

پیشنهاد یک شبکه عصبی کانولوشنی چندمقیاسه برای آشکارسازی خودکار ابرها و

سایه ابرها در تصاویر ماهواره گائوفن-۱

مهدی خوش برش ماسوله^۱، رضا شاه حسینی^{۲*}

۱- دانشجوی دکتری، دانشکده مهندسی نقشه برداری و اطلاعات مکانی، پردیس دانشکده‌های فنی، دانشگاه تهران
۲- استادیار دانشکده مهندسی نقشه برداری و اطلاعات مکانی، پردیس دانشکده‌های فنی، دانشگاه تهران

تاریخ دریافت مقاله: ۱۳۹۸/۱۰/۱۳ تاریخ پذیرش مقاله: ۱۳۹۹/۱۱/۰۷

چکیده

یک گام مهم در پیش‌پردازش تصاویر ماهواره‌ای با قدرت تفکیک مکانی بالا، بازسازی اطلاعات آلوده به پوشش ابرها و سایه ابرها است. اولین گام در فرآیند خودکار بازسازی اطلاعات آلوده به ابرها و سایه ابرها، مرحله آشکارسازی خودکار ابرها و سایه ابرها است. این مرحله به دلیل عملکرد نسبتاً نامناسب روش‌های موجود در صحنه‌های پیچیده در تصاویر با قدرت تفکیک مکانی بالا، یک چالش قابل توجه است. در سال‌های اخیر، دقت فرآیند آشکارسازی ابرها و سایه ابرها با به‌کارگیری شبکه‌های عصبی کانولوشنی عمیق بهبود یافته است. مسأله افزایش تعمیم‌پذیری برای آشکارسازی ابرها و سایه ابرها یکی از مشکل‌های شبکه‌های عصبی کانولوشنی عمیق است. در این تحقیق، راه‌حلی برای مشکل تعمیم‌پذیری آشکارسازی ابرها و سایه ابرها در تصاویر ماهواره گائوفن-۱ ارائه شده است. در این راستا، یک معماری یادگیری عمیق چندمقیاسه (MultiCloud-Net) مبتنی بر فیلترهایی با ابعاد مختلف برای آشکارسازی دقیق ابرها و سایه ابرها در تصاویر تک زمانه ماهواره گائوفن-۱ بر اساس طراحی بلوک‌های باقی‌مانده جدید مبتنی بر حذف تصادفی عمق، پیشنهاد شده است. در معماری پیشنهادی، فرآیند آشکارسازی ابرها و سایه ابرها بر اساس تابع آنتروپی متقاطع وزن‌دار برای حل مسأله عدم تعادل پیکسل‌های هدف، برای تولید نقشه نهایی صورت می‌گیرد. روش پیشنهادی با استفاده از ۱۲ تصویر ماهواره گائوفن-۱ با توزیع جهانی و با استفاده از سرویس رایانش ابری گوگل کولب پیاده‌سازی و اعتبارسنجی شده است. نتایج با استفاده از مجموعه تصاویر ماهواره گائوفن-۱، با کسب میانگین نمره $F1$ و ضریب شباهت ژاکارد برابر ۹۷ و ۹۶ برای کلاس ابر و مقادیر ۹۵/۵ و ۹۴/۵ برای کلاس سایه ابر و با ضریب کاپای ۰/۹۸ نشان‌دهنده دقت مناسب‌تر در آشکارسازی خودکار جزئیات حاشیه‌ای ابرها و سایه ابرها و دستیابی به هزینه محاسباتی کمتر در مقایسه با یک روش پیشرفته یادگیری عمیق و یک روش پیشرفته آماری است.

کلید واژه‌ها: گائوفن-۱، ابرها، سایه ابرها، یادگیری عمیق، کانولوشن چندمقیاسه.

* نویسنده مکاتبه کننده: گروه فتوگرامتری و سنجش‌ازدور، دانشکده مهندسی نقشه‌برداری و اطلاعات مکانی، پردیس دانشکده‌های فنی، دانشگاه تهران، تهران، ایران.

۱- مقدمه

ابرها و سایه ابرها^۱ یکی از عوامل ایجاد نابسامانی در پردازش تصاویر سنجنده‌های غیرفعال در سنجنش‌ازدور می‌باشند [۱، ۲ و ۳]. وجود پوشش ابر و سایه ابر در تصاویر سنجنش‌ازدور باعث ایجاد اختلال در فرآیندهای قطعه‌بندی، طبقه‌بندی، تناظریابی و تولید مدل‌های سه‌بعدی می‌شود [۴]. آشکارسازی دقیق ابرها و سایه ابرها، یک گام مهم در پیش‌پردازش تصاویر چندطیفی است [۵]. مهم‌ترین تحقیق‌های صورت گرفته در مورد آشکارسازی ابرها نظیر پروژه پایش جهانی توزیع ابرها از داده‌های رادیومتر پیشرفته با وضوح بسیار بالا^۲ (AVHRR) [۶]، برنامه پردازش داده‌های رادیومتر پیشرفته با وضوح بسیار بالا با هدف پایش یخ، برف و ابرها [۷]، و پروژه بین‌المللی اقلیم‌شناسی ماهواره‌ای ابرها^۳ (ISCCP) [۸]، از اطلاعات کانال‌های طیفی مادون قرمز حرارتی و با قدرت تفکیک مکانی پایین، استفاده کرده‌اند.

در سال‌های اخیر، پایش زمین با استفاده از تصاویر سنجنش‌ازدور با قدرت تفکیک مکانی بالا (در این تحقیق تصاویر ماهواره گائوفن-۱^۴ موردنظر است) بسیار موردتوجه بوده است [۹]. اغلب ماهواره‌های سنجنش‌ازدور با قابلیت تصویربرداری با قدرت تفکیک مکانی بالا، به دلیل ملاحظه‌های دستگاهی دارای کانال‌های طیفی محدود (کانال‌های قرمز، سبز، آبی و مادون قرمز نزدیک) هستند [۱۰ و ۱۱]. تصاویر ماهواره‌هایی با کانال‌های طیفی محدود، نظیر تصاویر ماهواره گائوفن-۱، اغلب پارامترهای کالیبراسیون رادیومتریکی کاملی ندارند و ناشی از عدم وجود کانال‌های مادون قرمز حرارتی و جذب بخار آب، فرآیند شناسایی دقیق ابرها و جداسازی آن‌ها از برخی عوارض

که دارای شباهت طیفی در محدوده مرئی می‌باشند، دشوار است [۱۲ و ۱۳]. در این زمینه، ارائه راهکاری با هدف آشکارسازی و حذف پوشش‌های ابرها و سایه ابرها از تصاویر با قدرت تفکیک مکانی بالا در صحنه‌های مختلف، دارای اهمیت است [۱۴]. فرآیند حذف ابرها و سایه ابرها از تصاویر، به دقت آشکارسازی ابرها و سایه ابرها وابسته است [۱۵]. جهت ارتقاء دقت آشکارسازی ابرها و سایه ابرها در تصاویر سنجنش‌ازدور با قدرت تفکیک مکانی بالا، تحقیق‌های متعددی با استفاده از روش‌های آماری تشخیص الگو [۱۶]، روش‌های متداول یادگیری ماشین نظیر ماشین بردار پشتیبان [۱۷]، و اخیراً استفاده از روش‌های یادگیری عمیق^۵ [۱۸]، صورت گرفته است. نتایج چند تحقیق اخیر با استفاده از روش‌های یادگیری عمیق بر روی کانال‌های مرئی و مادون قرمز نزدیک تصاویر ماهواره‌های ژی-یوان-۳^۶ با قدرت تفکیک مکانی ۵/۸ متر، گائوفن-۱ با قدرت تفکیک مکانی ۸ متر، و گائوفن-۲ با قدرت تفکیک مکانی ۴ متر، نشان‌دهنده بهبود دقت آشکارسازی ابرها با میانگین دقت کلی ۹۲ درصد است [۴، ۱۱ و ۱۶]، اما آشکارسازی جزئیات حاشیه‌ای ابرها و سایه ابرها ناشی از وجود عارضه‌های مختلف در این سطح از وضوح تصویر، همچنان دارای چالش مهمی می‌باشد.

در تحقیق حاضر، یک روش جدید مبتنی بر شبکه عصبی کانوولوشنی عمیق^۷ برای آشکارسازی خودکار ابرها و سایه ابرها از تصاویر ماهواره گائوفن-۱ پیشنهاد شده است. روش پیشنهادی بر مبنای تئوری شبکه‌های بازگشتی و کانوولوشنی عمیق در یک ساختار چندمقیاسه، طراحی شده است. در این تحقیق، مهم‌ترین نوآوری‌ها و سهم در توسعه حل مسأله عبارت است از:

^۱ Cloud and Cloud Shadow^۲ Advanced Very High Resolution Radiometer^۳ International Satellite Cloud Climatology Project^۴ Gaofen-1^۵ Deep Learning^۶ Zi-Yuan 3^۷ Deep Convolutional Neural Network (DCNN)

مادیس [۲۳]، بهینه‌سازی حدآستانه‌های طیفی لندست [۲۴]، ارزیابی خودکار پوشش ابر در تصاویر لندست-۷ [۲۵]، بهینه‌سازی الگوریتم *FMask* (ارائه‌شده توسط سازمان زمین‌شناسی آمریکا) برای تصاویر سنتینل-۲ [۲۶]، روش *MAJA*^۷ (ارائه‌شده توسط آژانس فضایی فرانسه) برای تصاویر سری زمانی لندست و سنتینل-۲ [۲۷]، و پردازشگر *Sen2Cor* (ارائه‌شده توسط آژانس فضایی اروپا) برای تصاویر سنتینل-۲ [۲۸]، نمونه‌هایی از روش‌های آماری برای آشکارسازی ابرها و سایه ابرها هستند که طی دهه اخیر ارائه شده‌اند. روش‌هایی که در کلاس اول قرار گرفته‌اند، در آشکارسازی ابرها و سایه ابرها از تصاویر با قدرت تفکیک مکانی بالا به دلیل عدم وجود کانال‌های مادون‌قرمز حرارتی و مشکل در حدآستانه‌گذاری به دلیل قدرت تفکیک مکانی بالا، عملکرد مناسبی ندارند.

کلاس دوم شامل روش‌های یادگیری ماشین است. روش‌های یادگیری ماشین بر اساس نمونه‌های آموزشی، اغلب فرآیند آشکارسازی ابرها و سایه ابرها را با دقت مطلوب صورت می‌دهند. روش‌های شبکه عصبی مصنوعی کم‌عمق برای تصاویر تک‌زمانه لندست [۲۹]، ماشین بردار پشتیبان برای تصاویر ورد-ویو ۲ [۳۰] و روش‌های شیء‌مبنای یادگیری ماشین برای تصاویر گائوفن-۱ [۳۱]، از جمله روش‌های یادگیری ماشین می‌باشند. روش‌های یادگیری ماشین نسبت به روش‌های آماری، نقش مؤثرتری را در آشکارسازی ابرها از تصاویر با قدرت تفکیک مکانی بالا داشته‌اند [۴] و [۱۸]، اما روش‌های معمول در یادگیری ماشین، ناشی از وابستگی زیاد به تنظیم پارامترهای پردازش، قابلیت تعمیم‌پذیری کمی دارند. تعمیم‌پذیری به معنای قابلیت استفاده از روش موردنظر برای نمونه آزمایش‌های مختلف با دقت مناسب می‌باشد [۳۲].

^۷ MAJA

(۱) یک شبکه عصبی کانولوشنی عمیق با ساختار چندمقیاسه برای آشکارسازی بهتر جزئیات حاشیه‌ای ابرها و سایه ابرها از سایر عوارض ارائه شده است.

(۲) طراحی بلوک‌های باقی‌مانده کانولوشنی مبتنی بر روش حذف تصادفی عمق در ساختار چندمقیاسه با هدف کاهش هزینه محاسبه، ارتقاء تعمیم‌پذیری و بهبود دقت نتایج آشکارسازی یکی دیگر از نوآوری‌های این تحقیق است.

(۳) در این تحقیق، برای حل مسأله عدم تعادل پیکسل‌های هدف از تابع آنتروپی متقاطع وزن‌دار^۱ استفاده شده است.

۲- پیشینه تحقیق

در چند دهه‌ی اخیر، در زمینه آشکارسازی ابرها و سایه ابرها از داده‌های مختلف سنجش‌ازدور به‌صورت تک‌زمانه^۲ یا سری زمانی^۳ نظیر تصاویر مادیس^۴ [۱۹] و [۲۰]، داده‌های رادیومتر پیشرفته با وضوح بسیار بالا [۲۱ و ۲۲]، تصاویر سری لندست^۵ [۲۳، ۲۴ و ۲۵] و تصاویر سنتینل-۲^۶ [۲۶ و ۲۷]، تحقیق‌های گسترده‌ای انجام شده است. روش‌های مورد استفاده در تحقیق‌های پیشین را می‌توان در دو کلاس به شرح زیر، طبقه‌بندی نمود.

کلاس اول شامل روش‌های آماری تشخیص الگو که بر اساس تعیین حدآستانه، فرآیند آشکارسازی ابرها و در برخی از موارد آشکارسازی سایه ابرها را اغلب بر مبنای دمای درخشندگی از طریق کانال‌های حرارتی تصاویر سنجش‌ازدور، صورت می‌دهند. روش‌های ماسک ابر

^۱ Weighted Cross Entropy^۲ Single Scene^۳ Multi-Temporal Scenes^۴ Moderate Resolution Imaging Spectroradiometer (MODIS)^۵ Landsat^۶ Sentinel-2

پردازش داده‌ها است. توسعه زیرساخت‌های رایانش آبری برای یادگیری عمیق مانند سرویس گوگل کولب از جمله راهکارهای مطلوب برای به‌کارگیری یادگیری عمیق در تحقیق‌های پردازش تصویر است. جدول (۱) تحلیل روش‌های یادگیری عمیق در زمینه آشکارسازی ابرها و سایه ابرها را نشان می‌دهد. تحلیل صورت گرفته در جدول (۱) بر اساس نوع معماری یادگیری عمیق، جزئیات مجموعه داده‌های مورد استفاده، قابلیت آشکارسازی و میانگین دقت کلی آشکارسازی در تحقیق‌های پیشین، نگارش شده است.

اخیراً به‌کارگیری روش‌های یادگیری عمیق (در این تحقیق، شبکه‌های عصبی کانولوشنی عمیق موردنظر است) که از جمله کامل‌ترین زیرمجموعه‌های روش‌های یادگیری ماشین هستند، در پردازش تصاویر سنجش‌ازدور بسیار موردتوجه بوده‌اند [۳۲]. یکی از نیازهای اساسی روش‌های یادگیری عمیق نیاز به کلان داده‌های تصویری است [۳۳]. در زمینه سنجش‌ازدور به دلیل وجود کلان داده‌های تصویری، روش‌های یادگیری عمیق دارای عملکرد مناسبی در حیطه موضوع‌های مختلف سنجش‌ازدور می‌باشد [۳۴]. چالش دیگر در یادگیری عمیق، زیرساخت مناسب برای

جدول ۱: تحقیق‌های پیشین در زمینه آشکارسازی ابرها و سایه ابرها با استفاده از روش‌های یادگیری عمیق

قابلیت آشکارسازی	میانگین دقت کلی آشکارسازی		جزئیات مجموعه داده‌ها	نوع معماری یادگیری عمیق	پژوهشگر (سال انتشار)
	سایه ابر	ابر			
دارد	دارد	٪۸۹	سری لندست و سنتینل-۲	یونت	ویلند و همکاران [۱۸] (۲۰۱۹)
دارد	دارد	٪۹۳	لندست-۷ و ۸	سگنت	کای و همکاران [۳۵] (۲۰۱۹)
دارد	دارد	٪۹۶	لندست-۵، ۷ و ۸، گائوفن-۱، ۲ و ۴، سنتینل-۲، ژی-یوآن-۱ و ۳، هوآن جینگ-۱	تلفیق ویژگی‌های کانولوشنی چندمقیاسه	لی و همکاران [۳۶] (۲۰۱۹)
ندارد	دارد	٪۹۳	ژی-یوآن-۳، گائوفن-۱ و لندست-۸	سی دی نت	یانگ و همکاران [۴] (۲۰۱۹)
ندارد	دارد	٪۹۲	سنتینل-۲	کلودنت	لیو و همکاران [۳۷] (۲۰۱۹)
ندارد	دارد	٪۸۷	کربونیت-۲ و لندست-۸	کلود اف سی ان	فرانسیس و همکاران [۳۸] (۲۰۱۹)
دارد	دارد	٪۹۴	ژی-یوآن-۳، گائوفن-۱ و ۲	شبکه عصبی کانولوشنی چند سطحی	چن و همکاران [۱۱] (۲۰۱۸)
دارد	دارد	٪۹۴	سنتینل-۲	شبکه عصبی کانولوشنی شی مینا	وانگ و همکاران [۳۹] (۲۰۱۸)

به صورت توأمان است. بر اساس نتایج تحقیق‌های پیشین، هرچه قدرت تفکیک مکانی بیشتر و صحنه‌ها پیچیده‌تر باشد دقت کلی آشکارسازی ابرها و سایه ابرها به میزان زیادی کاهش می‌یابد.

۳- مبانی نظری

در این بخش، ابتدا به تعریف مفاهیم پایه در زمینه شبکه‌های عصبی کانولوشن پرداخته می‌شود. سپس، روش‌های مرجع معرفی می‌شوند. در پایان، جزئیات الگوریتم پیشنهادی و مجموعه داده، تشریح می‌شوند.

۳-۱- مفاهیم پایه

طراحی یک شبکه عصبی کانولوشنی مشتمل بر طراحی فیلتر، انتخاب تابع فعال‌ساز (فعالیت) مناسب، طراحی مرحله گذراری و نحوه آموزش و اصلاح وزن‌های شبکه عصبی کانولوشنی می‌باشد. در ادامه این بخش، هر یک از این مولفه‌ها، مورد بررسی قرار می‌گیرند.

۳-۱-۱- طراحی فیلتر و وزن دهی اولیه در شبکه عصبی کانولوشنی

یکی از ویژگی‌های مهم شبکه‌های عصبی کانولوشنی استفاده از فیلترها با توجه به وزن‌های موجود در آن‌ها است. وزن‌های موجود در هر فیلتر به‌عنوان یک پارامتر آموزش در شبکه عصبی کانولوشنی بشمار می‌آید [۴]. ابعاد بهینه فیلترها در شبکه‌های عصبی کانولوشنی اغلب 3×3 می‌باشد و بعد سوم فیلترها بر اساس تعداد کانال‌های ورودی تعیین می‌گردند [۱۸ و ۳۲]. پس از اعمال فیلترها بر روی تصویر ورودی، نتیجه به دست آمده با یک مقدار بایاس (در اینجا یک در نظر گرفته شده است) جمع می‌شود و تشکیل یک ماتریس ویژگی (با ابعاد تصویر ورودی و با یک کانال) را می‌دهد. یک راه‌حل مناسب برای حفظ ابعاد تصویر ورودی در شبکه‌های عصبی کانولوشنی، استفاده از پدینگ با مقادیر صفر در حاشیه تصویر ورودی می‌باشد. در عمل، استفاده از این روش موجب حفظ تمامی مقادیر در فرآیند استخراج ویژگی از تصویر ورودی می‌شود.

نتایج تحلیل پیشینه تحقیق در زمینه آشکارسازی ابرها و سایه ابرها از تصاویر با قدرت تفکیک مکانی بالا عبارت است از:

(۱) **نوع معماری یادگیری عمیق:** روش‌های پیشین، اغلب از یک معماری اولیه یادگیری عمیق مانند *U-Net* (یک شبکه کانولوشنی پیکسل مبنا با ۲۳ لایه کانولوشن) یا *SegNet* (یک شبکه کانولوشنی پیکسل مبنا با ۱۳ لایه کانولوشن برای استخراج ویژگی) به وجود آمده‌اند. معماری‌های اولیه یادگیری عمیق به دلیل بهینه نبودن ساختار و استفاده متعدد از لایه‌های کانولوشن یکسان و بدون توجه، در حال حاضر در زمینه پردازش تصویر به‌صورت چندمقیاسه، کمتر موردتوجه هستند.

(۲) **جزئیات مجموعه داده‌ها:** بر اساس نتایج تحقیق‌های پیشین، هرچه قدرت تفکیک مکانی افزایش یافته است (مانند تصاویر گائوفین-۱، ژ-۱، یوآن-۳ و کربونیت-۲)، توانایی الگوریتم‌ها در آشکارسازی ابرها و سایه ابرها به میزان قابل‌توجهی کاهش یافته است. البته تنوع صحنه‌های مورد پردازش در عملکرد الگوریتم‌های یادگیری عمیق تأثیر زیادی داشته است. به‌عبارت‌دیگر، در تحقیق‌هایی که ابرها و سایه ابرها در صحنه‌های مختلف مانند پهنه‌های آب، زمین‌های کشاورزی یا مناطق پوشیده از برف، موردتوجه بوده است، دقت کلی آشکارسازی نیز کاهش یافته است [۱۸، ۳۴، ۴ و ۳۸].

(۳) **نوع منطقه:** مناطق مطالعاتی در تحقیق‌های پیشین، اغلب شامل مناطقی با سطح همگن می‌باشد. بنابراین توجه به آشکارسازی ابرها و سایه ابرها در مناطق مختلف در تصاویر ماهواره‌هایی مانند گائوفین-۱، موضوع مورد اهمیت است.

(۴) **قابلیت و دقت کلی آشکارسازی:** تحقیق‌های اخیر نشان‌دهنده اهمیت آشکارسازی ابرها و سایه ابرها

استفاده می‌کنند [۳۶ و ۴۵]. واحد یکسو شده‌ی خطی با عبور خروجی یک لایه از خود نتیجه را بین صفر و کران بی‌نهایت مثبت، نرمال می‌کند و با روش وزن دهی اولیه هی‌نرم سازگاری مناسبی دارد [۴۲]. این امر موجب می‌شود تا به ازای مقادیر مثبت، همان مقدار به‌عنوان خروجی ارائه شود که یک مزیت برای شبکه محسوب می‌شود.

۳-۱-۳- مرحله گذاری از طریق کاهش ابعاد

مرحله کاهش ابعاد با هدف جلوگیری از پدیده بیش‌برازش ناشی از عدم آموزش بهینه تعداد زیاد وزن‌های فیلتر در شبکه‌های عصبی کانولوشنی مورد استفاده قرار می‌گیرند [۳۳]. اگر شبکه عصبی کانولوشنی، داده‌های آموزشی را به‌طور کامل یاد بگیرد اما در مورد داده‌های آزمایشی به‌خوبی عمل نکند، در این حالت پدیده بیش‌برازش رخ می‌دهد.

در طراحی شبکه‌های عصبی کانولوشنی اغلب پس از اعمال یک فیلتر از یک لایه کاهش‌دهنده ابعاد استفاده می‌شود. لایه کاهش ابعاد دارای عملکرد مستقل است، بدین‌صورت که یک لایه کاهش ابعاد با تعریف ابعاد 2×2 این قابلیت را دارد تا ابعاد عرض و ارتفاع داده ورودی را به‌اندازه ۲ پیکسل کاهش دهد. ابعاد بهینه برای تعریف لایه‌های کاهش ابعاد به‌طور تجربی 2×2 و با گام حرکت ۲ (مقدار حرکت فیلتر بر روی سطر و ستون تصویر) در نظر گرفته می‌شود. با اعمال این لایه، ابعاد داده ورودی به نسبت ۷۵٪ کاهش پیدا می‌کند. کاهش ابعاد در شبکه‌های کانولوشنی اغلب می‌تواند با سه روش کاهش ابعاد بیشینه^۷، کاهش ابعاد میانگین^۸ و کاهش ابعاد کمینه^۹ صورت بگیرد. انتخاب این روش‌ها با توجه به نوع داده ورودی و هدف مسأله تعیین می‌شود. در تحقیق‌های مربوط به قطعه‌بندی تصویر، استفاده از روش کاهش ابعاد بیشینه دارای کاربرد

یک فیلتر با ابعاد 3×3 دارای ۹ وزن می‌باشد که باید در اولین مرحله از آموزش مقداردهی شوند. مقداردهی اولیه وزن‌ها در شبکه‌های عصبی کانولوشنی برای مقابله با محوشدگی گرادیان^۱ و انفجار گرادیان^۲ صورت می‌گیرد. مشکل محوشدگی گرادیان اغلب در شبکه‌هایی که مقادیر وزن‌ها کوچک باشد اتفاق می‌افتد و مشکل انفجار گرادیان زمانی اتفاق می‌افتد که مقادیر وزن‌ها بزرگ انتخاب شود. روش‌های *Xavier Glorot* و *Kaiming He* دو روش شناخته‌شده برای وزن دهی اولیه به شبکه‌های عصبی کانولوشنی می‌باشند [۳۸]. هر دو روش مدل‌های نرمال و یکنواخت ارائه داده‌اند. اما روش *Kaiming He* نرمال که با نام هی‌نرم^۳ شناخته می‌شود، به دلیل استفاده از تعداد ورودی‌های شبکه در تعیین مقادیر اولیه وزن، روش مناسب‌تری در شبکه‌های عصبی کانولوشنی می‌باشد [۴۲].

۳-۱-۲- انتخاب تابع فعال‌ساز (فعالیت) غیر خطی

تابع فعال‌ساز^۴ که با نام تابع انتقال^۵ و یا تابع فعالیت نیز شناخته می‌شود به‌عنوان یک قسمت اصلی در شبکه‌های عصبی کانولوشنی همانند سایر شبکه‌های عصبی مصنوعی مورد استفاده قرار می‌گیرد. تابع فعال‌ساز در شبکه‌های عصبی کانولوشنی معمولاً پس از فیلترها جانمایی می‌شوند و از نوع غیرخطی هستند [۳۲]. تابع فعال‌ساز وظیفه فعال یا غیرفعال کردن یک نورون در هر لایه را در شبکه عصبی به عهده دارد. به عبارت دیگر ورودی را از لایه قبلی خود می‌گیرد و اغلب نتیجه را بین دو عدد معلوم مشخص می‌کند. اخیراً در بسیاری از شبکه‌های عصبی کانولوشنی از تابع فعال‌ساز با نام واحد یکسو شده‌ی خطی^۶ (*ReLU*)

^۱ Vanishing Gradient

^۲ Exploding Gradient

^۳ *he_norm*

^۴ Activation Function

^۵ Transfer Function

^۶ Rectified Linear Unit

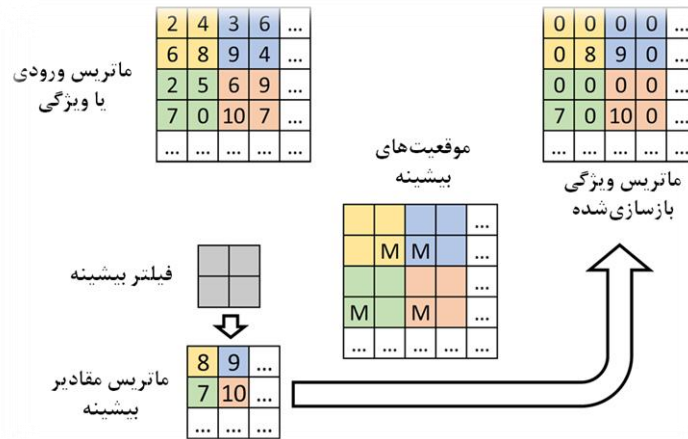
^۷ Max Pooling

^۸ Average Pooling

^۹ Min Pooling

سپس ماتریس با ابعاد کاهش یافته از سایر قسمت‌های شبکه عبور می‌کند و مقادیر جدیدی محاسبه می‌شود و در موقعیت‌های ذخیره شده جانمایی می‌شوند.

بیشتری است. فرآیند کُدگذاری و کُدگشایی (لایه نمونه افزا) با استفاده از کاهش ابعاد به روش پیشینه در شکل (۱) ارائه شده است. با توجه به این شکل، موقعیت و مقادیر پیشینه پس از کاهش ابعاد ذخیره می‌شوند و



شکل ۱: فرآیند کُدگذاری و کُدگشایی با استفاده از شیوه کاهش ابعاد به روش پیشینه [۴۸]

۲-۲- روش‌های مرجع

شرط کسب بیشترین دقت در بین روش‌های قبلی، معیار مناسبی برای انتخاب روش‌های مرجع به منظور مطالعه تطبیقی با روش پیشنهادی است. دو روش پیشرفته برای آشکارسازی ابرها و سایه ابرها از تصاویر ماهواره گائوفن-۱ عبارت‌اند از: روش ترکیب ویژگی‌ها^۱ [۱۶] و روش تلفیق ویژگی‌های کانولوشنی چندمقیاسه^۲ [۳۶].

۲-۲-۱- روش ترکیب ویژگی‌ها

روش ترکیب ویژگی‌ها، یک روش آماری تشخیص الگو به منظور آشکارسازی ابرها و سایه ابرها از تصاویر ماهواره گائوفن-۱ است. این روش بر اساس تعیین حدآستانه برای قطعه‌بندی بر مبنای ویژگی‌های طیفی تصویر ماهواره گائوفن-۱ عمل می‌کند. سپس، به منظور بهبود نتایج آشکارسازی ابرها با استفاده از اطلاعات

روش تحقیق با هدف بهبود چالش‌های اشاره شده در نتایج تحلیل پیشینه تحقیق (بخش ۲) طراحی شده است. به طور خلاصه، چالش‌های موجود که این تحقیق درصدد بهبود آن‌ها است عبارت است از:

(۱) یک الگوریتم بهینه برای بهبود دقت آشکارسازی جزئیات حاشیه‌ای ابرها و سایه ابرها به صورت توأمان از تصاویر ماهواره گائوفن-۱ طراحی شده است.

(۲) داده‌هایی با توزیع جهانی و در صحنه‌های مختلف برای ارزیابی قابلیت تعمیم‌پذیری الگوریتم پیشنهادی، مورد استفاده قرار گرفته است.

در این ادامه، ابتدا روش‌های مرجع به منظور مطالعه تطبیقی با روش پیشنهادی، مورد بررسی قرار می‌گیرند (قسمت ۲-۳). سپس، ساختار الگوریتم پیشنهادی معرفی می‌شود (قسمت ۳-۳). در نهایت، مجموعه داده‌های تحقیق برای انجام آزمایش، معرفی می‌شوند (قسمت ۴-۳).

^۱ Multi-Feature Combined

^۲ Multi-Scale Convolutional Feature Fusion

(۱) به کارگیری فیلترهای کانولوشنی با ابعاد مختلف در یک ساختار کُدگذار-کُدگشا با هدف جداسازی بهتر جزئیات حاشیه‌ای ابرها و سایه ابرها از سایر عوارض زمینی، یکی از نوآوری‌های این تحقیق است.

(۲) طراحی بلوک‌های باقی‌مانده کانولوشنی مبتنی بر روش حذف تصادفی عمق، برخلاف بلوک‌های باقی‌مانده معمولی که به صورت همانی عمل می‌کنند.

(۳) توسعه تابع خطای آنتروپی متقاطع با هدف افزایش خاصیت یکنوایی و ایجاد تعادل بین پیکسل‌ها، برای ارتقاء دقت آشکارسازی ابرها و سایه ابرها، یکی دیگر از ابتکار عمل‌های این الگوریتم است.

در شکل (۲)، ساختار معماری *MultiCloud-Net* نشان داده شده است. الگوریتم *MultiCloud-Net* یک معماری با فرآیند یادگیری *End-to-End* است. فرآیند یادگیری *End-to-End*، به مفهوم یادگیری تمام ویژگی‌های استخراج‌شده در روند آموزش مدل و آزمایش آن بدون استفاده از هرگونه روش پس‌پردازش می‌باشد [۳۲]. معماری *MultiCloud-Net* یک معماری یادگیری عمیق با عمق شبکه ۶ (طول شبکه) می‌باشد. همچنین در این شبکه بجای استفاده از لایه‌های کانولوشنی با ابعاد فیلتر ثابت و به صورت پی‌درپی (مانند شبکه یونت یا سگنت) از یک نوآوری منحصر به فرد نیز استفاده شده است. این نوآوری شامل به کارگیری فیلترهایی با ابعاد مختلف برای روند آموزش می‌باشد.

هندسی از فیلتر هدایتی^۱ (یک نوع فیلتر از نوع فیلترهای دوطرفه^۲ برای بهبود لبه است) برای تولید محدوده ابرها استفاده می‌شود. در نهایت، نقشه سایه ابرها با تطابق هندسی بین ابرها و سایه متناظر ابرها استخراج می‌شوند [۱۶]. برنامه روش ترکیب ویژگی‌ها در لینک (<http://sendimage.whu.edu.cn/en/mfc>) موجود است.

۳-۲-۲- روش تلفیق ویژگی‌های کانولوشنی چندمقیاسه

روش تلفیق ویژگی‌های کانولوشنی چندمقیاسه، یک روش جدید یادگیری عمیق به منظور آشکارسازی ابرها و سایه ابرها از تصاویر مختلف سنجش‌ازدور به‌ویژه تصاویر با قدرت تفکیک مکانی بالا مانند تصاویر ماهواره گائوفن-۱ است. این روش نسبت به روش‌های پیشین یادگیری عمیق نظیر دیپ‌لب^۳ و دی‌سی‌ان^۴ که برای آشکارسازی ابرها و سایه ابرها مورد استفاده قرار گرفته‌اند، در حدود ۲ درصد دقیق‌تر از سایر نتایج می‌باشد. همچنین، نسبت به تحقیق‌های پیشین (جدول (۱))، این الگوریتم در صحنه‌های مختلفی آزمایش شده است. این روش، یک معماری کُدگذار-کُدگشای کانولوشنی با ساختار عمیق را پیشنهاد داده است [۳۶]. منبع کُد روش تلفیق ویژگی‌های کانولوشنی چندمقیاسه در لینک موجود (<http://sendimage.whu.edu.cn/en/mscfff>) موجود است.

۳-۳- الگوریتم پیشنهادی

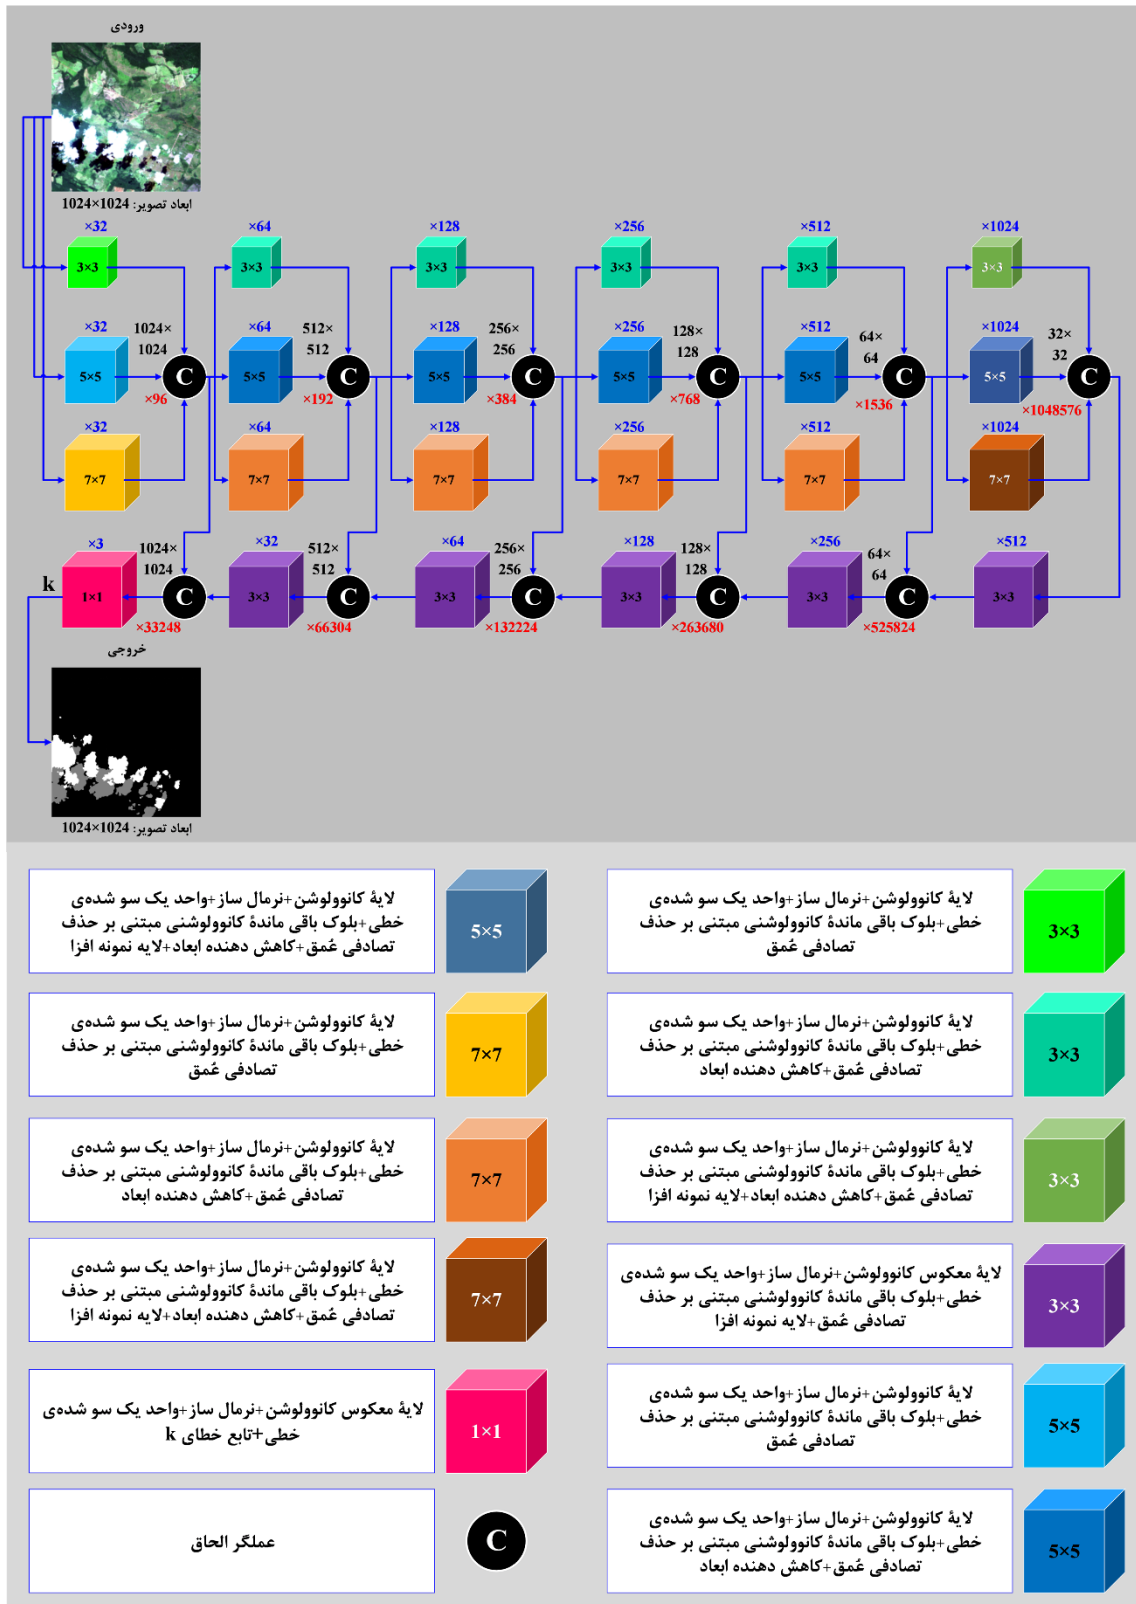
الگوریتم پیشنهادی در این تحقیق با نام *MultiCloud-Net*، یک معماری جدید در یادگیری عمیق است. مهم‌ترین ویژگی‌های معماری *MultiCloud-Net* عبارت است از:

^۱ Guided Filter

^۲ Bilateral Filters

^۳ DeepLab

^۴ Deep Convolutional Network



شکل ۲: معماری پیشنهادی با نام MultiCloud-Net

پردازش تنسورفلو، قوی‌ترین پردازنده برای تحقیق‌های یادگیری عمیق است که در محیط رایانش ابری گوگل کولب قابل استفاده است.

۳-۳-۱- بلوک‌های باقی‌مانده کانولوشنی مبتنی بر روش حذف تصادفی عمق

روش حذف تصادفی برای بهبود مقابله با پدیده بیش‌برازش در شبکه‌های عصبی مورد استفاده قرار می‌گیرد. در هر مرحله از آموزش، هر نورون با احتمال $p-1$ از شبکه خارج می‌شود و یا با احتمال p در شبکه باقی می‌ماند، به‌نحوی که یک شبکه عصبی با نورون‌های کاهش‌یافته باقی بماند. در مرحله گذار در یک شبکه عصبی کانولوشنی، ابعاد ماتریس نقشه‌های ویژگی به تدریج کاهش می‌یابد و تعداد نقشه ویژگی‌های تولیدشده افزایش می‌یابد. افزایش تعداد نقشه‌های ویژگی در شبکه عصبی کانولوشنی به دلیل استفاده از فیلترهای کانولوشنی می‌باشد. افزایش تعداد فیلترهای کانولوشنی موجب افزایش تعداد نقشه‌های ویژگی و در نتیجه بهبود دقت طبقه‌بندی می‌شود، اما با قرار دادن فیلترها به صورت پیاپی، شبکه با مشکل محوشدگی گرادیان در مرحله پس انتشار مواجه می‌شود. در ساختار بلوک‌های باقی‌مانده کانولوشنی هدف حل مشکل صفر شدن تدریجی گرادیان با استفاده از نگاشت باقی‌مانده می‌باشد. در نگاشت باقی‌مانده، مقادیر خروجی پیش از نگاشت با نتایج خروجی جمع می‌شوند [۴۹].

به‌کارگیری بلوک‌های باقی‌مانده در معماری‌های یادگیری عمیق، علی‌رغم بهبود دقت طبقه‌بندی، موجب افزایش هزینه محاسبه‌ها، به‌ویژه در تلفیق بلوک‌های باقی‌مانده با لایه‌های کانولوشن، به میزان زیادی اثرگذار است. به‌طورمعمول، با فرض اینکه بلوک کانولوشنی شامل دو فیلتر کانولوشن باشد، مقدار ورودی از دو فیلتر عبور کرده و سپس مجدداً با مقدار اولیه جمع می‌شود (شکل ۳-الف). همان‌طور که از نظر تئوری مشهود است، صرفاً برای جلوگیری از تقلیل

بر اساس نتایج این تحقیق، به‌کارگیری فیلترهایی با ابعاد مختلف در شبکه‌های عصبی کانولوشنی مزایایی به شرح زیر دارد:

(۱) موجب تولید ویژگی‌های جدید و ادغام خودکار آن‌ها در طول شبکه می‌شود، این کار یک روش مناسب برای تقویت داده‌ها است (در شکل ۲ در هر لایه تعداد ویژگی‌ها با رنگ قرمز و تعداد فیلترها با رنگ آبی مشخص شده است).

(۲) امکان دسترسی به ویژگی‌های کلی-جزئی به‌صورت توأمان ایجاد می‌شود. به‌عنوان مثال اگر هدف استخراج سایه ابرها است ممکن است در بخش سایه، خطوط ساحلی وجود داشته باشند، اگر از یک فیلتر با ابعاد ثابت استفاده شود، خطوط ساحلی در فرآیند استخراج نابسامانی ایجاد می‌کنند. درحالی‌که می‌توانیم با به‌کارگیری فیلترهایی با ابعاد بزرگ‌تر اثر آن‌ها را در این ناحیه از بین ببریم (این مزیت در نمونه شماره ۵ در بخش نتایج ارائه شده است).

معیار تعیین عمق شبکه و تعداد لایه‌هایی با ابعاد فیلتر مختلف، بیشترین میزان حافظه دسترسی تصادفی^۱ (RAM) قابل‌مصرف در محیط گوگل کولب می‌باشد. به‌عبارت‌دیگر، بر اساس محدودیت‌های زیرساختی، شبکه بیشترین رشد خود را در جهت طول (عمق شبکه) و عرض (تعداد فیلترهایی با ابعاد مختلف) داشته است.

در این تحقیق، پیاده‌سازی روش پیشنهادی با استفاده از زبان برنامه‌نویسی پایتون و کتابخانه برنامه‌نویسی متن‌باز یادگیری عمیق به نام کِراس که به زبان پایتون توسعه پیدا کرده است در محیط رایانش ابری گوگل کولب، صورت گرفته است. یکی از ویژگی‌های استفاده از کتابخانه کِراس قابلیت اجرای مدل‌های یادگیری عمیق بر روی واحد پردازش تنسورفلو می‌باشد. واحد

^۱ Random Access Memory


در رابطه‌های (۱) و (۲)، o_n معادل خروجی بلوک باقی‌مانده؛ f_n تابع تبدیل کانولوشن و o_{n-2} معادل ورودی بلوک باقی‌مانده؛ a_n مقیاس تعمیم که از توزیع برنولی پیروی می‌کند و t_n تابع آموزش (در فرم اولیه گرادیان کاهش تصادفی) است.

در این تحقیق، جهت توسعه روش حذف تصادفی عمق برای فیلتر کانولوشنی، یک تغییر عمده در ساختار روش حذف تصادفی عمق ایجاد شده است. این تغییر شامل، استفاده از روش آموزش برآورد لحظه تطبیقی بجای روش آموزش گرادیان کاهش تصادفی، می‌باشد. به دلیل اینکه روش گرادیان کاهش تصادفی، یک روش با هزینه محاسبه بالا است و فرآیند آموزش به‌خوبی بهینه‌سازی نمی‌شود، از روش جدید و بهینه برآورد لحظه تطبیقی که عملکرد آن در بسیاری از تحقیق‌ها نظیر [۴۱ و ۴۲]، مورد بررسی قرار گرفته است، استفاده شده است. ابرپارامترها در روش برآورد لحظه تطبیقی به ترتیب 0.1 ، 0.9 ، 0.999 و 0.8 (برای نرخ یادگیری، بتا-۱، بتا-۲ و اسپیلون در نظر گرفته می‌شود [۳۸]). همچنین از روش هی‌نرم برای مقداردهی اولیه به شبکه استفاده می‌شود. روش هی‌نرم یکی از مناسب‌ترین روش‌های وزن دهی در یادگیری عمیق می‌باشد [۴۳].

ویژگی‌هایی که توسط فیلترهای کانولوشن ایجاد شده است، مقدار پردازش شده با مقدار اولیه جمع می‌شود. این فرآیند موجب دشوار شدن به‌کارگیری این بلوک‌ها در معماری‌های عمیق کُدگذار-کُدگشا می‌شود. برای ارتقاء به‌کارگیری بلوک‌های باقی‌مانده در معماری‌های عمیق کُدگذار-کُدگشا، در این تحقیق از یک شیوه جدید با نام بلوک‌های باقی‌مانده کانولوشنی مبتنی بر روش حذف تصادفی عمق، استفاده می‌گردد (شکل ۳-ب). حذف تصادفی عمق، اولین بار برای شبکه رزنت ۵۶ لایه، با هدف طبقه‌بندی اشیا بر روی مجموعه تصاویر *CIFAR10* و *ImageNet* (دو مجموعه تصویر شناخته‌شده در علوم رایانه) مورد استفاده قرار گرفت [۴۰]. نتایج نشان‌دهنده افزایش سرعت پردازش تا ۱۷/۵ درصد در مقایسه با ساختار معمولی رزنت ۵۶ لایه را نشان می‌دهد. به‌طورکلی، یک بلوک باقی‌مانده معمولی با استفاده از رابطه (۱) محاسبه می‌شود. درحالی‌که بلوک باقی‌مانده بر اساس حذف تصادفی عمق با رابطه (۲) تعیین می‌گردد.

$$o_n = f_n(o_{n-2}) + o_{n-2} \quad (۱) \text{ رابطه}$$

$$o_n = a_n f_n(o_{n-2}) + t_n(o_{n-2}) \quad (۲) \text{ رابطه}$$



شکل ۳: مقایسه الگوهای مختلف توسعه بلوک‌های باقی‌مانده کانولوشنی

۳-۲- توسعه تابع خطای آنتروپی متقاطع

نقش یک تابع خطای مناسب در شبکه‌های عصبی کانوولوشنی عمیق بسیار مهم است [۳۳]. به دلیل حجم زیاد داده‌های آموزشی در یادگیری عمیق، بسیاری از توابع خطا ناشی از وجود داده‌های اشتباه (حتی کم)، عملکرد ضعیفی دارند [۴۴]. اغلب روش‌های یادگیری عمیق که در تحقیق‌های قبلی مورد استفاده قرار گرفته‌اند از خطای کمترین مربعات ($L2$) برای محاسبه خطای شبکه استفاده کرده‌اند. یکی از مهم‌ترین معایب استفاده از خطای کمترین مربعات در شبکه‌های عصبی کانوولوشنی عمیق، عملکرد ضعیف در مقابله با داده‌های اشتباه است [۴۵]. داده‌های مورد استفاده در سنجش‌ازدور اغلب فاقد اشتباه نیستند (مواردی مثل وجود نویز در تصویر) و اغلب مسائل قطعه‌بندی دارای مسأله عدم تعادل پیکسل‌های هدف می‌باشند، بنابراین طراحی یک تابع خطای مناسب اجتناب‌ناپذیر است. در زمینه قطعه‌بندی تصویر با به‌کارگیری روش‌های یادگیری عمیق (به‌عنوان مثال آشکارسازی ابرها و سایه ابرها)، افزایش خاصیت یکنوایی تابع خطا و ایجاد تعادل بین پیکسل‌های هدف و غیر هدف، موجب بهبود عملکرد معماری در فرآیند به‌روزرسانی و خروجی نهایی می‌شود. فرآیند به‌روزرسانی اغلب بر مبنای گرادیان صورت می‌گیرد، به همین منظور در صورتی که تابع خطا خاصیت یکنوایی بیشتری داشته باشد، روند مشتق‌گیری به‌منظور رسیدن به یک آموزش بهینه (همگرایی مطلوب مقادیر خطا) تسهیل می‌گردد. در این تحقیق، به‌منظور توسعه تابع خطای آنتروپی متقاطع، از الگوی وزن‌دار تابع آنتروپی متقاطع استفاده شده است. در تابع آنتروپی متقاطع وزن‌دار، یک وزن نزدیک به یک برای هر پیکسل بر اساس حاصل تقسیم تعداد پیکسل‌های غیر هدف بر تعداد کل پیکسل‌ها در نظر گرفته می‌شود. این مقدار وزن به عنوان پارامتر تعادل تعیین می‌گردد. در این تحقیق، به دلیل اینکه در برخی نمونه‌ها (مانند نمونه‌های دوم، سوم، یازدهم و دوازدهم در شکل (۵))

تعداد پیکسل‌های غیر هدف بیشتر است، لازم است پارامتر تعادل نیز استفاده شود. تابع آنتروپی متقاطع وزن‌دار برای یک طبقه‌بندی چند کلاسی به صورت رابطه (۳) تعریف می‌گردد.

رابطه (۳)

$$H(p, \hat{p})_k = -(\beta \log(\hat{p}) + (1 - \hat{p}) \log(1 - \hat{p}))$$

در رابطه (۳)، H تابع آنتروپی متقاطع وزن‌دار؛ k نوع کلاس‌ها (کلاس ابر، کلاس سایه ابر و کلاس غیر هدف)؛ p احتمال شرطی برای خروجی هدف؛ \hat{p} احتمال شرطی برای خروجی غیر هدف و β پارامتر تعادل می‌باشد.

تابع خطای طراحی‌شده در قسمت انتهایی معماری پیشنهادی برای طبقه‌بندی کلاس‌های پیش‌بینی‌شده، مورد استفاده قرار می‌گیرد.

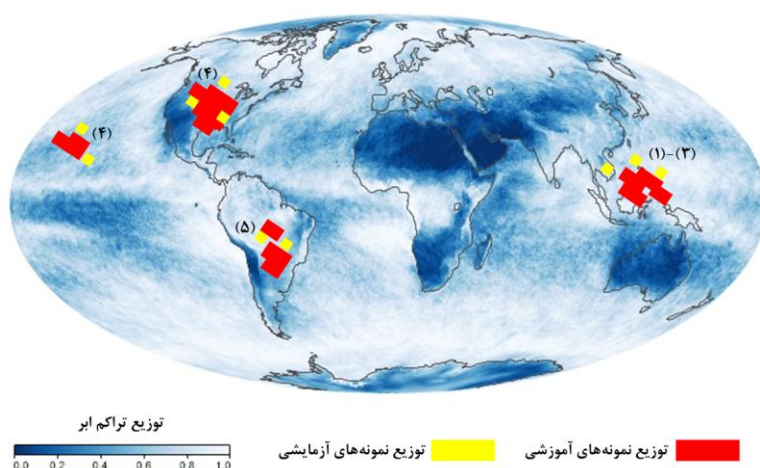
۳-۴- مجموعه داده‌ها

در این تحقیق، برای ارزیابی روش پیشنهادی از ۱۰۲ قطعه تصویر (۹۰ قطعه برای آموزش و ۱۲ قطعه برای آزمایش) اخذ شده توسط ماهواره گائوفن-۱ با ترکیب رنگ حقیقی (RGB) و با ابعاد 1024×1024 پیکسل با قدرت تفکیک مکانی ۸ متر و در سطح محصولات $2A$ استفاده شد. سطح محصولات $2A$ در ماهواره گائوفن-۱ شامل محصولاتی با تصحیح رادیومتری نسبی و تصحیح هندسی سیستماتیک^۱ می‌باشد. تصاویر مورد استفاده، یک زیرمجموعه از مجموعه تصاویر تحقیق [۱۶]، می‌باشند. نقشه واقعیت ابرها و سایه ابرها توسط عامل انسانی متخصص و با روش پیشنهادی [۳۶] و [۴۶]، تهیه شده است. برای ارتقاء اعتمادپذیری به نتایج در زمینه تعمیم‌پذیر بودن روش پیشنهادی، مجموعه

در تصحیح هندسی سیستماتیک از داده‌های کالیبراسیون^۱ سنجنده، پارامترهای مداری، مختصات و موقعیت سنجنده در لحظه تصویربرداری برای کاهش اعوجاجات هندسی تصویر استفاده می‌شود.

(۳) تنوع صحنه‌های تصویربرداری: تصاویر مورد استفاده در صحنه‌های مختلفی نظیر زمین‌های کشاورزی، پهنه‌های آبی، مناطق ساحلی و مناطق نیمه‌شهری می‌باشند.

برای ارزیابی نحوه توزیع نمونه‌های آموزشی و آزمایشی در مجموعه داده تحقیق شکل (۴) ارائه شده است. شکل (۴)، الگوی جانمایی نمونه‌های مجموعه داده تحقیق بر اساس نقشه جهانی میانگین ماهانه توزیع ابر مادیس [۴۷] در تاریخ فوریه ۲۰۱۴ را نشان می‌دهد.



شکل ۴: جانمایی نقشه توزیع جهانی مجموعه داده تحقیق بر اساس نقشه جهانی میانگین ماهانه توزیع ابر مادیس در تاریخ فوریه ۲۰۱۴

تعریف می‌شوند دارای کاربرد زیادی می‌باشند. در این تحقیق، دو معیار ارزیابی دقت، شامل نمره FI و ضریب شباهت ژاکارد^۱ موردنظر است. بر اساس تحقیق‌های اخیر [۱۸ و ۳۶]، به‌کارگیری نمره FI و ضریب شباهت ژاکارد، ارزیابی مناسبی از اعتبارسنجی نتایج در زمینه آشکارسازی ابرها و سایه ابرها، ارائه می‌دهد. همچنین از منحنی مشخصه عملکرد سیستم^۲ (ROC) نیز برای ارزیابی نتایج استفاده می‌شود. عدد حد آستانه مطلوب


^۱ ضریب شباهت ژاکارد ($Jaccard Similarity Index$) در برخی از تحقیق‌ها با نام $Intersection over Union (IoU)$ شناخته می‌شود.

^۲ Receiver Operating Characteristics

تصاویر مورد استفاده دارای چالش‌هایی به شرح زیر می‌باشند:

(۱) تنوع زمان اخذ تصاویر: تصاویر مورد استفاده طی سال‌های ۲۰۱۳ تا ۲۰۱۶ اخذ شده‌اند. تنوع زمان اخذ تصاویر، موجب تنوع نوع ابرها در فصل‌های مختلف سال می‌شود.

(۲) تنوع موقعیت مکانی تصاویر: تصاویر مورد استفاده از شهرهای مختلف واقع در کشورهای چین، فیلیپین، مالزی، آمریکا و برزیل تهیه شده است.



۴- ارزیابی نتایج و بحث

در این بخش، ابتدا معیارهای ارزیابی دقت معرفی می‌شوند، سپس نتایج به‌دست‌آمده از روش پیشنهادی در مقایسه با دو روش مرجع معرفی شده در بخش (۳-۲) ارائه می‌شوند. در پایان این بخش، بحثی درباره نتایج و نقاط قوت و ضعف روش پیشنهادی در مقایسه با روش‌های مرجع، ارائه می‌شود.

۴-۱- معیارهای ارزیابی دقت

در زمینه آشکارسازی ابرها و سایه ابرها از تصاویر با قدرت تفکیک مکانی بالا، ارزیابی دقیق موقعیت پیکسل‌های ابر و سایه ابر، بسیار دارای اهمیت است. به همین جهت، معیارهایی که بر مبنای صحت پیکسل‌ها

$$JSI = \frac{TP}{TP + FP + FN} \quad \text{رابطه (۵)}$$

در رابطه‌های (۴) و (۵)، TP بیانگر تعداد پیکسل‌های ابر (یا سایه ابر) در کلاس ابر (یا سایه ابر)؛ FP بیانگر تعداد پیکسل‌های ابر (یا سایه ابر) در کلاس غیر ابر (یا غیر سایه ابر)؛ FN بیانگر تعداد پیکسل‌های غیر ابر (یا غیر سایه ابر) در کلاس ابر (یا سایه ابر) است.

۴-۲- نتایج

شکل (۵) و جدول‌های (۲) و (۳)، به ترتیب نتایج بصری و عددی حاصل از آزمایش صورت گرفته با استفاده معماری پیشنهادی (*MultiCloud-Net*) در مقایسه با روش‌های مرجع را نشان می‌دهد. بر اساس شکل (۴) توضیحاتی که در بخش (۳-۴) ارائه شد، ۱۲ نمونه مختلف برای انجام یک آزمایش چالش‌برانگیز انتخاب گردید. در جدول‌های (۲) و (۳)، بهترین مقادیر به صورت پُررنگ، بهترین مقادیر مشابه به صورت پُررنگ زیرخط دار و دومین نتیجه مناسب به صورت زیرخط دار نشان داده شده است.

در جایی که بیشترین سطح زیر منحنی مشخصه عملکرد سیستم موجود باشد، انتخاب می‌گردد. نمره $F1$ ، نوعی معیار میانگین بین دقت و حساسیت به دست آمده از نتایج را نشان می‌دهد. به عبارت دیگر نوعی میانگین بر اساس دقت داده‌های پیش‌بینی شده و نسبت داده‌های پیش‌بینی شده به کل داده‌های موردنظر است. معیار نمره $F1$ بر اساس مقادیر ماتریس خطا به صورت رابطه (۴) محاسبه می‌شود.

$$F1 = \frac{2 \times TP}{(2 \times TP) + FP + FN} \quad \text{رابطه (۴)}$$


ضریب شباهت ژاکارد، توصیفگر شباهت یا تفاوت مجموعه نمونه‌های موردنظر می‌باشد. این معیار نسبت اشتراک دو مجموعه بر تعداد اجتماع دو مجموعه را محاسبه می‌کند. در حال حاضر، ضریب شباهت ژاکارد یکی از معیارهای پرکاربرد و قابل اطمینان در ارزیابی نتایج قطعه‌بندی تصویر بشمار می‌آید. ضریب شباهت ژاکارد بر اساس مقادیر ماتریس خطا به صورت رابطه (۵) محاسبه می‌شود.


جدول ۲: نتایج ارزیابی عددی آشکارسازی ابرها با استفاده از روش‌های *MultiCloud-Net*، ترکیب ویژگی‌ها و تلفیق ویژگی‌های کانولوشنی چندمقیاسه.

تلفیق ویژگی‌های کانولوشنی چندمقیاسه		ترکیب ویژگی‌ها		<i>MultiCloud-Net</i>		روش
$F1$ (%)	JSI (%)	$F1$ (%)	JSI (%)	$F1$ (%)	JSI (%)	معیار
۹۶٫۶	۹۳٫۳	۹۳٫۷	۸۸٫۲	۹۷٫۶	۹۷٫۲	نمونه ۱
۹۵٫۷	۹۱٫۷	۶۳٫۱	۴۶٫۱	۹۷٫۷	۹۷٫۳	نمونه ۲
۹۵٫۹	۹۲٫۲	۹۳٫۰	۸۷٫۰	۹۷٫۶	۹۷٫۲	نمونه ۳
۹۷٫۳	۹۶٫۶	۹۷٫۸	۹۷٫۸	۹۷٫۸	۹۷٫۸	نمونه ۴
۸۴٫۵	۷۳٫۲	۶۹٫۴	۵۳٫۲	۹۶٫۵	۹۳٫۰	نمونه ۵
۹۱٫۳	۸۴٫۰	۷۹٫۳	۶۵٫۸	۹۷٫۲	۹۶٫۵	نمونه ۶
۸۹٫۵	۸۱٫۱	۸۹٫۹	۸۱٫۶	۹۷٫۲	۹۶٫۵	نمونه ۷
۹۵٫۹	۹۲٫۱	۸۸٫۵	۷۹٫۳	۹۷٫۴	۹۷٫۸	نمونه ۸
۹۳٫۰	۸۶٫۹	۹۳٫۲	۸۷٫۲	۹۷٫۴	۹۷٫۷	نمونه ۹
۹۲٫۱	۸۵٫۴	۹۱٫۶	۸۴٫۴	۹۷٫۳	۹۷٫۶	نمونه ۱۰
۹۷٫۵	۹۷٫۱	۹۶٫۱	۹۵٫۷	۹۸٫۶	۹۸٫۲	نمونه ۱۱
۹۵٫۱	۹۳٫۸	۹۵٫۵	۹۴٫۲	۹۷٫۸	۹۷٫۶	نمونه ۱۲

جدول ۳: نتایج ارزیابی عددی آشکارسازی سایه ابرها با استفاده از روش‌های *MultiCloud-Net*، ترکیب ویژگی‌ها و تلفیق ویژگی‌های کانولوشنی چندمقیاسه.

تلفیق ویژگی‌های کانولوشنی چندمقیاسه		ترکیب ویژگی‌ها		<i>MultiCloud-Net</i>		روش
<i>FI (%)</i>	<i>JSI (%)</i>	<i>FI (%)</i>	<i>JSI (%)</i>	<i>FI (%)</i>	<i>JSI (%)</i>	معیار
۸۴٫۵	۷۳٫۱	۱٫۱	۱٫۰	۹۶٫۴	۹۴٫۹	نمونه ۱
۷۸٫۳	۶۴٫۳	۹٫۷	۵٫۱	۹۷٫۱	۹۶٫۲	نمونه ۲
۹۳٫۲	۸۷٫۳	۸۳٫۱	۷۱٫۲	۹۷٫۶	۹۷٫۲	نمونه ۳
۸۱٫۵	۶۸٫۸	۹۷٫۳	۹۵٫۰	۹۷٫۳	۹۶٫۷	نمونه ۴
۶۷٫۳	۵۰٫۷	۵۶٫۷	۳۹٫۶	۹۵٫۵	۹۳٫۰	نمونه ۵
۸۱٫۰	۶۸٫۰	۴۶٫۰	۲۹٫۹	۹۶٫۷	۹۵٫۵	نمونه ۶
۷۷٫۹	۶۳٫۸	۶۵٫۵	۴۸٫۷	۹۶٫۶	۹۵٫۲	نمونه ۷
۷۰٫۵	۵۴٫۵	۵۵٫۶	۳۸٫۵	۹۵٫۶	۹۳٫۳	نمونه ۸
۸۲٫۶	۷۰٫۴	۷۲٫۸	۵۷٫۳	۹۶٫۵	۹۵٫۰	نمونه ۹
۷۰٫۷	۵۴٫۷	۶۷٫۲	۵۰٫۶	۹۶٫۰	۹۴٫۱	نمونه ۱۰
۹۸٫۲	۹۷٫۶	۹۰٫۰	۸۹٫۷	۹۸٫۱	۹۸٫۸	نمونه ۱۱
۹۸٫۶	۹۸٫۱	۸۸٫۶	۸۷٫۲	۹۹٫۴	۹۹٫۱	نمونه ۱۲





شکل ۵: نتایج آشکارسازی ابرها و سایه ابرها با به کارگیری روش‌های *MultiCloud-Net*، ترکیب ویژگی‌ها و تلفیق ویژگی‌های کانولوشنی چندمقیاسه بر روی تصاویر *RGB* ماهواره گائوفن-۱ (سفید: کلاس ابر، خاکستری: کلاس سایه ابر و مشکی: کلاس سایر).

۴-۲-۱- ارزیابی دقت روش‌ها در زمینه

آشکارسازی ابرها

روش‌های ترکیب ویژگی‌ها و تلفیق ویژگی‌های کانولوشنی چندمقیاسه در مواجهه با ابرهایی با اندازه‌های کوچک عملکرد مناسبی ندارند (مانند نمونه‌های دوم، ششم، هفتم و یازدهم). با توجه به اینکه قدرت تفکیک مکانی در تصاویر ماهواره گائوفن-۱ برابر ۸ متر است، آشکارسازی ابرها با اندازه کوچک بسیار حائز اهمیت است. بر اساس نتایج عددی، روش

نتایج به دست آمده از آزمایش صورت گرفته به وسیله روش *MultiCloud-Net* به عنوان الگوریتم پیشنهادی، روش ترکیب ویژگی‌ها به عنوان یک الگوریتم آماری و روش تلفیق ویژگی‌های کانولوشنی چندمقیاسه، به عنوان یک الگوریتم یادگیری عمیق، در زمینه دقت روش‌ها در آشکارسازی ابرها، سایه ابرها، چالش وجود مه غلیظ در صحنه و هزینه پردازش ارزیابی می‌شوند.

روش تلفیق ویژگی‌های کانوولوشنی چندمقیاسه ارتقاء پیدا کرده است.

۳- روش تلفیق ویژگی‌های کانوولوشنی چندمقیاسه در معیارهای نمره *FI* و ضریب شباهت ژاکارد در حدود ۲۳٪ و ۲۵٪ نسبت به روش ترکیب ویژگی‌ها عملکرد بهتری داشته است.

۴-۲-۳- ارزیابی دقت روش‌ها در چالش وجود مه غلیظ در صحنه

نمونه چهارم در این آزمایش دارای چالش وجود مه غلیظ در صحنه است. با توجه به اینکه، هدف از ایجاد یک الگوریتم برای آشکارسازی ابرها و سایه ابرها، استفاده از این نتایج در مرحله بازیابی عوارض پوشیده شده توسط ابرها و سایه ابرها است. در این آزمایش مه غلیظ در کلاس ابرها در نظر گرفته شده است.

۱- روش ترکیب ویژگی‌ها و روش *MultiCloud-Net* در مقایسه با روش تلفیق ویژگی‌های کانوولوشنی چندمقیاسه دارای نتایج مناسب‌تری می‌باشند. نتایج نشان‌دهنده این است که روش ترکیب ویژگی‌ها به‌عنوان یک روش آماری عملکرد مطلوبی در تمایز بین مه غلیظ و رقیق و سایه ابرها داشته است.

۲- هدف از به‌کارگیری روش‌های یادگیری عمیق، دستیابی به عملکردی مشابه عامل انسانی متخصص با کمترین خطا می‌باشد. روش *MultiCloud-Net* در چالش وجود مه غلیظ در صحنه، عملکرد مناسبی برای آشکارسازی ابرها داشته است. همچنین سایه ابرها را نیز در این چالش با دقت قابل‌توجهی شناسایی کرده است.

۴-۲-۴- ارزیابی نتایج با استفاده از منحنی

مشخصه عملکرد سیستم

در شکل (۶)، ماتریس ابهام و منحنی مشخصه عملکرد سیستم برای تمامی نمونه‌های آزمایش، بر اساس روش‌های مورد استفاده ارائه شده است.

پیشنهادی عملکرد مناسبی در آشکارسازی ابرها با اندازه کوچک داشته است. مقایسه عددی روش‌های مورد بررسی عبارت است از:

۱- روش *MultiCloud-Net* در معیارهای نمره *FI* و ضریب شباهت ژاکارد در حدود ۱۱٪ و ۲۰٪ نسبت به روش ترکیب ویژگی‌ها ارتقاء پیدا کرده است.

۲- روش *MultiCloud-Net* در معیارهای نمره *FI* و ضریب شباهت ژاکارد در حدود ۴٪ و ۹٪ نسبت به روش تلفیق ویژگی‌های کانوولوشنی چندمقیاسه ارتقاء پیدا کرده است.

۳- روش تلفیق ویژگی‌های کانوولوشنی چندمقیاسه در معیارهای نمره *FI* و ضریب شباهت ژاکارد در حدود ۷٪ و ۱۱٪ نسبت به روش ترکیب ویژگی‌ها عملکرد بهتری داشته است.

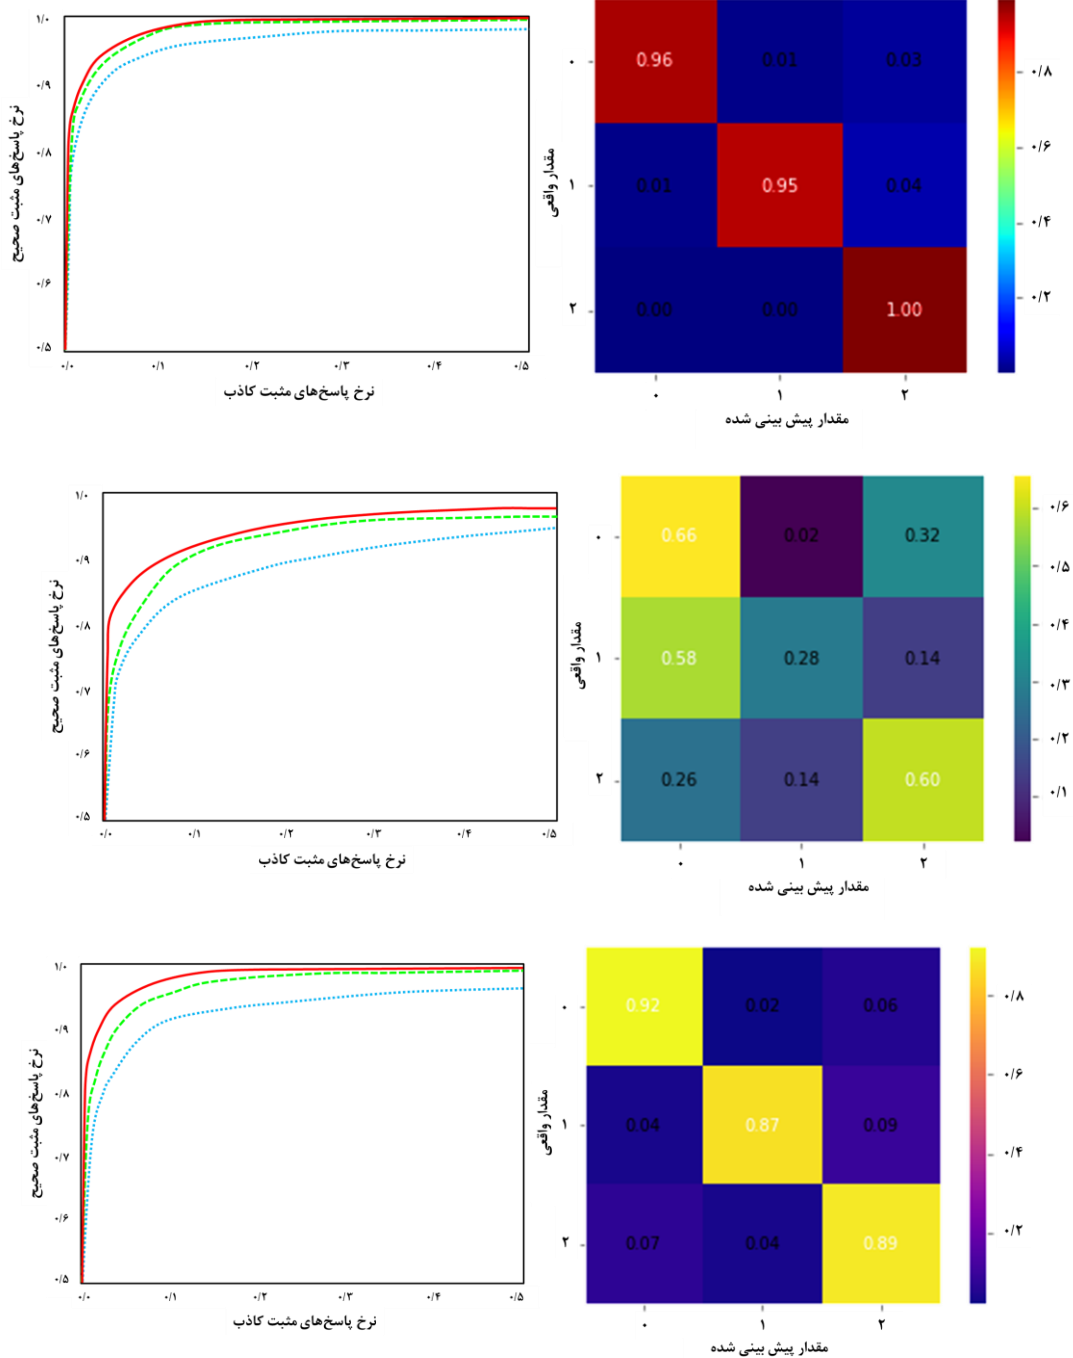
۴-۲-۴- ارزیابی دقت روش‌ها در زمینه

آشکارسازی سایه ابرها

روش ترکیب ویژگی‌ها نسبت به دو روش *MultiCloud-Net* و روش تلفیق ویژگی‌های کانوولوشنی چندمقیاسه در زمینه آشکارسازی سایه ابرها عملکرد مناسبی نداشته است و در برخی موارد مانند نمونه‌های اول، دوم، پنجم، نهم و دهم، کلاس ابرها و سایه ابرها را به میزان زیادی اشتباه شناسایی کرده است. روش تلفیق ویژگی‌های کانوولوشنی چندمقیاسه نسبت به روش *MultiCloud-Net* عملکرد ضعیف‌تری در آشکارسازی سایه ابرهای جزئی مانند نمونه‌های پنجم، هفتم و هشتم داشته است. مقایسه عددی روش‌های مورد بررسی عبارت است از:

۱- روش *MultiCloud-Net* در معیارهای نمره *FI* و ضریب شباهت ژاکارد در حدود ۴۱٪ و ۵۱٪ نسبت به روش ترکیب ویژگی‌ها ارتقاء پیدا کرده است.

۲- روش *MultiCloud-Net* در معیارهای نمره *FI* و ضریب شباهت ژاکارد در حدود ۱۸٪ و ۲۶٪ نسبت به



شکل ۶: ماتریس ابهام و منحنی مشخصه عملکرد سیستم مربوط به تمام نمونه‌های آزمایشی به تفکیک روش‌های مورد استفاده. سطر اول تا سوم به ترتیب معرف روش *MultiCloud-Net* ترکیب ویژگی‌ها و تلفیق ویژگی‌های کانولوشنی چندمقیاسه می‌باشد. کلاس صفر، یک و دو به ترتیب معرف کلاس ابر، سایه ابر و پس‌زمینه می‌باشند. در منحنی‌های مشخصه عملکرد سیستم، رنگ قرمز، سبز و آبی به ترتیب مربوط به کلاس پس‌زمینه، ابر و سایه ابر می‌باشند.

در روش *MultiCloud-Net* مساحت زیر منحنی برابر ویژگی‌ها مساحت زیر منحنی برابر ۰/۸۱، ۰/۸۸ و ۰/۷۷، ۰/۹۶ و ۰/۹۴ به ترتیب برای کلاس پس‌زمینه،

به ترتیب برای کلاس پس‌زمینه، کلاس ابر و کلاس سایه ابر می‌باشد. در روش تلفیق ویژگی‌های کانوولوشنی چندمقیاسه مساحت زیر منحنی برابر ۰/۹۶، ۰/۹۱ و ۰/۸۹ به ترتیب برای کلاس پس‌زمینه، کلاس ابر و کلاس سایه ابر می‌باشد. همچنین، میانگین ضرایب کاپا برای هر یک از روش‌ها به ترتیب برای روش *MultiCloud-Net*، ترکیب ویژگی‌ها و روش تلفیق ویژگی‌های کانوولوشنی چندمقیاسه برابر ۰/۹۸، ۰/۸۴ و ۰/۹۳ می‌باشد.

۴-۲-۵- هزینه پردازش

بین روش *MultiCloud-Net* و روش تلفیق ویژگی‌های کانوولوشنی چندمقیاسه به‌عنوان یک روش یادگیری عمیق، محاسبه هزینه پردازش مطرح است. هزینه پردازش عبارت است از مدت‌زمانی که برای آموزش معماری یادگیری عمیق هزینه می‌شود و معیار آن بر اساس تعداد تکرار در زمان هزینه‌شده برای هر تکرار است. هزینه پردازش برای روش *MultiCloud-Net* و روش تلفیق ویژگی‌های کانوولوشنی چندمقیاسه به ترتیب برابر ۱۹۲۰ و ۲۱۳۰ دقیقه در ۱۵۰ مرتبه تکرار آموزش می‌باشد. روش *MultiCloud-Net* نسبت به روش تلفیق ویژگی‌های کانوولوشنی چندمقیاسه، حدود ۲۱۰ دقیقه از هزینه محاسبه کمتری برخوردار است.

۵- نتیجه‌گیری

امروزه، توجه به پردازش تصاویر ماهواره‌ای با قدرت تفکیک مکانی بالا، بسیار مورد اهمیت است. یکی از چالش‌های مهم در زمینه آشکارسازی ابرها و سایه ابرها از این تصاویر و در مرحله بعد بازیابی عوارض پوشیده شده در زیر ابرها و سایه ابرها به‌وسیله نقشه‌های دقیق آشکارساز ابرها و سایه ابرها می‌باشد. تصاویر ماهواره گائوفن-۱ از جمله تصاویر با قدرت تفکیک مکانی بالا می‌باشند که ارائه یک راه‌حل مناسب برای آشکارسازی ابرها و سایه ابرها به‌صورت دقیق و سریع در این تصاویر بسیار حائز اهمیت است. در این تحقیق، یک روش کارآمد برای آشکارسازی خودکار ابرها و سایه ابرها مبتنی بر طراحی یک شبکه

عصبی کانوولوشنی-بازگشتی چندمقیاسه از تصاویر ماهواره گائوفن-۱ ارائه شد. روش پیشنهادی یک روش یادگیری عمیق و از نوع شبکه‌های کانوولوشنی بر اساس فیلترهایی با ابعاد مختلف، می‌باشد. مهم‌ترین نوآوری‌های روش پیشنهادی شامل: (۱) آموزش پیکسل‌ها در سه مقیاس مختلف بجای استفاده از پیکسل‌ها در یک مقیاس ثابت، موجب تولید ویژگی‌هایی می‌گردد که به تغییرهای مقیاس، مقاوم هستند و دقت فرآیند قطعه‌بندی را در تصاویر رنگی بهبود می‌دهد. (۲) به‌کارگیری یک ایده جدید به نام روش حذف تصادفی عمق، موجب بهبود هزینه محاسبه و دقت نتایج شده است. (۳) توجه به اهمیت تابع خطا در شبکه‌های یادگیری عمیق، موجب توسعه تابع خطای آنتروپی متقاطع برای قطعه‌بندی چند کلاسی شده است.

نتایج تحقیق حاضر، با یک روش آماری دقیق با نام ترکیب ویژگی‌ها و یک روش یادگیری عمیق جدید با نام تلفیق ویژگی‌های کانوولوشنی چندمقیاسه، به‌وسیله معیارهای نمره *F1* و ضریب شباهت ژاکارد، مورد مقایسه و ارزیابی قرار گرفت. نتایج نشان‌دهنده ارتقاء دقت روش پیشنهادی با نام *MultiCloud-Net* می‌باشد. در حال حاضر، روش‌های موجود در تصاویر با قدرت تفکیک مکانی بالا دارای دقت نسبتاً بالایی هستند، اما توجه به معیارهای مناسب ارزیابی دقت و تحلیل نتایج بر اساس هدف موردنظر بسیار اهمیت دارد (به همین علت در بخش ۴-۱ معیارهای مطلوب، واکاوی شدند). در این تحقیق، با توجه به اینکه قدرت تفکیک مکانی داده‌های مورد استفاده برابر ۸ متر است، حتی تعداد کم پیکسل‌های اشتباه هم حائز اهمیت است، چراکه در مرحله بعدی بازیابی عوارض پوشیده شده در ابرها و سایه ابرها موردنظر می‌باشند. بنابراین تحلیل بهبود روش‌های قبلی باید در سطح کاربرد موردبحث قرار بگیرد (همان‌طور که در انتهای بخش ۴-۲ موردبحث و مقایسه قرار گرفت).

تقدیر و تشکر

نویسندگان از پژوهشگر فرهیخته دانشگاه وهان چین، جناب آقای دکتر لی و شرکت علوم فضایی و فناوری چین (CASC) برای فراهم آوردن داده‌های این تحقیق و سایر همکاری‌های ارزشمند، تقدیر و تشکر می‌نمایند. همچنین، از شرکت گوگل برای فراهم آوردن زیرساخت گوگل کولب و واحد پردازش تنسورفلو (TPU) که موجب تسریع فرآیند پردازش در این تحقیق شد، سپاس‌گذاری می‌شود.

موضوع بازیابی عوارض پوشیده شده توسط ابرها و سایه ابرها یکی از چالش‌های اساسی و وابسته به دقت آشکارسازی ابرها و سایه ابرها است. در این تحقیق، مرحله آشکارسازی ابرها و سایه ابرها با ارائه یک روش دقیق برای تصاویر ماهواره گائوفن-۱ صورت پذیرفت. برای تحقیق‌های آینده، موضوع بازیابی عوارض بر مبنای تصاویر سری زمانی ماهواره گائوفن-۱ با استفاده از روش MultiCloud-Net برای تولید نقشه‌های دقیق آشکارساز ابرها و سایه ابرها، مورد بررسی قرار خواهد گرفت.

مراجع

- [1] M. R. Mobasheri and Y. Rezaei, "Detection of fog and low stratus using MSG-1 images," *J. College. Eng.*, vol. 41, no. 2, pp. 1107-1119, Mar. 2007.
- [2] M. R. Mobasheri, N. Gholami and M. Farajzadeh ASL, "Cloud detection from multi-temporal satellite images," *J. Spatial Plan.*, vol. 15, no. 2, pp. 81-99, Jan. 2011.
- [3] S. Foga, P. L. Scaramuzza, S. Guo, Z. Zhu, R. D. Dilley, T. Beckmann, G. L. Schmidt, J. L. Dwyer, M. Joseph Hughes, and B. Laue, "Cloud detection algorithm comparison and validation for operational Landsat data products," *Remote Sens. Environ.*, vol. 194, pp. 379-390, Jun. 2017, doi: 10.1016/j.rse.2017.03.026.
- [4] J. Yang, J. Guo, H. Yue, Z. Liu, H. Hu, and K. Li, "CDnet: CNN-based cloud detection for remote sensing imagery," *IEEE Trans. Geosci. Remote Sens.*, vol. 57, no. 8, pp. 6195-6211, Aug. 2019, doi: 10.1109/TGRS.2019.2904868.
- [5] S. Baseri Nam, A. Esmaeily, and M. Dehghani, "Propose an algorithm to improve the accuracy of snow covered mapping using MODIS images," *Eng. J. Geospatial Inf. Technol.*, vol. 3, no. 1, pp. 61-75, Jun. 2015, doi: 10.29252/jgit.3.1.61.
- [6] L. L. Stowe, E. P. McClain, R. Carey, P. Pellegrino, G. G. Gutman, P. Davis, C. Long, and S. Hart, "Global distribution of cloud cover derived from NOAA/AVHRR operational satellite data," *Adv. Space Res.*, vol. 11, no. 3, pp. 51-54, Jan. 1991, doi: 10.1016/0273-1177(91)90402-6.
- [7] G. Gesell, "An algorithm for snow and ice detection using AVHRR data An extension to the APOLLO software package," *Int. J. Remote Sens.*, vol. 10, no. 4-5, pp. 897-905, Apr. 1989, doi: 10.1080/01431168908903929.
- [8] W. B. Rossow and L. C. Garder, "Cloud detection using satellite measurements of infrared and visible radiances for ISCCP," *J. Clim.*, vol. 6, no. 12, pp. 2341-2369, Dec. 1993.
- [9] H. Guo, W. Fu, and G. Liu, "Development of Earth observation satellites," in *Scientific Satellite and Moon-Based Earth Observation for Global Change*, H. Guo, W. Fu, and G. Liu, Eds. Singapore: Springer Singapore, 2019, pp. 31-49.
- [10] K. E. Sawaya, L. G. Olmanson, N. J. Heinert, P. L. Brezonik, and M. E. Bauer, "Extending satellite remote sensing to local scales: land and water resource monitoring using high-resolution imagery," *Remote Sens. Environ.*, vol. 88,

- no. 1, pp. 144–156, Nov. 2003, doi: 10.1016/j.rse.2003.04.006.
- [11] Y. Chen, R. Fan, M. Bilal, X. Yang, J. Wang, and W. Li, "Multilevel cloud detection for high-resolution remote sensing imagery using multiple convolutional neural networks," *ISPRS Int. J. Geo-Inf.*, vol. 7, no. 5, p. 181, May 2018, doi: 10.3390/ijgi7050181.
- [12] A. Yang, B. Zhong, W. Lv, S. Wu, and Q. Liu, "Cross-calibration of GF-1/WFV over a desert site using Landsat-8/OLI imagery and ZY-3/TLC data," *Remote Sens.*, vol. 7, no. 8, pp. 10763–10787, Aug. 2015, doi: 10.3390/rs70810763.
- [13] C. Huang, N. Thomas, S. N. Goward, J. G. Masek, Z. Zhu, J. R. G. Townshend, and J. E. Vogelmann, "Automated masking of cloud and cloud shadow for forest change analysis using Landsat images," *Int. J. Remote Sens.*, vol. 31, no. 20, pp. 5449–5464, Oct. 2010, doi: 10.1080/01431160903369642.
- [14] T. Bai, D. Li, K. Sun, Y. Chen, and W. Li, "Cloud detection for high-resolution satellite imagery using machine learning and multi-feature fusion," *Remote Sens.*, vol. 8, no. 9, p. 715, Aug. 2016, doi: 10.3390/rs8090715.
- [15] A. Hollstein, K. Segl, L. Guanter, M. Brell, and M. Enesco, "Ready-to-use methods for the detection of clouds, cirrus, snow, shadow, water and clear sky pixels in Sentinel-2 MSI images," *Remote Sens.*, vol. 8, no. 8, p. 666, Aug. 2016, doi: 10.3390/rs8080666.
- [16] Z. Li, H. Shen, H. Li, G. Xia, P. Gamba, and L. Zhang, "Multi-feature combined cloud and cloud shadow detection in GaoFen-1 wide field of view imagery," *Remote Sens. Environ.*, vol. 191, pp. 342–358, Mar. 2017, doi: 10.1016/j.rse.2017.01.026.
- [17] C. Latry, C. Panem, and P. Dejean, "Cloud detection with SVM technique," in *2007 IEEE International Geoscience and Remote Sensing Symposium*, 2007, pp. 448–451, doi: 10.1109/IGARSS.2007.4422827.
- [18] M. Wieland, Y. Li, and S. Martinis, "Multi-sensor cloud and cloud shadow segmentation with a convolutional neural network," *Remote Sens. Environ.*, vol. 230, p. 111203, Sep. 2019, doi: 10.1016/j.rse.2019.05.022.
- [19] L. Sun, X. Mi, J. Wei, J. Wang, X. Tian, H. Yu, and P. Gan, "A cloud detection algorithm-generating method for remote sensing data at visible to short-wave infrared wavelengths," *ISPRS J. Photogramm. Remote Sens.*, vol. 124, pp. 70–88, Feb. 2017, doi: 10.1016/j.isprsjprs.2016.12.005.
- [20] R. A. Frey, S. A. Ackerman, Y. Liu, K. I. Strabala, H. Zhang, J. R. Key, and X. Wang, "Cloud detection with MODIS. Part I: improvements in the MODIS cloud mask for collection 5," *J. Atmospheric Ocean. Technol.*, vol. 25, no. 7, pp. 1057–1072, Jul. 2008, doi: 10.1175/2008JTECHA1052.1.
- [21] A. V. D. Vittorio and W. J. Emery, "An automated, dynamic threshold cloud-masking algorithm for daytime AVHRR images over land," *IEEE Trans. Geosci. Remote Sens.*, vol. 40, no. 8, pp. 1682–1694, Aug. 2002, doi: 10.1109/TGRS.2002.802455.
- [22] K. V. Khlopenkov and A. P. Trishchenko, "SPARC: New cloud, snow, and cloud shadow detection scheme for historical 1-km AVHRR data over Canada," *J. Atmospheric Ocean. Technol.*, vol. 24, no. 3, pp. 322–343, Mar. 2007, doi: 10.1175/JTECH1987.1.
- [23] Q. Li, W. Lu, J. Yang, and J. Z. Wang, "Thin cloud detection of all-sky images using Markov random fields," *IEEE Geosci. Remote Sens. Lett.*, vol. 9, no. 3, pp. 417–421, May 2012, doi: 10.1109/LGRS.2011.2170953.

- [24] Z. Shao, J. Hou, M. Jiang, and X. Zhou, "Cloud detection in Landsat imagery for Antarctic region using multispectral thresholds," in *Remote Sensing of the Atmosphere, Clouds, and Precipitation V*, 2014, vol. 9259, p. 92590P, doi: 10.1117/12.2070635.
- [25] R. R. Irish, "Landsat 7 automatic cloud cover assessment," in *Algorithms for Multispectral, Hyperspectral, and Ultraspectral Imagery VI*, 2000, vol. 4049, pp. 348–355, doi: 10.1117/12.410358.
- [26] D. Frantz, E. Haß, A. Uhl, J. Stoffels, and J. Hill, "Improvement of the Fmask algorithm for Sentinel-2 images: Separating clouds from bright surfaces based on parallax effects," *Remote Sens. Environ.*, vol. 215, pp. 471–481, Sep. 2018, doi: 10.1016/j.rse.2018.04.046.
- [27] O. Hagolle, M. Huc, D. V. Pascual, and G. Dedieu, "A multi-temporal method for cloud detection, applied to FORMOSAT-2, VEN μ S, LANDSAT and SENTINEL-2 images," *Remote Sens. Environ.*, vol. 114, no. 8, pp. 1747–1755, Aug. 2010, doi: 10.1016/j.rse.2010.03.002.
- [28] L. Baetens, C. Desjardins, and O. Hagolle, "Validation of Copernicus Sentinel-2 cloud masks obtained from MAJA, Sen2Cor, and FMask Processors Using Reference Cloud Masks Generated with a Supervised Active Learning Procedure," *Remote Sens.*, vol. 11, no. 4, p. 433, Jan. 2019, doi: 10.3390/rs11040433.
- [29] M. Hughes and D. Hayes, "Automated detection of cloud and cloud shadow in single-date Landsat imagery using neural networks and spatial post-processing," *Remote Sens.*, vol. 6, no. 6, pp. 4907–4926, May 2014, doi: 10.3390/rs6064907.
- [30] X. Huang and L. Zhang, "An SVM ensemble approach combining spectral, structural, and semantic features for the classification of high-resolution remotely sensed imagery," *IEEE Trans. Geosci. Remote Sens.*, vol. 51, no. 1, pp. 257–272, Jan. 2013, doi: 10.1109/TGRS.2012.2202912.
- [31] K. Tan, Y. Zhang, and X. Tong, "Cloud extraction from Chinese high resolution satellite imagery by probabilistic latent semantic analysis and object-based machine learning," *Remote Sens.*, vol. 8, no. 11, p. 963, Nov. 2016, doi: 10.3390/rs8110963.
- [32] J. E. Ball, D. T. Anderson, and C. S. Chan, "A comprehensive survey of deep learning in remote sensing: Theories, tools and challenges for the community," *J. Appl. Remote Sens.*, vol. 11, no. 04, p. 1, Sep. 2017, doi: 10.1117/1.JRS.11.042609.
- [33] M. Khoshboresh Masouleh and R. Shah-Hosseini, "Development and evaluation of a deep learning model for real-time ground vehicle semantic segmentation from UAV-based thermal infrared imagery," *ISPRS J. Photogramm. Remote Sens.*, vol. 155, pp. 172–186, Sep. 2019, doi: 10.1016/j.isprsjprs.2019.07.009.
- [34] X. X. Zhu, D. Tuia, L. Mou, G.-S. Xia, L. Zhang, F. Xu, and F. Fraundorfer, "Deep learning in remote sensing: a review," *IEEE Geosci. Remote Sens. Mag.*, vol. 5, no. 4, pp. 8–36, Dec. 2017, doi: 10.1109/MGRS.2017.2762307.
- [35] D. Chai, S. Newsam, H. K. Zhang, Y. Qiu, and J. Huang, "Cloud and cloud shadow detection in Landsat imagery based on deep convolutional neural networks," *Remote Sens. Environ.*, vol. 225, pp. 307–316, May 2019, doi: 10.1016/j.rse.2019.03.007.
- [36] Z. Li, H. Shen, Q. Cheng, Y. Liu, S. You, and Z. He, "Deep learning based cloud detection for medium and high resolution remote sensing images of different sensors," *ISPRS J. Photogramm. Remote Sens.*, vol. 150, pp. 197–212, Apr. 2019, doi: 10.1016/j.isprsjprs.2019.02.017.

- [37] C.C. Liu, Y.C. Zhang, P.-Y. Chen, C.C. Lai, Y.H. Chen, J.H. Cheng, and M.H. Ko, "Clouds classification from Sentinel-2 imagery with deep residual learning and semantic image segmentation," *Remote Sens.*, vol. 11, no. 2, p. 119, Jan. 2019, doi: 10.3390/rs11020119.
- [38] A. Francis, P. Sidiropoulos, and J.-P. Muller, "CloudFCN: Accurate and robust cloud detection for satellite imagery with deep learning," *Remote Sens.*, vol. 11, no. 19, p. 2312, Jan. 2019, doi: 10.3390/rs11192312.
- [39] L. Wang, Y. Chen, L. Tang, R. Fan, and Y. Yao, "Object-based convolutional neural networks for cloud and snow detection in high-resolution multispectral imagers," *Water*, vol. 10, no. 11, p. 1666, Nov. 2018, doi: 10.3390/w10111666.
- [40] J. Guo and S. Gould, "Depth Dropout: Efficient training of residual convolutional neural networks," in *2016 International Conference on Digital Image Computing: Techniques and Applications (DICTA)*, 2016, pp. 1–7, doi: 10.1109/DICTA.2016.7797032.
- [41] M. Khoshboresh Masouleh, R. Shah-Hosseini, and A. Safari, "Integration of deep learning algorithms and bilateral filters with the purpose of building extraction from mono optical aerial imagery," *Eng. J. Geospatial Inf. Technol.*, vol. 7, no. 2, pp. 241–263, Sep. 2019.
- [42] D. P. Kingma and J. Ba, "Adam: A method for stochastic optimization," *3rd Int. Conf. Learn. Represent. ICLR*, 2014.
- [43] K. He, X. Zhang, S. Ren, and J. Sun, "Delving deep into rectifiers: Surpassing human-level performance on ImageNet classification," in *2015 IEEE International Conference on Computer Vision (ICCV)*, Santiago, Chile, 2015, pp. 1026–1034, doi: 10.1109/ICCV.2015.123.
- [44] "Loss Functions In Deep Learning," yeephycho. [Online]. Available: <http://yeephycho.github.io/2017/09/16/Loss-Functions-In-Deep-Learning/index.html>. [Accessed: 24-Jul-2019].
- [45] M. Khoshboresh Masouleh and R. Shah-Hosseini, "A hybrid deep learning-based model for automatic car extraction from high-resolution airborne imagery," *Appl. Geomat.*, Aug. 2019, doi: 10.1007/s12518-019-00285-4.
- [46] R. R. Irish, J. L. Barker, S. N. Goward, and T. Arvidson, "Characterization of the Landsat-7 ETM+ Automated Cloud-Cover Assessment (ACCA) Algorithm," *Photogramm. Eng. Remote Sens.*, vol. 72, no. 10, pp. 1179–1188, Oct. 2006, doi: 10.14358/PERS.72.10.1179.
- [47] "Cloud Fraction." [Online]. Available: https://earthobservatory.nasa.gov/global-maps/MODAL2_M_CLD_FR. [Accessed: 30-Oct-2019].
- [48] M. Khoshboresh-Masouleh (2019). "Deploying superpixel segmentation and deep learning to improve the accuracy of the building extraction from remote sensing data", University of Tehran.
- [49] H. A. Amirkolaei and H. Arefi, "Height estimation from single aerial images using a deep convolutional encoder-decoder network," *ISPRS J. Photogramm. Remote Sens.*, vol. 149, pp. 50–66, Mar. 2019.



A multi-scale convolutional neural network for automatic cloud and cloud shadow detection from Gaofen-1 images

Mehdi Khoshboresh-Masouleh ¹, Reza Shah-Hosseini ^{2*}

1- PhD Student., School of Surveying & Geospatial Engineering, College of Engineering, University of Tehran, Tehran, Iran.

2- Assistant Professor., School of Surveying & Geospatial Engineering, College of Engineering, University of Tehran, Tehran, Iran.

Abstract

The reconstruction of the information contaminated by cloud and cloud shadow is an important step in pre-processing of high-resolution satellite images. The cloud and cloud shadow automatic segmentation could be the first step in the process of reconstructing the information contaminated by cloud and cloud shadow. This stage is a remarkable challenge due to the relatively inefficient performance of the current methods in complex scenes in multispectral high-resolution satellite images. In recent years, using deep convolutional neural networks has largely improved the performance of cloud and cloud shadow segmentation. Increasing the generalization capability of cloud and cloud shadow segmentation is one of the problems of deep convolutional neural networks. In this paper, we focus on tackling the poor generalization performance of automatic cloud and cloud shadow segmentation in Gaofen-1 (GF-1) images. In this regard, we propose a deep learning multi-scale method, founded on multi-dimension filters, for accurate segmentation of cloud/cloud shadow in single date GF-1 images which is based on a new multi-scale deep residual-convolutional neural network called MultiCloud-Net. The cloud/cloud shadow masks are extracted based on a new loss function to generate the final cloud/cloud shadow masks. The MultiCloud-Net was implemented in the Google Colab and was validated using 12 globally distributed GF-1 images. The quantitative assessments of test images show that the average F1 score, the average Jaccard Similarity Index (JSI), and the Kappa coefficient for cloud (cloud shadow) segmentation are about 97 (95.5), 96 (94.5), and 0.98, respectively. The experimental results using the GF-1 images demonstrate a more reasonable accuracy and efficient computational cost achievement of the proposed method compared to the automatic cloud/cloud shadow segmentation performance of two advanced deep learning and statistical methods.

Key words: Gaofen-1; cloud; cloud shadow; deep learning; multi-scale convolution.