری است که نسبت پیکسل‌هایی را که به درستی طبقه‌بندی شده‌اند، صرف نظر از کلاس آن‌ها اندازه‌گیری می‌کند. از این معیار که از رابطه ۶ به دست می‌آید می‌توان برای تخمین سریع تعداد پیکسل‌هایی که با هزینه محاسباتی کم به درستی طبقه‌بندی شده‌اند، استفاده نمود.

$$Global_Accuracy = \frac{(T_p + T_n)}{(T_p + T_n + F_p + F_n)} \quad (6)$$

که در آن T_p ، T_n ، F_p ، و F_n به ترتیب تعداد نمونه‌های مثبت واقعی، مثبت کاذب، منفی واقعی، و منفی کاذب را هستند.

• صحت (Accuracy)

صحت نشان‌دهنده درصد پیکسل‌هایی است که به درستی برای هر کلاس شناسایی شده‌اند. معیار صحت را می‌توان برای تعیین دقیق میزان تشخیص هر کلاس از پیکسل‌ها استفاده نمود. با توجه به معیار درستی^{۲۰}، صحت نسبت پیکسل‌های طبقه‌بندی شده صحیح به پیکسل‌های کلاس مربوطه است. از رابطه ۷ به دست می‌آید.

$$Accuracy = \frac{T_p}{(T_p + F_n)} \quad (7)$$

که در آن T_p و F_n به ترتیب تعداد نمونه‌های مثبت واقعی و منفی کاذب هستند. برای مجموعه داده کلی، صحت متوسط، میانگین صحت همه کلاس‌ها در همه تصاویر است و برای هر تصویر، متوسط همه کلاس‌ها در آن تصویر خاص است.

• همپوشانی بر واحد Intersection Over Union (IoU)

IoU به عنوان نسبت نواحی بخش‌بندی مثبت واقعی هر کلاس بر کلیه نواحی پیش‌بینی شده با آن کلاس تعریف شده است. اگر این پارامتر برای چند کلاس محاسبه شود، ابتدا IoU هر کلاس محاسبه شده و سپس میانگین آن‌ها در نظر گرفته می‌شود و از رابطه ۸ محاسبه می‌شود.

$$IoU = \frac{(T_p)}{(T_p + F_p + F_n)} \quad (8)$$

• IoU وزن‌دار شده Weighted IoU

پارامتری مبتنی بر IoU متوسط برای مقابله با عدم تعادل کلاس‌ها می‌باشد. به این معنی که اگر یک کلاس در اکثر تصاویر یک مجموعه داده غالب باشد، بهتر است در مقایسه با سایر کلاس‌ها وزن‌دار شده و میانگین وزنی IoU ها بر حسب فراوانی کلاس در مجموعه داده در نظر گرفته می‌شود.

• معیار BF Score (Boundary F1 Score)

الحاق شده اضافه می‌شود. از آنجا که تصویر مورد نیاز برای بخش‌بندی می‌تواند هر اندازه‌ای در ورودی داشته باشد، اطلاعات چند مقیاس ASPP به بهبود نتایج کمک می‌کند. از میان مدل‌هایی که تاکنون ارائه شده خانواده Deeplab از ASPP استفاده می‌کند. اگرچه ASPP به طور قابل توجهی در بهبود نتایج بخش‌بندی مفید بوده، اما برخی موارد بر اساس معماری آن حائز اهمیت است. هیچ اطلاعاتی در لایه‌های مختلف موازی در ASPP به اشتراک گذاشته نشده است، بنابراین بر قدرت تعمیم هسته در هر لایه تأثیر می‌گذارد. از آنجاییکه هر لایه بر حسب اندازه شیء به مجموعه‌های مختلفی از نمونه‌های آموزشی اختصاص دارد، میزان داده‌ها برای هر لایه موازی کمتر بر تعمیم‌پذیری کلی تأثیر می‌گذارد. همچنین تعداد پارامترهای موجود در شبکه به صورت خطی با تعداد پارامترهای هر شاخه افزایش می‌یابد و بنابراین می‌تواند منجر به برازش بیش از حد شود. اتروس‌ها می‌توانند در مدل‌های مختلف هم به صورت سری و هم به صورت موازی مورد استفاده قرار گیرند.

با به‌کارگیری و توسعه این مدل با عناوین DeepLabv2، DeepLabv3 و DeepLabv3+ هر بار رمزگذارهایی با قابلیت بالا در ارائه نتایج با دقتی بیشتر قابل دست‌یابی است [۲۹، ۴۷]. به‌عنوان مثال DeepLabv3+، با ترکیب ماژول‌های سری و موازی از کانولوشن اتروس همراه با تغییر معماری ResNet برای دستیابی به نقشه‌های ویژگی با وضوح بالا ارائه گردید. در این روش از کانولوشن‌های اتروس با نرخ اتساع مختلف برای اخذ اطلاعات در مقیاس‌های متعدد، بدون کاهش قابل توجه در اندازه تصویر استفاده می‌شود. با ترکیب مدل‌های مختلف deeplab با مدل‌های از پیش آموزش یافته به عنوان استخراج کنندگان ویژگی می‌توان به بخش‌بندی معنایی تصاویر بدون محدودیت سباز تصویر دست یافت. به عنوان مثال مدل DeepLabv3 با ResNet-101 روی مجموعه داده‌های ImageNet و JFT-300M آموزش دیده و نمره mIoU ۸۶٫۹ ارائه داده است.

در مدل DeepLabv3+ به جای نمونه برداری ۱۶ برابر، از یک رمزگشا که در معماری مانند U-Net استفاده شده و اطلاعات را از لایه های رمزگذار می‌گیرد برای بهبود نتایج استفاده شده است. خروجی رمزگذار با استفاده از نمونه‌برداری دو خطی ۴ برابر نمونه‌برداری شده و پس از ترکیب با ویژگی‌های رمزگذار مجدداً با کانولوشن ۳×۳ با نرخ نمونه‌برداری ۴، نمونه برداری می‌شود. این روش نتایج بهتری نسبت به نمونه برداری با نرخ ۱۶ دارد. همچنین در این مدل معماری Xception اصلاح شده به جای Resnet به عنوان بخشی از رمزگذار جایگزین شده است. با استفاده از کانولوشن‌های تفکیک‌پذیر عمیقی پیش از کانولوشن‌های اتروس می‌توان برای کاهش تعداد محاسبات استفاده نمود [۲۹].

دهند و با بکارگیری نمونه‌های متنوع از هر کلاس، اطلاعات متنی تصاویر SAR را تا حد امکان به یک اندازه بین ۵ کلاس توزیع نمایند. مجموعه داده نشت نفت توسعه یافته از طریق وب سایت آزمایشگاه (<https://mklab.iti.gr/results/oil-spill-detection-dataset/>) به صورت عمومی در دسترس است. در این مقاله از مجموعه داده فوق در بخش‌بندی معنایی تصویر استفاده شده است. داده‌ها به منظور آموزش، تست و ارزیابی به ترتیب در مجموعه‌های ۸۹۰، ۱۱۰ و ۱۱۲ تصویر در نظر گرفته شده‌اند.

۳- روش پیشنهادی

بر اساس موارد مطرح شده و با تکیه بر مزایای شبکه‌های شافلنت و آتروس، در این مقاله بر طراحی مدل‌های ترکیبی از این دو ماژول تمرکز شده است. هدف این مقاله بخش‌بندی معنایی و شناسایی لکه‌های نفتی در تصاویر SAR به کمک شبکه‌های عصبی عمیق می‌باشد بطوریکه در استخراج ویژگی‌های تصویر (رمزگذاری) از آرایش‌های مختلف بلوک‌های shuffleNet و آتروس به عنوان معماری‌های زیربنایی و به دنبال آن یک شبکه رمزگشایی ترکیبی متشکل از لایه‌های دیکانولوشن و کانولوشن‌های ترانهاد و لایه‌های برش معرفی می‌گردد. وظیفه رمزگشایی این است که ویژگی‌های قابل تمایز آموخته شده توسط رمزگذار را در فضای پیکسل به گونه‌ای طرح‌ریزی کند تا یک طبقه‌بندی متراکم را به دست آورد.

در شکل ۶ برخی مدل‌های الهام گرفته از معماری شبکه شافلنت ارائه گردیده است. شایان ذکر است کارایی شبکه شافلنت در مسایل بخش‌بندی علاوه بر مجموعه داده تصاویر SAR، توسط مجموعه داده CamVid هم مورد آموزش و تست قرار گرفته است. در این مقاله طراحی‌های متنوعی از شبکه‌های عمیق با تعداد لایه کم از حدود ۱۰ لایه تا شبکه‌هایی با تعداد بالای ۲۵۰ لایه مورد آزمون واقع شدند. فرایند آموزش، تست و ارزیابی هر مدل طراحی در محیط نرم افزاری Matlab2021a و در جعبه ابزار یادگیری عمیق (deep learning) در سیستمی با پردازنده گرافیکی Nvidia GTX 1660 با حافظه گرافیک ۶ و پردازنده CPU Corei7-6700k اجرا گردید. با توجه به محدود بودن تعداد نمونه‌ها در مجموعه داده، فرایند افزونی دیتا در مرحله آموزش اجرا شد. به عبارتی با اعمال تغییر اندازه، چرخش افقی و یا عمودی تصادفی روی داده‌های تصویری افزونگی داده صورت می‌گیرد. با توجه به اینکه سایز تصاویر ورودی ۶۵۰×۱۲۵۰ پیکسل است و شبکه‌های ارائه شده به سایز تصویر وابسته نیستند، مدل‌های طراحی شده با اعمال ورودی‌ها بدون تغییر سایز، آموزش داده شد و مورد ارزیابی قرار گرفت.

به منظور تنظیم پارامترهای آموزش شبکه، الگوریتم بهینه‌سازی "sgdm"، نرخ یادگیری اولیه ۰،۰۱، مومنتوم ۰،۸، تنظیم L2، ۰،۰۰۱ و تعداد ایپوک‌ها در هر تکرار ۱۰-۳۰ و حداقل تعداد دسته‌های تصویر با توجه به طراحی و تعداد لایه‌های شبکه از ۲ تا ۱۲ در

امتیاز BF (Boundary F1) نشان می‌دهد که مرز پیش‌بینی شده یک شی چقدر با مرز واقعی آن مطابقت دارد. در واقع، بر اساس میانگین هارمونیک دقت و فراخوانی، تعیین می‌کند که آیا یک نقطه در یک مرز پیش‌بینی شده با مرز واقعی مطابقت دارد یا خیر. امتیاز BF نسبت به IoU با ارزیابی کیفی انسان، همبستگی بهتری دارند. برای هر تصویر، میانگین امتیاز BF نشان دهنده میانگین مقدار BF همه کلاس‌ها را نشان می‌دهد و برای مجموعه داده کلی، میانگین امتیاز BF همه کلاس‌ها را در همه تصاویر معرفی می‌کند. در این مطالعه، میانگین امتیاز BF (میانگین تمام تصاویر میانگین امتیاز BF برای هر تصویر) ارائه شده است.

• معیار F1 Score

معیار متداول در طبقه بندی F1_Score می‌تواند برای بخش‌بندی و همچنین برای مقابله با عدم تعادل کلاس استفاده شود.

$$F_1_score = \frac{(2T_p)}{(2T_p + F_p + F_n)} \quad (9)$$

۲-۵- مجموعه داده های مورد استفاده

فقدان یک مجموعه داده جامع از تصاویر SAR که کلیه پیکسل‌های آن‌ها دارای برچسب معتبر و مورد تایید باشد یکی از چالش‌های اساسی در کاربرد شناسایی لکه‌های نفتی است که منجر به عدم تصمیم‌گیری منسجم در مقایسه روش‌های پیشنهادی مقالات می‌گردد. در سال ۲۰۱۹ محققان نویسنده در [۲۸] اقدام به تهیه یک مجموعه داده جامع برچسب‌دار از بخش‌های مختلف تصویر نمودند. در مجموعه داده مذکور تصاویر SAR ماهواره‌ای حاوی مناطق دریایی آلوده به نفت از طریق پایگاه داده آژانس فضایی اروپا (ESA)، مرکز دسترسی باز (<https://scihub.copernicus.eu/>) Copernicus جمع‌آوری و اطلاعات مربوط به مختصات جغرافیایی و زمان‌بندی رویداد آلودگی توسط آژانس ایمنی دریایی اروپا (EMSA) از طریق سرویس CleanSeaNet ارائه گردیده است. بنابراین نواحی تیره‌ای که در هر تصویر به عنوان نشت نفت برچسب خورده است مورد تایید توسط سوابق EMSA می‌باشد. این مجموعه داده حوادث آلودگی نفتی از ۲۸ سپتامبر ۲۰۱۵ تا ۳۱ اکتبر ۲۰۱۷ که تصاویر آن توسط ماهواره اروپایی Sentinel-1 در باند C و با قطبش VV اخذ گردیده است را پوشش می‌دهد [۲۸]. مرحله پیش‌پردازش صورت گرفته بر روی تصاویر SAR خام پس از مشخص شدن نواحی مورد نظر شامل تغییر مقیاس تصاویر با ابعاد ۶۵۰×۱۲۵۰ و اعمال کالیبراسیون رادیومتر، اعمال فیلتر میانه ۷×۷ به منظور کاهش نویز اسپیکل، و در نهایت اعمال تبدیل خطی از dB به درخشندگی می‌باشد. مجموعه داده ایجاد شده شامل ۱۱۱۲ تصویر بوده و در ۵ کلاس از جمله لکه نفتی، شبه لکه نفتی، کشتی، خشکی و دریا (پس‌زمینه) برچسب‌گذاری شده است.

با توجه به چالش‌های موجود در شناسایی لکه‌های نفتی در تصاویر SAR و نیز عدم تعادل بین نمونه‌های مربوط به هر کلاس، نویسندگان در [۲۸] تلاش کردند که یک مجموعه داده متعادل ارائه

۴- آزمایشات و ارزیابی نتایج

همانطور که اشاره شد، با توجه به تنوع طراحی‌های صورت گرفته به منظور دستیابی به دقت بالاتر شبکه‌های مورد نظر توسط دو مجموعه داده CamVid و مجموعه داده تصاویر SAR [۲۰] مورد آموزش قرار گرفتند. در واقع برای ارزیابی کلی مدل ارائه شده و اطمینان از اینکه مدل عملکرد خوبی در بخش‌بندی معنایی تصویر دارد، بنابراین ابتدا با استفاده از مجموعه داده CamVid، عملکرد بخش‌بندی مدل را ارزیابی می‌کنیم و سپس با اعمال تغییرات مناسب در مدل بر روی مجموعه داده SAR و با هدف بخش‌بندی لکه‌های نفتی، عملکرد هر یک از مدل‌های معرفی شده در بخش قبل مورد ارزیابی قرار گرفته و نتایج آن در این بخش قابل مشاهده است. شایان ذکر است فرایند ارزیابی بدون در نظر گرفتن افزونگی داده صورت می‌گیرد.

در این بخش ابتدا به ارزیابی مدل جدیدی می‌پردازیم که از ترکیب شبکه ShuffleNet و شبکه کانولوشنی آتروس به عنوان بخش رمزگذار و ترکیبی از لایه‌های دیکانولوشن، کانولوشن ترانهاده، برش به عنوان رمزگشا و در ۲۰۲ لایه طراحی شده است. با توجه به اینکه در طراحی معماری شبکه از مدل Vgg16 الهام گرفته شده، مسیرهای نمونه برداری ویژگی از مسیر رمزگذاری (استخراج ویژگی) به مسیر رمزگشایی وارد می‌شود. به منظور ارزیابی این شبکه ابتدا با به کارگیری مجموعه داده CamVid با در نظر گرفتن ۱۱ کلاس معمول، به بخش-بندی تصاویر می‌پردازیم. نتایج پیاده سازی مدل فوق در جدول شماره ۱ قابل مشاهده است.

نظر گرفته شده است. همچنین با هدف به حداقل رساندن زیان، تابع آنتروپی متقابل در نظر گرفته شده که از رابطه ۹ محاسبه می‌شود.

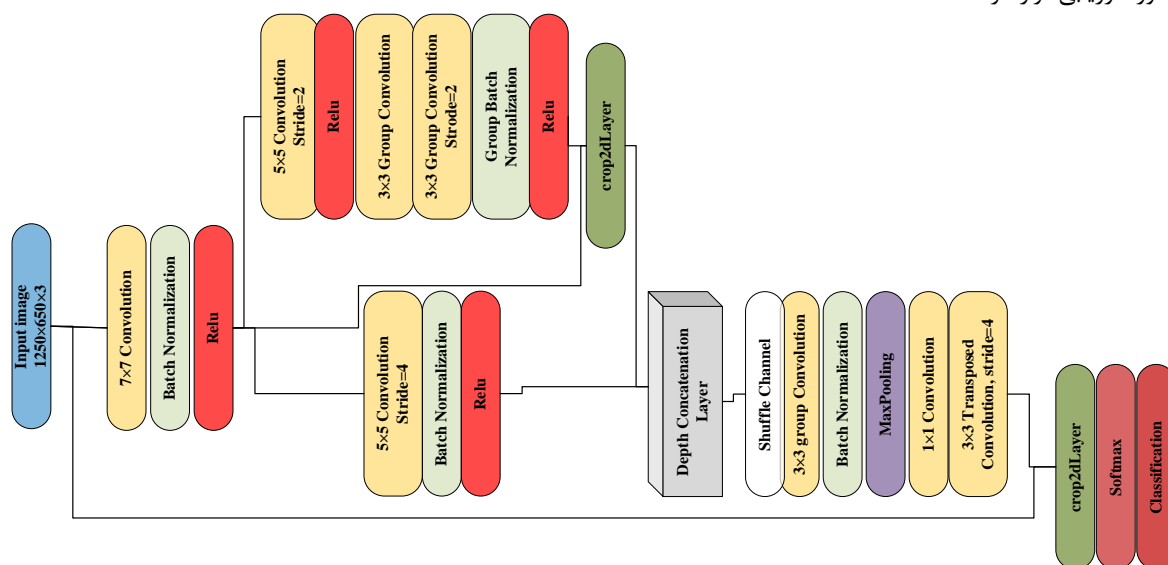
$$H(p, q) = \sum_i p_i \log q_i \quad (10)$$

که در آن p برچسب رمزگذاری شده اولیه و q بردار احتمالات کلاس پیش‌بینی شده می‌باشد.

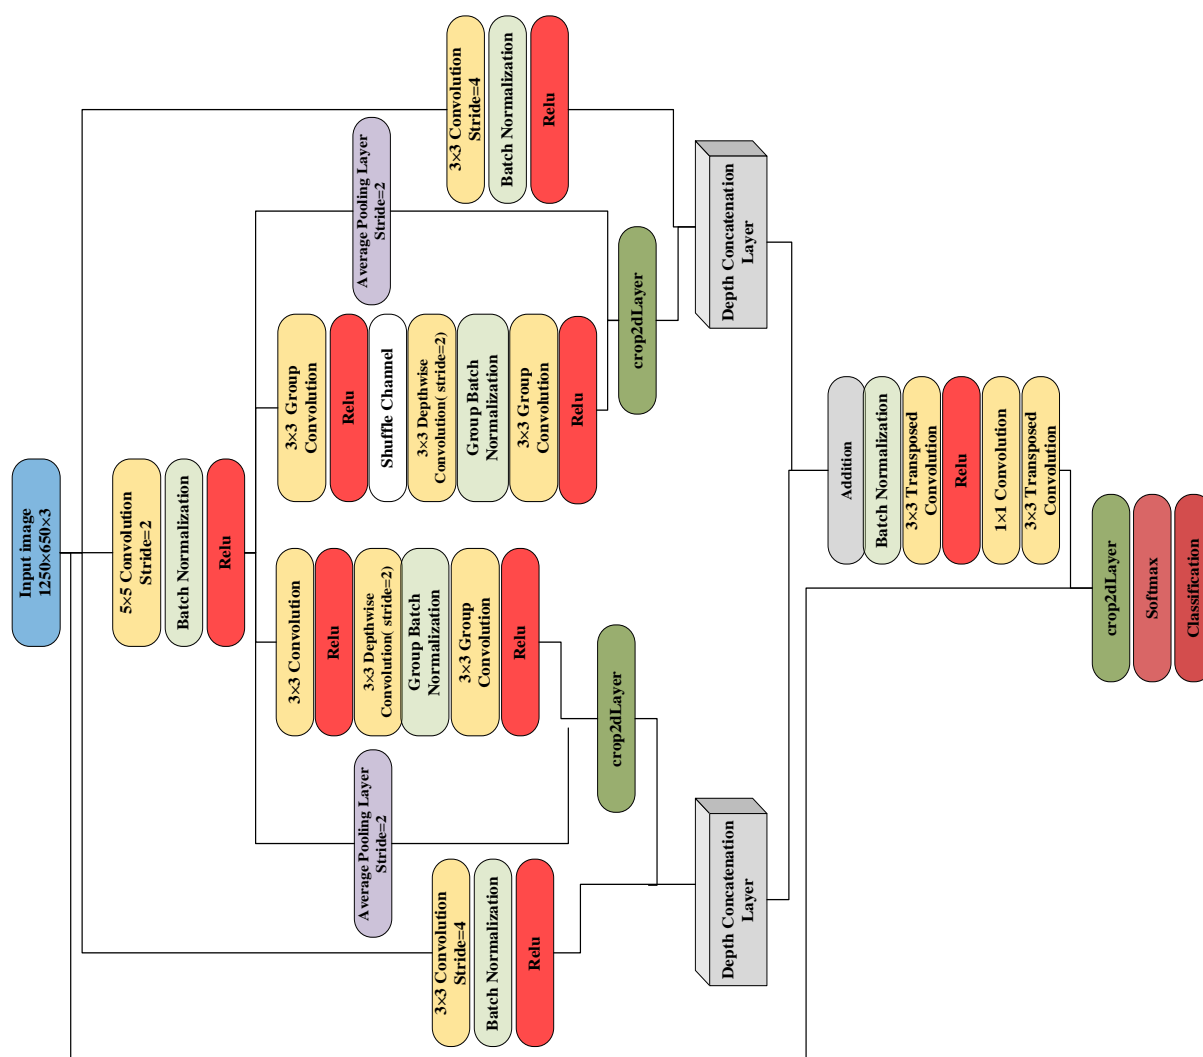
ارزیابی و مقایسه روش پیشنهادی با دیگر روش‌ها از جمله DeepLabV3+، هر ۴ مدل ResNet18، MobileNetV2، Xception و ResNet50 به عنوان رمزگذار پیاده‌سازی گردید. شبکه‌هایی که با تعداد پارامترهای کمتری همگرا شده و در نتیجه هزینه محاسباتی کمتری دارند، به شرط داشتن دقت بخش‌بندی مناسب در اولویت انتخاب قرار می‌گیرند.

طراحی کلی روش‌های پیشنهاد شده در این مقاله در شکل‌های شماره ۵ و ۶ نشان داده شده‌اند.

علاوه بر آن، بلوک‌های معرفی شده در بخش ۲ نیز در آرایش و تعداد لایه‌های متفاوت در شناسایی لکه‌های نفتی مورد استفاده قرار گرفته‌اند. در شکل شماره ۲ شماتیک بلوک‌های مورد استفاده در شبکه‌های پیشنهادی نشان داده شده است که به تنهایی و به صورت ترکیبی برای شناسایی لکه‌های نفتی مورد استفاده قرار گرفته‌اند. در واقع طرح پیشنهادی سوم شبکه‌ای طراحی شده بر مبنای استفاده از بلوک شکل ۲-الف)، طرح پیشنهادی چهارم استفاده از بلوک شکل ۲-ج)، طرح پیشنهادی پنجم بر اساس بلوک شکل ۳ و در نهایت طرح پیشنهادی ششم شبکه‌ای ترکیبی از مدل‌های پیشنهادی فوق است. این بلوک‌ها به صورت سری و موازی با هم در تعداد لایه‌های مختلف مورد ارزیابی قرار گرفتند.



شکل (۵): مدل پیشنهادی اول




شکل (۶): مدل پیشنهادی دوم

ج

جدول (۲): پارامترهای ارزیابی مدل پیشنهادی مبتنی بر شافلنت

Global Accuracy	Mean Accuracy	Mean IoU	Weighed IoU	Mean BFScore
0.8905	0.5813	0.5049	0.8068	0.5402

همچنین نمونه ارزیابی کیفی شبکه پیشنهادی در شکل شماره ۷ قابل مشاهده است.



(ب)

(الف)

شکل (۷): بخش بندی معنایی تصویر. (الف) تصویر اصلی. (ب) تصویر بخش بندی شده با روش پیشنهادی مبتنی بر شافلنت

نتایج پیاده سازی مدل های ترکیبی DeepLabv3+ با شبکه های از پیش آموزش یافته در کاربرد شناسایی لکه های نفتی و محاسبه

جدول (۱): نتایج پیاده سازی مدل ترکیبی پیشنهادی مبتنی بر شافل - نت

classes	Accuracy	IoU	MeanBFScore
Sky	0.9405	0.8968	0.8659
Building	0.9395	0.8216	0.6022
Pole	0.00014	0.00014	0.0099
Road	0.9695	0.9208	0.7548
Pavement	0.7887	0.6743	0.6482
Tree	0.8804	0.7556	0.6381
Sign_Symbol	0.2345	0.2107	0.2329
Fence	0.4872	0.3586	0.3083
Car	0.8539	0.7017	0.5867
Pedestrian	0.1014	0.0871	0.2549
Bicyclist	0.2968	0.1765	0.1990

پارامترهای محاسبه شده مربوط به بخش ارزیابی شبکه نیز به صورت میانگین در جدول ۲ نشان داده شده است.

در شناسایی لکه‌های نفتی و شبه‌لکه نفتی دست یافته است و به عبارتی شناسایی لکه های نفتی را به میزان ۷/۸٪ و شبه لکه‌های نفتی را به میزان ۷/۳٪ در مقدار IoU بهبود داده است.


نتایج ارزیابی کیفی بخش‌بندی در مدل‌های ارائه شده در جدول ۳ در شکل شماره ۸ قابل مشاهده است. بر این اساس با اختصاص برجسب به پیکسل‌های مربوط به هر کلاس، تصاویر مرجع ایجاد و پس از آموزش شبکه‌ها نتایج ارزیابی دو تصویر نمونه قابل مشاهده است. نواحی مشخص شده با رنگ فیروزه‌ای نواحی نشت نفت، نواحی سبز نواحی خشکی، رنگ قرمز نمایانگر شبه‌لکه نفتی، قهوه‌ای نشانگر وجود کشتی در تصویر و نواحی آب (مشکی) به عنوان پس‌زمینه در بخش-بندی مشخص می‌شوند. قابلیت شناسایی نواحی مورد نظر توسط روش پیشنهادی در تصاویر کاملاً قابل مشاهده است.

همانطورکه در بخش ۳ ذکر شد، در این پژوهش شبکه‌های متنوعی آموزش یافته و نتایج تست و ارزیابی شبکه‌های پیشنهادی در بخش ۳ برای ۳۰ تکرار در جدول شماره ۵ قابل مشاهده است. هدف از ارائه و تست مدل‌های فوق بیان تاثیر مثبت استفاده از مخلوط کردن کانال در فرایند بخش‌بندی و شناسایی لکه‌های نفتی در آب‌های آزاد می باشد.

جدول (۵): پارامترهای ارزیابی به دست آمده در مدل های پیشنهادی

مدل	تعداد لایه	Global Accuracy	Mean Accuracy	Mean IoU	Weighted IoU	Mean BScore
Our_design_1	186	0.8751	0.3493	0.2304	0.8105	0.4626
Our_design_2	211	0.8714	0.5205	0.3161	0.8198	0.3411
Our_design_3	106	0.7229	0.3274	0.1876	0.6784	0.1807
Our_design_4	211	0.9021	0.2866	0.2463	0.8200	0.6051
Our_design_5	208	0.8974	0.2879	0.2425	0.8161	0.5616
Our_design_۶	195	0.9463	0.5539	0.4900	0.9075	0.7037

بر اساس نتایج قابل مشاهده در جدول شماره ۴، بهترین شبکه از میان شبکه‌های پیشنهادی در شرایط یکسان از لحاظ مجموعه داده و تنظیمات شبکه، مدل ترکیبی از هر دو نوع بلوک شکل ۲- (الف و ب) با افزایش یک در میان و البته با ایجاد تغییرات در تعداد کانال‌ها و سایز فیلترها توسط روش پیشنهادی ۶ ارائه شده است. به منظور ارزیابی کیفی دو نمونه از تصاویر بخش‌بندی شده توسط روش پیشنهادی ۶ در شکل شماره ۹ نشان داده شده است. در هر دو تصویر لکه‌های نفتی با دقت بالا تشخیص داده شده‌اند.



SAR images

پارامتر IoU مربوط به کلیه کلاس ها با تعداد لایه‌های مختلف در مقایسه با مدل پیشنهادی در جدول ۳ قابل مشاهده است.

جدول (۳): پیاده‌سازی مدل‌های ترکیبی DeepLabv3+ پارامتر IoU


مدل	Sea surface	Oil spill	Look-alike	ship	land	mIoU
ResNet18	0.958	0.436	0.47	0.396	0.868	0.625
ResNet50	0.946	0.334	0.409	0.318	0.711	0.543
Inception	0.81	0.297	0.216	0.1	0.080	0.300
Resnetv2	0.955	0.389	0.455	0.396	0.897	0.618
Xception	0.947	0.446	0.431	0.358	0.908	0.618
Mobile Netv2	0.967	0.481	0.504	0.219	0.921	0.618

با توجه به نتایج به‌دست آمده مشخص گردید که بالاترین عملکرد کلی بر اساس بیشترین مقدار IoU از ترکیب DeepLabv3+ و شبکه ResNet18 با مقدار ۰/۶۲۵۴ به‌دست آمده است و بر همین اساس با اختلاف ناچیز ترکیب آن با Xception، و روش پیشنهادی در رتبه بعدی قرار دارند. همانطورکه مشاهده می‌شود روش پیشنهادی در کلیه کلاس‌ها به جز کشتی از سایر روش‌ها پیشی گرفته است. بر اساس معیار حداکثر IoU، این پارامتر برای کلاس‌های "lookalike" و "sea surface" بیشترین مقدار می‌باشد. در رابطه با کلاس "نشت نفت" که از اهمیت ویژه‌ای برخوردار است و می‌توان آن را به‌عنوان هدف اصلی در این فرایند دانست، میزان بیشترین دقت IoU با ۰/۴۸۱۴ توسط روش پیشنهادی به‌دست آمده است. همچنین نتایج مقایسه‌ای فرایند آموزش روش های مورد اشاره در جدول شماره ۳ به لحاظ تعداد لایه‌ها و زمان مورد نیاز آموزش آن‌ها در جدول شماره ۴ قابل مشاهده است. علی رغم پایین تر بودن دقت شناسایی کشتی در مدل پیشنهادی، می‌توان از مدل‌های متنوعی که متشکل از بلوک‌های شافل‌نت هستند در بخش‌بندی معنایی تصاویر استفاده نمود.

جدول (۴): مقایسه تعداد لایه ها و زمان آموزش مدل های مطرح شده در جدول ۳

مدل	تعداد لایه های مدل های جدول ۳	تعداد تکرار	مدت زمان مورد نیاز فرایند آموزش
ResNet18	۱۰۰	۳۰	۰۴:۱۵:۳۸
ResNet50	۲۰۶	۳۰	۱۹:۴۹:۵۸
Inception	۸۵۳	۳۰	۴۱:۰۳:۳۲
Resnetv2	۲۰۵	۳۰	۲۰:۴۴:۱۶
Xception	۱۸۶	۳۰	۱۲:۴۵:۱۵
MobileNetv2	۲۰۲	۳۰	۰۳:۴۵:۵۰
مدل پیشنهادی			

همانطورکه در جداول ۳ و ۴ قابل مشاهده است، مدل پیشنهادی در کمترین زمان نسبت به سایر روش های مورد مقایسه به نتایج بهتری



شکل (۹): ارزیابی کیفی مدل پیشنهادی ۶ با بالاترین دقت


در مطالعات بعدی بهبود دقت و ارائه روش های موثر با ترکیب شبکه های از پیش آموزش یافته مورد بررسی قرار خواهد گرفت.

۵- نتیجه گیری

بخش بندی معنایی تصاویر به عنوان یکی از چالش های آنالیز تصویر برای محققان این حوزه شناخته شده است که اخیراً به واسطه توسعه شبکه های عصبی عمیق می تواند به صورت یک راه حل یکپارچه دیده شود. با توسعه و گسترش هر چه بیشتر شبکه های عصبی عمیق، هر روز مدل های پیشرفته تری مطرح می شوند که از معماری هایی پیچیده برای ارائه راهکارهای حل مسایل استفاده می کنند. در بسیاری موارد با استفاده از مفاهیمی از جمله به هم زدن کانال های ویژگی می توان علاوه بر کاهش پیچیدگی شبکه به دقت قابل قبولی دست یافت. بر اساس مطالب مطرح شده در این مقاله استفاده از شبکه های مبتنی بر مخلوط کردن کانال های ویژگی به همراه استفاده از کانولوشن های گروهی، آتروس و در نهایت لایه هایی به منظور رمزگشایی ویژگی ها می توان به دقت قابل قبولی در کاربرد شناسایی لکه های نفتی دست یافت. همچنین، نتایج نشان می دهند علاوه بر کاهش پیچیدگی های محاسباتی، بخش بندی لکه های نفتی به مراتب بهتر از سایر روش ها است. معماری شبکه ارائه شده مبتنی بر معماری Vgg16 می باشد. دقت کلی، صحت، همپوشانی بر واحد، IoU و وزن دار و امتیاز BF به عنوان پارامترهای ارزیابی در نظر گرفته شده اند. در روش ارائه شده دقت بخش بندی لکه های نفتی و شبه لکه های نفتی به ترتیب به میزان $7/8$ و $7/3$ نسبت به روش های پیشین شبیه سازی شده بهبود یافته است. در ادامه طراحی مدل های ترکیبی از شبکه های مطرح کنونی و معرفی بلوک های جدید با دقت بهتر و پیچیدگی محاسباتی کمتر مورد بررسی قرار خواهد گرفت.

مراجع

- [1] A. Beigi and A. Akbarian, "Profit increasing in smart grid market via actor-critic reinforcement learning," Journal of Iranian Association of Electrical and Electronics Engineers, pp. 0-0.



روش پیشنهادی

شکل (۸): آنالیز کیفی پیاده سازی مدل های ترکیبی و روش


پیشنهادی

و در نهایت میزان دقت IoU/ برای هر دو تصویر شکل شماره ۹ برای کلاس های مورد نظر در جدول شماره ۶ بیان شده است.

جدول (۶): IoU% مربوط به تصاویر شکل ۹

Classes	IoU%	
	(a)	(b)
Sea-Surface	98.30	96.44
Oil-Spill	53.46	35.14
Look-alike	NAN	NAN
Ship	0	0
Land	NAN	NAN

در مجموع با توجه به دامنه نامحدود طراحی شبکه های عصبی عمیق که بسیار متنوع هستند و اهمیت بکارگیری صحیح آن ها در کاربردهای مختلف به نظر می رسد که با استفاده از شبکه های شافل نت می توان با دقت مناسبی به شناسایی لکه های نفتی در آب های آزاد دست یافت.



- [14] Al-Ruzouq, R., Gibril, M.B.A., Shanableh, A., Kais, A., Hamed, O., Al-Mansoori, S. and Khalil, M.A., "Sensors, features, and machine learning for oil spill detection and monitoring: A review." *Remote Sensing*, Vol.12, No.20, p.3338.2020.
- [15] Carvalho, G.D.A., Minnett, P.J., Miranda, F.P.D., Landau, L. and Moreira, F., "The Use of a RADARSAT-Derived Long-Term Dataset to Investigate the Sea Surface Expressions of Human-Related Oil Spills and Naturally Occurring Oil Seeps in Campeche Bay, Gulf of Mexico." *Canadian Journal of Remote Sensing*, Vol.42, No.3, pp.307-321.2016.
- [16] Topouzelis, K.N., "Oil spill detection by SAR images: dark formation detection, feature extraction and classification algorithms." *Sensors*, Vol.8, No.10, pp.6642-6659., 2008.
- [17] Fingas, M. and Brown, C., "Review of oil spill remote sensing," *Marine pollution bulletin*, vol. 83, no. 1, pp. 9-23, 2014.
- [18] Song, D., Ding, Y., Li, X., Zhang, B. and Xu, M., "Ocean oil spill classification with RADARSAT-2 SAR based on an optimized wavelet neural network," *Remote Sensing*, vol. 9, no. 8, p. 799, 2017.
- [19] Genovez, P., Ebecken, N., Freitas, C., Bentz, C. and Freitas, R., "Intelligent hybrid system for dark spot detection using SAR data." *Expert Systems with Applications*, 81, pp.384-397., 2017.
- [20] Lupidi, A., Staglianò, D., Martorella, M. and Berizzi, F., "Fast detection of oil spills and ships using SAR images." *Remote Sensing*, Vol.9, No.3, p.230., 2017.
- [21] Mera, D., Bolon-Canedo, V., Cotos, J.M. and Alonso-Betanzos, A., "On the use of feature selection to improve the detection of sea oil spills in SAR images." *Computers & Geosciences*, 100, pp.166-178, 2017.
- [22] Raeisi, A., Akbarizadeh, G. and Mahmoudi, A., "Combined method of an efficient cuckoo search algorithm and nonnegative matrix factorization of different zernike moment features for discrimination between oil spills and lookalikes in SAR images." *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, Vol.11, No.11, pp.4193-4205, 2018.
- [23] Aghaei, N., Akbarizadeh, G., & Kosarian, A. "GreyWolfLSM: an accurate oil spill detection method based on level set method from synthetic aperture radar imagery." *European Journal of Remote Sensing*, pp.1-18, 2022.
- [24] Zeng, K. and Wang, Y., "A deep convolutional neural network for oil spill detection from spaceborne SAR images," *Remote Sensing*, vol. 12, no. 6, p. 1015, 2020.
- [25] Temitope Yekeen, S. and Balogun, A.L., "Advances in remote sensing technology, machine learning and deep learning for marine oil spill detection, prediction and vulnerability assessment," *Remote Sensing*, vol. 12, no. 20, p. 3416, 2020.
- [26] Nieto-Hidalgo, M., Gallego, A.J., Gil, P. and Pertusa, A., "Two-stage convolutional neural network for ship and spill detection using SLAR images," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 56, no. 9, pp. 5217-5230, 2018.
- [27] Krestenitis, M., Orfanidis, G., Ioannidis, K., Avgerinakis, K., Vrochidis, S. and Kompatsiaris, I., "Oil spill identification from satellite images using deep neural networks," *Remote Sensing*, vol. 11, no. 15, p. 1762, 2019.
- [28] Chen, L.C., Papandreou, G., Kokkinos, I., Murphy, K. and Yuille, A.L., "Deeplab: Semantic image
- [2] M. Hojjat, M. Javidi, and S. Goldani, "Transmission Loss Allocation in Pool-Bilateral Environment Using Artificial Neural Networks," *Journal of Iranian Association of Electrical and Electronics Engineers*, vol. 11, no. 1, pp. 49-57, 2014.
- [3] R. Hooshmand and M. Moazzami, "Short-Term Nodal Congestion Price Forecasting in Large-Scale Power Market Using ANN with Genetic Optimization Training," (in eng), *Journal of Iranian Association of Electrical and Electronics Engineers*, Research vol. 11, no. 1, pp. 37-48, 2014. [Online]. Available: <http://jiaeee.com/article-1-143-en.html>.
- [4] A. Hokmabadi, A. Zakeri, and A. Sherafat, "Sidelobe Reduction for Similar Targets in Radar Pulse Compression Using Neural Network," (in eng), *Journal of Iranian Association of Electrical and Electronics Engineers*, Research vol. 14, no. 2, pp. 65-73, 2017. [Online]. Available: <http://jiaeee.com/article-1-389-en.html>.
- [5] Emadalelami, M., Majidi, H., & Haghighi, M. A., "Two-Stage Model to Detect Electricity Fraud in The Distribution Network Using Deep Learning." *Journal of Iranian Association of Electrical and Electronics Engineers*, 0-0.
- [6] Lateef, F. and Ruichek, Y., "Survey on semantic segmentation using deep learning techniques." *Neurocomputing*, 338, pp.321-348. 2019.
- [7] Shahmiri, A., Safabakhsh, R. and Dezhkam, R., "Automatic Farsi Typo Correction Using a Hybrid Neural Network." *Journal of Iranian Association of Electrical and Electronics Engineers*, Vol 5, No.1, pp.16-29, 2008.
- [8] Mavaddati, S., "ECG Arrhythmia Classification Based on Wavelet Packet Transform and Sparse Non-Negative Matrix Factorization." *Journal of Iranian Association of Electrical and Electronics Engineers*, 17(3), pp.119-128. 2020.
- [9] P. Parsa and R. Safabakhsh, "A New Method for Image Segmentation based on Multi-Objective Differential Evolution Fuzzy Clustering," (in eng), *Journal of Iranian Association of Electrical and Electronics Engineers*, Research vol. 13, no. 2, pp. 103-114, 2016. [Online]. Available: <http://jiaeee.com/article-1-68-en.html>.
- Seyedarabi H, Aghagolzadeh A, Khanmohammadi S, Kabir E. "Analysis and Synthesis of Facial Expressions by Feature-Points Tracking and Deformable Model." *Journal of Iranian Association of Electrical and Electronics Engineers*. 2007; 4 (1) :11-19. URL: <http://jiaeee.com/article-1-260-en.html>.
- [10] Akbarizadeh, G., "A new statistical-based kurtosis wavelet energy feature for texture recognition of SAR images." *IEEE Transactions on Geoscience and Remote Sensing*, Vol.50, No.11, pp.4358-4368. 2012.
- [11] Alpers, W., Holt, B. and Zeng, K., "Oil spill detection by imaging radars: Challenges and pitfalls." *Remote Sensing of Environment*, 201, pp.133-147, 2017.
- [12] Solberg, A.H., Brekke, C. and Husoy, P.O., "Oil spill detection in Radarsat and Envisat SAR images." *IEEE Transactions on Geoscience and Remote Sensing*, Vol.45, No.3, pp.746-755. 2007.
- [13] Angelliaume, S., Dubois-Fernandez, P.C., Jones, C.E., Holt, B., Minchew, B., Amri, E. and Mieggebielle, V., "SAR imagery for detecting sea surface slicks: Performance assessment of polarization-dependent parameters." *IEEE Transactions on Geoscience and Remote Sensing*, Vol.56, No.8, pp.4237-4257.2018.

- connections on learning," in Thirty-first AAAI conference on artificial intelligence, 2017.
- [43] Howard, A.G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Andreetto, M. and Adam, H., "Mobilenets: Efficient convolutional neural networks for mobile vision applications," arXiv preprint arXiv:1704.04861, 2017.
- [44] Ma, N., Zhang, X., Zheng, H.T. and Sun, J., "Shufflenet v2: Practical guidelines for efficient cnn architecture design," in Proceedings of the European conference on computer vision (ECCV), 2018, pp. 116-131, 2018.
- [45] Hu, X. and Wang, H., "Efficient fast semantic segmentation using continuous shuffle dilated convolutions," IEEE Access, Vol. 8, pp. 70913-70924, 2020.
- [46] He, K., Zhang, X., Ren, S. and Sun, J., "Spatial pyramid pooling in deep convolutional networks for visual recognition," IEEE transactions on pattern analysis and machine intelligence, Vol. 37, No. 9, pp. 1904-1916, 2015.
- [47] He, K., Zhang, X., Ren, S. and Sun, J., "Deep residual learning for image recognition," in Proceedings of the IEEE conference on computer vision and pattern recognition, pp. 770-778, 2016.
- [48] Long, J., Shelhamer, E. and Darrell, T., "Fully convolutional networks for semantic segmentation," in Proceedings of the IEEE conference on computer vision and pattern recognition, pp. 3431-3440, 2015.
- [49] Chen, L.C., Zhu, Y., Papandreou, G., Schroff, F. and Adam, H., "Encoder-decoder with atrous separable convolution for semantic image segmentation," in Proceedings of the European conference on computer vision (ECCV), pp. 801-818, 2018.
- [50] He, K., Zhang, X., Ren, S. and Sun, J., "Going deeper with convolutions," in Proceedings of the IEEE conference on computer vision and pattern recognition, pp. 1-9, 2015.
- segmentation with deep convolutional nets, atrous convolution, and fully connected crfs," IEEE transactions on pattern analysis and machine intelligence, vol. 40, no. 4, pp. 834-848, 2017.
- [29] Li, X., Liu, B., Zheng, G., Ren, Y., Zhang, S., Liu, Y., Gao, L., Liu, Y., Zhang, B. and Wang, F., "Deep-learning-based information mining from ocean remote-sensing imagery," National Science Review, Vol. 7, No. 10, pp. 1584-1605, 2020.
- [30] Krestenitis, M., Orfanidis, G., Ioannidis, K., Avgerinakis, K., Vrochidis, S. and Kompatsiaris, I., "Early identification of oil spills in satellite images using deep CNNs," in International Conference on Multimedia Modeling, Springer, pp. 424-435, 2019.
- [31] Chen, G., Li, Y., Sun, G. and Zhang, Y., "Application of deep networks to oil spill detection using polarimetric synthetic aperture radar images," Applied Sciences, Vol. 7, No. 10, p. 968, 2017.
- [32] Y. Bengio, P. Lamblin, D. Popovici, and H. Larochelle, "Greedy layer-wise training of deep networks," in Advances in neural information processing systems, 2007, pp. 153-160.
- [33] Bengio, Y., Lamblin, P., Popovici, D. and Larochelle, H., "A deep neural network for oil spill semantic segmentation in Sar images," in 2018 25th IEEE International Conference on Image Processing (ICIP), IEEE, pp. 3773-3777, 2018.
- [34] Yekeen, S.T., Balogun, A.L. and Yusof, K.B.W., "A novel deep learning instance segmentation model for automated marine oil spill detection," ISPRS Journal of Photogrammetry and Remote Sensing, vol. 167, pp. 190-200, 2020.
- [35] Yu, Y., Zhang, K., Yang, L. and Zhang, D., "Fruit detection for strawberry harvesting robot in non-structural environment based on Mask-RCNN," Computers and Electronics in Agriculture, Vol. 163, p. 104846, 2019.
- [36] Cantorna, D., Dafonte, C., Iglesias, A. and Arcay, B., "Oil spill segmentation in SAR images using convolutional neural networks. A comparative analysis with clustering and logistic regression algorithms," Applied Soft Computing, Vol. 84, p. 105716, 2019.
- [37] Song, D., Zhen, Z., Wang, B., Li, X., Gao, L., Wang, N., Xie, T. and Zhang, T., "A novel marine oil spillage identification scheme based on convolution neural network feature extraction from fully polarimetric SAR imagery," IEEE Access, Vol. 8, pp. 59801-59820, 2020.
- [38] Zhang, X., Zhou, X., Lin, M. and Sun, J., "Shufflenet: An extremely efficient convolutional neural network for mobile devices," in Proceedings of the IEEE conference on computer vision and pattern recognition, pp. 6848-6856, 2018.
- [39] Chollet, F., "Xception: Deep learning with depthwise separable convolutions," in Proceedings of the IEEE conference on computer vision and pattern recognition, pp. 1251-1258, 2017.
- [40] Xie, S., Girshick, R., Dollár, P., Tu, Z. and He, K., "Aggregated residual transformations for deep neural networks," in Proceedings of the IEEE conference on computer vision and pattern recognition, pp. 1492-1500, 2017.
- [41] Krizhevsky, A., Sutskever, I. and Hinton, G.E., "Imagenet classification with deep convolutional neural networks," Advances in neural information processing systems, Vol. 25, pp. 1097-1105, 2012.
- [42] Szegedy, C., Ioffe, S., Vanhoucke, V. and Alemi, A.A., "Inception-v4, inception-resnet and the impact of residual

زیر نویس ها

¹ Synthetic Aperture Radar

² Deep Convolutional Neural Network

³ Oil Spill Convolutional Network

⁴ Convolutional Neural Network

⁵ Side-looking Airborne Radar

⁶ Polarimetric Synthetic Aperture Radar

⁷ Stacked Auto-Encoder

⁸ Deep Belief Network

⁹ European Space Agency

¹⁰ European Maritime Safety Agency

¹¹ Feature Pyramid Network

¹² Intersection Over Union

¹³ Principal Component Analysis

¹⁴ Support Vector Machine with a Radial Basis Function kernel

¹⁵ Floating-Point Operations Per Second

¹⁶ Memory Access Cost

¹⁷ Spatial Pyramid Pooling

¹⁸ Atrous Spatial Pyramid Pooling

¹⁹ Depth Concatenate

²⁰ Ground Truth