

طبقه بندی تصاویر رادار SAR با استفاده از شبکه CNN-GA

بهرنگ هادیان سیاهکل^{محل}، علی علیزاده^۲

۱. استادیار، دانشکده مهندسی برق، دانشگاه علوم و فنون هوایی شهید ستاری، تهران، ایران.

۲. کارشناسی ارشد مهندسی برق مخابرات رمز، دانشکده مهندسی برق، دانشگاه علوم و فنون هوایی شهید ستاری، تهران، ایران.

تاریخ دریافت:

۲۹ مهر ماه ۱۴۰۴

تاریخ پذیرش:

۴ آذر ماه ۱۴۰۴

چکیده

در این پژوهش، یک چارچوب هوشمند برای طبقه بندی خودکار اهداف زمینی در تصاویر رادار روزنه مصنوعی معرفی می شود. مساله اصلی، تنوع ویژگی های هدف و وجود نویز اسپیکل ذاتی است که تحلیل و طبقه بندی دستی را با چالش مواجه می سازد. برای حل این مساله، یک معماری ترکیبی مبتنی بر شبکه عصبی کانولوشنی و الگوریتم ژنتیک پیشنهاد شده است. در این روش، الگوریتم ژنتیک برای بهینه سازی خودکار ابرپارامترهای معماری شبکه عصبی کانولوشنی به کار رفته و از فیلتر لی در مرحله پیش پردازش برای کاهش مؤثر نویز و حفظ لبه ها استفاده شده است. ارزیابی عملکرد بر روی مجموعه داده استاندارد ام استار نشان می دهد که روش پیشنهادی به دقت برجسته ۹۹.۳۳٪ در طبقه بندی تصاویر نویززدایی شده دست یافته است. این نتیجه، عملکرد برتر روش پیشنهادی را در مقایسه با سایر روش های متعارف به وضوح نشان می دهد. دستاورد این پژوهش، کارایی بالای رویکرد ترکیبی را در مواجهه با چالش های پیچیده پردازش تصاویر راداری تأیید کرده و گامی مؤثر در جهت توسعه سیستم های شناسایی خودکار اهداف محسوب می شود.

واژه های کلیدی: رادار روزنه مصنوعی، طبقه بندی تصاویر، شبکه کانولوشن، الگوریتم ژنتیک

Classification of SAR radar images using CNN-GA network

Mohammad Mahdi Farajollahi^۱, Mohammad Javad Babae^۲, Nadali Zarei^۳,
Mohammad Mahdi feraidooni^۴, Mahmoud Azari^۵

1. Assistant Professor, Department of Electrical Engineering Department of Electrical Engineering, Shahid Sattari Aeronautical University of Science and Technology, Tehran, Iran.

2. Department of Electrical Engineering Department of Electrical Engineering, Shahid Sattari Aeronautical University of Science and Technology, Tehran, Iran

Abstract

This research presents an intelligent framework for the automatic classification of ground targets in Synthetic Aperture Radar images. The principal challenges addressed are the diversity of target characteristics and the presence of inherent speckle noise, which complicate manual analysis and classification. To address these issues, a hybrid architecture based on a Convolutional Neural Network and a Genetic Algorithm is proposed. In this method, the Genetic Algorithm is employed for the automated optimization of the CNN architecture's hyperparameters, while the Lee filter is utilized in the pre-processing stage to effectively reduce noise and preserve edges. Performance evaluation on the standard MSTAR dataset demonstrates that the proposed method achieves a remarkable accuracy of 99.33% in classifying the denoised images. This result clearly indicates the superior performance of the proposed method compared to other conventional approaches. The outcome of this research confirms the high efficacy of the hybrid approach in addressing the complex challenges of SAR image processing and represents a significant step towards the development of robust Automatic Target Recognition systems.

Key words: Synthetic aperture radar, Classification of images, Convolution network, Genetic algorithm.

جستجوی ابرپارامترها را به طور کارآمد کاوش کنند. اهداف اصلی این پژوهش را می‌توان به شرح زیر بیان کرد:

هدف اول: طراحی یک چارچوب هوشمند برای بهینه‌سازی خودکار معماری شبکه‌های عصبی کانولوشنی با استفاده از الگوریتم ژنتیک. در این راستا، توسعه مکانیسم encode/decode کارآمد برای نمایش کروموزوم‌ها و طراحی عملگرهای ژنتیک تخصصی برای فضای پارامترهای شبکه‌های عصبی مد نظر است.

هدف دوم: توسعه یک سیستم طبقه‌بندی دقیق و robust برای اهداف زمینی در تصاویر SAR. این سیستم باید قادر به تشخیص و طبقه‌بندی اهداف مختلف در شرایط تصویربرداری متنوع باشد.

هدف سوم: کاهش اثر نویز اسپکل با استفاده از فیلترهای پیش‌پردازش پیشرفته و بررسی تأثیر این فیلترها بر دقت نهایی طبقه‌بندی.

هدف چهارم: بهبود دقت طبقه‌بندی در مقایسه با روش‌های متعارف و دستیابی به عملکرد برتر در مجموعه داده استاندارد MSTAR.

هدف پنجم: ارائه یک راه‌حل مقیاس‌پذیر برای کاربردهای عملی در محیط‌های واقعی که قابلیت adaptation با داده‌های جدید را داشته باشد. دستاوردهای این پژوهش می‌تواند در حوزه‌های متعددی کاربرد داشته باشد که از آن جمله می‌توان به موارد زیر اشاره نمود.

الف- کاربردهای دفاعی و امنیتی:

- سیستم‌های شناسایی خودکار اهداف (ATR در تصاویر SAR)

- پایش مرزها و شناسایی تحرکات نظامی

- نظارت بر مناطق حساس و شناسایی تغییرات

- شناسایی تجهیزات و ادوات نظامی [۹]

ب- کاربردهای زیست‌محیطی:

- پایش تغییرات پوشش زمین و جنگل‌زدایی

- مدیریت منابع طبیعی و ارزیابی تخریب محیط زیست

- نظارت بر مناطق حفاظت شده

- پایش تغییرات یخچال‌های طبیعی [۱۰]

ج- کاربردهای مدیریت بحران:

- ارزیابی خسارت سیل و زلزله

- پایش طوفان‌ها و گردبادها

- مدیریت بحران در بلایای طبیعی

- شناسایی مناطق آسیب‌دیده [۱۱]

د- کاربردهای کشاورزی:

- پایش محصولات کشاورزی و برآورد سطح زیرکشت

- شناسایی آفات و بیماری‌های گیاهی

- مدیریت منابع آب و خاک

- پیش‌بینی عملکرد محصولات [۱۲]

نوآوری‌های اصلی این پژوهش را می‌توان در موارد چون ارائه یک چارچوب ترکیبی CNN-GA برای بهینه‌سازی خودکار معماری شبکه، طراحی مکانیسم encode-decode کارآمد برای نمایش کروموزوم‌ها، توسعه عملگرهای ژنتیک تخصصی برای فضای پارامترهای شبکه‌های عصبی، ارائه راه‌حلی یکپارچه برای پیش‌پردازش و طبقه‌بندی تصاویر SAR،

تصویربرداری رادار روزنه مصنوعی^۱ با قابلیت منحصر به فرد تصویربرداری در تمام شرایط جوی و نوری، به یکی از ارکان اساسی سیستم‌های سنش از دور مدرن تبدیل شده است [۱]. با این حال، ماهیت تصاویر SAR با چالش‌های متعددی همراه است که مهمترین آنها وجود نویز ذاتی اسپکل^۲ می‌باشد. این نویز که ناشی از برهم‌کنش امواج الکترومغناطیسی با سطوح ناهموار است، کیفیت تصاویر را به شدت کاهش داده و تحلیل آنها را با دشواری مواجه می‌سازد [۲]. مسئله اصلی در طبقه‌بندی تصاویر SAR، تنوع و پیچیدگی ویژگی‌های اهداف مختلف در شرایط تصویربرداری متفاوت است. تغییرات زاویه دید، شرایط جوی و خصوصیات فیزیکی اهداف، موجب ایجاد تغییرات قابل توجه در بازتاب‌های راداری می‌شوند [۳]. این تغییرات، طراحی سیستم‌های طبقه‌بندی robust و دقیق را به چالشی بزرگ تبدیل کرده است. ضرورت توسعه سیستم‌های هوشمند طبقه‌بندی زمانی آشکارتر می‌شود که با حجم انبوه داده‌های تولید شده توسط ماهواره‌های مدرن مانند Sentinel-1، TerraSAR-X، RADARSAT2 مواجه می‌شویم. به عنوان مثال، ماهواره Sentinel-1 هر ۶ روز یکبار از کل کره زمین تصویربرداری می‌کند که حجم عظیمی از داده را تولید می‌نماید [۴]. در چنین شرایطی، روش‌های دستی طبقه‌بندی نه تنها غیرعملی، بلکه با خطای انسانی قابل توجهی همراه هستند. از طرفی، وابستگی به متخصصان انسانی هزینه‌های مالی و زمانی قابل توجهی را به سازمان‌ها تحمیل می‌کند.

۲-۱ مبانی نظری، ایده اصلی و اهداف پژوهش

شبکه‌های عصبی کانولوشنی^۳ به عنوان یکی از قدرتمندترین معماری‌های یادگیری عمیق، توانایی بالایی در استخراج ویژگی‌های سلسله‌مراتبی و پیچیده از تصاویر دارند [۵]. این شبکه‌ها با استفاده از لایه‌های کانولوشنی متوالی، قادر به یادگیری ویژگی‌های ساده تا پیچیده از تصاویر ورودی هستند. با این حال، عملکرد بهینه این شبکه‌ها به شدت وابسته به انتخاب مناسب ابرپارامترها شامل تعداد لایه‌ها، اندازه فیلترها، تعداد فیلترها در هر لایه، نرخ یادگیری و تابع فعال‌ساز می‌باشد [۶]. الگوریتم ژنتیک^۴ به عنوان یک تکنیک بهینه‌سازی مبتنی بر اصول تکامل طبیعی و ژنتیک، توانایی جستجوی کارآمد در فضای پارامترهای پیچیده را دارد [۷]. این الگوریتم با شبیه‌سازی فرآیند تکامل طبیعی شامل انتخاب، تقاطع و جهش، به تدریج راه‌حل‌های بهینه را تولید می‌کند. مکانیسم انتخاب بر اساس اصل "بقای مناسب‌ترین‌ها"^۵ عمل کرده و به راه‌حل‌های بهتر اجازه تولید مثل بیشتر می‌دهد. ایده اصلی این پژوهش، ترکیب هوشمندانه این دو روش در یک چارچوب یکپارچه است. در این روش، از الگوریتم ژنتیک برای بهینه‌سازی خودکار ساختار شبکه CNN استفاده می‌شود. بدین ترتیب که هر کروموزوم در الگوریتم ژنتیک نماینده یک معماری خاص از شبکه CNN است و تابع برازش بر اساس دقت طبقه‌بندی بر روی داده‌های معتبر^۶ تعریف می‌شود [۸]. مکانیسم رمزگشا/ رمزکننده^۷ در این پژوهش به این صورت پیاده‌سازی شده که هر ژن در کروموزوم نماینده یک پارامتر خاص از شبکه (مانند تعداد فیلترها یا اندازه فیلترها در یک لایه) است. عملگرهای ژنتیک شامل انتخاب^۸، تقاطع^۹ و جهش^{۱۰} به گونه‌ای طراحی شده‌اند که بتوانند فضای

6. validation

7. encode/decode

8. selection

9. crossover

10. mutation

1. Synthetic Aperture Radar

2. Speckle Noise

3. Convolution Neural Network (CNN)

4. Genetic Algorithm

5. Survival of the Fittest

استفاده از فیلترهای پیش‌پردازش هوشمند برای بهبود کیفیت تصاویر و ارائه معماری scalable برای کار با داده‌های حجیم SAR خلاصه کرد. در بخش بعد به پیشینه تحقیق پرداخته شده، در بخش سوم، مبانی نظری مربوط به رادار SAR، شبکه‌های عصبی کانولوشنی و الگوریتم ژنتیک ارائه می‌شود. در بخش چهارم به تشریح روش پیشنهادی پرداخته می‌شود. در بخش پنجم، نتایج آزمایش‌ها و شبیه‌سازی‌ها ارائه و تحلیل می‌شوند. در نهایت، در بخش ششم نتیجه‌گیری و پیشنهادات برای پژوهش‌های آتی ارائه خواهد شد.

۲- پیشینه تحقیق

در سال‌های اخیر، روش‌های مبتنی بر یادگیری عمیق به طور گسترده‌ای برای طبقه‌بندی تصاویر SAR مورد استفاده قرار گرفته‌اند. در مرجع [۱] یک چارچوب سیستماتیک برای یادگیری عمیق ویژه SAR ارائه شده و تأکید بر آن بود که طراحی معماری شبکه باید با ویژگی‌های منحصر به فرد تصاویر SAR سازگار باشد. در مرجع [۲] در مروری جامع، چالش‌های اصلی در پردازش تصاویر SAR با یادگیری عمیق را شناسایی و راهکارهای متعددی را ارائه نمودند. در مرجع [۵] یک بررسی سیستماتیک از روش‌های مبتنی بر CNN برای تفسیر تصاویر SAR انجام دادند و نشان دادند که این روش‌ها در استخراج ویژگی‌های پیچیده از تصاویر SAR موفق عمل می‌کنند. در مرجع [۶] از متا-یادگیری برای طراحی خودکار معماری CNN در طبقه‌بندی تصاویر SAR استفاده شده و بهبود قابل توجهی در دقت طبقه‌بندی گزارش شده است. همچنین مسئله بهینه‌سازی ابرپارامترها در شبکه‌های عصبی عمیق به طور گسترده‌ای مورد مطالعه قرار گرفته است. در مرجع [۷] مروری جامع بر الگوریتم‌های بهینه‌سازی چندهدفه تکاملی ارائه شده و کاربرد آنها در مسائل مختلف بهینه‌سازی مورد بررسی قرار گرفته است. در مرجع [۸] یک روش جستجوی معماری عصبی چندهدفه برای یادگیری عمیق ارائه شده که می‌توان بدین وسیله توازن بین دقت و پیچیدگی محاسباتی را برقرار کند. اخیراً پژوهش‌های متعددی بر ترکیب الگوریتم‌های تکاملی با یادگیری عمیق متمرکز شده‌اند. در مرجع [۱۳] یک روش ترکیبی مبتنی بر الگوریتم ژنتیک و CNN برای تشخیص اهداف در تصاویر SAR ارائه شده و بهبود ۳.۵ درصدی در دقت نسبت به روش‌های متعارف گزارش شده است. در مرجع [۱۴] از الگوریتم بهینه‌سازی ازدحام ذرات (PSO برای تنظیم) ابرپارامترهای شبکه‌های عمیق در طبقه‌بندی تصاویر SAR استفاده شده است. روش‌های پیش‌پردازش نقش مهمی در بهبود کیفیت تصاویر SAR ایفا می‌کنند. در مرجع [۱۵] یک روش کاهش نویز اسپکل مبتنی بر شبکه‌های عصبی ارائه شده که می‌تواند همزمان نویز را کاهش داده و جزئیات ساختاری تصویر را حفظ کند. در مرجع [۱۶] عملکرد فیلترهای مختلف کاهش نویز در تصاویر SAR را مقایسه و فیلتر Lee را به عنوان موثرترین فیلتر در حفظ لبه‌ها معرفی نموده است. مجموعه داده MSTAR به عنوان استاندارد طلایی برای ارزیابی روش‌های طبقه‌بندی اهداف در تصاویر SAR شناخته می‌شود. در مرجع [۱۷] یک بررسی جامع بر روش‌های مختلف طبقه‌بندی بر روی این مجموعه داده انجام پذیرفته و چالش‌های موجود تحلیل شده است. در مرجع [۱۸] یک معماری جدید مبتنی بر توجه به Attention برای طبقه‌بندی تصاویر SAR ارائه شده که دقت ۹۸.۷ درصدی بر روی مجموعه داده MSTAR گزارش نموده است.

با وجود پیشرفت‌های قابل توجه در زمینه طبقه‌بندی تصاویر SAR، چندین خلأ پژوهشی قابل شناسایی بوده که عبارتند از:

- عدم وجود چارچوب یکپارچه برای بهینه‌سازی خودکار معماری شبکه‌های عمیق
- نیاز به روش‌های هوشمند برای تنظیم ابرپارامترها بدون نیاز به دانش تخصصی
- کمبود پژوهش‌های سیستماتیک در زمینه ترکیب الگوریتم‌های تکاملی با CNN برای تصاویر SAR

این پژوهش با ارائه چارچوب ترکیبی CNN-GA و طراحی عملگرهای ژنتیک تخصصی، در صدد پر کردن این خلأهای پژوهشی است.

۳- اصول و مبانی فنی


۳-۱- رادار روزه مصنوعی (SAR)

رادار SAR یک سامانه تصویربرداری سنجش از راه دور می‌باشد که با نصب بر روی هواپیما، ماهواره و یا هواپیمای بدون سرنشین اقدام به تصویربرداری با کیفیت بالا از صحنه موردنظر می‌کند. این سامانه به دلیل استفاده از امواج مایکروویو، بدون در نظر گرفتن شرایط آب و هوایی و نور محیط قادر به تصویربرداری می‌باشد که این کارایی مزیت اصلی این سامانه تصویربرداری نسبت به سامانه‌های تصویربرداری نوری می‌باشد [۱۹]. وقتی رادار در طول مسیر پرواز حرکت می‌کند، پالس‌هایی به سمت هدف ارسال و اکوهای بازتابی را دریافت می‌کند. رادار بعد از ثبت و پردازش اکوهای دریافتی قادر به ترکیب آنها شده و تصویر هدف را می‌سازد.

۳-۲- مجموعه داده‌های MSTAR

با توجه به اینکه شناسایی خودکار هدف یک زمینه تحقیقی نظامی است، جمع‌آوری داده برای آن برای تمام محققان مقدور نیست و در اغلب کشورها بدلیل محرمانه بودن اطلاعات نظامی، اکتساب اطلاعاتی از آنها بسیار مشکل است و محدودیت‌های بسیاری برای محققان در این زمینه وجود دارد. خوشبختانه در سال‌های جنگ سرد، وزارت دفاع آمریکا مجموعه داده‌های بسیار بزرگ و خوبی از وسایل نظامی ساخت شوروی سابق تهیه کرده و کاملاً رایگان و آزاد در اختیار محققان قرار می‌دهد. این مجموعه MSTAR نام دارد و از ۱۰ کلاس مختلف اهداف نظامی تهیه شده‌است. داده‌های مورد استفاده در این مقاله داده‌های MSTAR می‌باشد. برای پیاده سازی سیستم طبقه‌بندی تصاویر از ۷۰ درصد داده‌های MSTAR به عنوان داده-های آموزشی و از ۳۰ درصد به عنوان داده‌های تست استفاده شده‌است [۲۰]. در شکل (۱) نمایی از ۱۰ هدف مختلف موجود در MSTAR را ملاحظه می‌کنید که در کنار هر یک از آنها نمونه‌ای از تصویر SAR مربوط به آن هدف قرار دارد.

بهبودیافته می‌باشند. تنها فیلتر حوزه مکان که از معیار MAP استفاده می‌کند، فیلتر Gamma MAP است. فیلترهای حوزه موجک از معیار MAP استفاده می‌نمایند. تفاوت این فیلترها در توزیع‌هایی است که برای ضرایب موجک تصویر بدون نویز و نویز Speckle در نظر گرفته‌اند. فیلترهای حوزه موجک لبه‌های تصویر را بهتر حفظ می‌کنند اما آنها نیز به زمان محاسبات زیادتری نسبت به فیلترهای حوزه مکان نیاز دارند. در مقابل فیلترهای حوزه مکان در جاهایی که حفظ لبه اهمیت چندانی ندارد و همچنین با محدودیت زمان روبرو هستیم مناسب هستند. در این مقاله در مرحله پیش‌پردازش، فیلترهای کاهش اثر نویز speckle مانند Lee, Frost, Koun و Gamma MAP را بر روی ۳ نمونه از تصاویر MSTAR شبیه‌سازی نموده و نتایج حاصل را مطابق شکل (۲) مقایسه می‌نماییم. با بررسی نتایج حاصل از اعمال فیلترهای مذکور مشاهده می‌کنیم که فیلتر Lee به نسبت سایر فیلترها نویززدایی بهتری از تصاویر MSTAR داشته و لبه‌های تصاویر را بهتر حفظ می‌نماید. لذا در مرحله پیش‌پردازش از فیلتر Lee بدلیل بهبود کیفیت تصویر و کاهش اثر نویز speckle استفاده نمودیم.



شکل (۲) اعمال فیلترهای Lee, Frost, Koun و GammaMap بر روی تصاویر TWO_S1, SLICY, T62

۴- شبکه عصبی پیچشی یا کانولوشنی (CNN)

از زمان پیدایش یادگیری عمیق، شبکه عصبی کانولوشنی گل سرسید ایده‌ها در یادگیری عمیق بوده‌است. به شبکه کانولوشنی به اختصار CNN یا ConvNet گفته می‌شود. شبکه CNN در سال ۱۹۹۰ با الهام‌گیری از آزمایش‌های انجام‌شده توسط Hubel و Wiesel روی قشر بینایی معرفی شد [۲۲]. یکی از اولین پروژه‌های انجام‌شده با این شبکه CNN، پروژه معروف شناسایی ارقام دست‌نویس MNIST در سال ۱۹۹۸ توسط Yann Lecun بود که نتایج امیدوارکننده‌ای به‌همراه داشت. از آنجا که استفاده از شبکه‌های عصبی تمام‌متصل عمیق به قدرت محاسباتی (حافظه) بالایی نیاز دارد تا بتوان تعداد زیادی وزن و ضرب ماتریسی سنگین را مدیریت کرد، نوع جدیدی از شبکه‌های عصبی به‌نام شبکه عصبی کانولوشنی (CNN) معرفی شد [۲۳]. در میان شبکه‌های عصبی، شبکه عصبی کانولوشنی یکی از بهترین‌ها برای حل مسائل حوزه بینایی ماشین مانند شناسایی اشیاء [۲۴]، طبقه‌بندی تصاویر [۲۵]، تشخیص چهره [۲۶] و غیره است. در طبقه‌بندی تصاویر،



شکل (۱) انواع اهداف موجود در مجموعه MSTAR [۲۱].

در جدول (۱) تعداد تصاویر ۸ کلاس از داده‌های MSTAR که در مقاله استفاده‌شده، نشان داده شده‌است.

جدول (۱) تعداد تصاویر ۸ کلاس از داده‌های MSTAR

تعداد	نام کلاس	تعداد	نام کلاس
۱۱۴۴	T62	۱۴۱۵	BRDM_2
۱۱۶۴	TWO_S1	۱۳۵۳	BTR60
۱۱۴۶	ZIL131	۵۷۳	D7
۱۴۰۳	ZSU_23_4	۱۲۷۰	SLICY

۳-۳- پیش‌پردازش تصاویر رادار SAR

تقریباً در تمامی کاربردهای پردازش تصویر به‌دلیل عدم وجود شرایط ایده‌آل برای داده‌برداری و وجود نویزهای ناخواسته‌ای که در تصاویر وجود دارد، بیش از انجام پردازش‌های اصلی بر روی داده‌ها، نیازمند کاهش نویز در داده‌ها و بهبود کیفیت تصویر هستیم که به این مرحله از فرآیند شناسایی خودکار اهداف، پیش‌پردازش می‌گویند. ساده‌ترین تأثیر نویز Speckle در تصاویر رادار را می‌توان به‌صورت بافت دانه دانه یا لکه‌های سفید و سیاه در یک تصویر راداری که از یک منطقه با پوشش کاملاً یکنواخت اخذشده، به‌وضوح دید [۲۱]. فیلترهای کاهش نویز Speckle به دو دسته تقسیم می‌شوند: فیلترهای حوزه مکان و فیلترهای حوزه موجک. بعضی از فیلترها عمومی هستند و برای هر نویزی به‌کار می‌روند که از جمله می‌توان به فیلترهای mean, median و LR^۱ اشاره نمود. بقیه فیلترها مخصوص نویز Speckle می‌باشند و براساس توزیع‌هایی که برای تصویر و نیز Speckle با آمارگان‌های آنها در نظر گرفته می‌شود، تصویر را نویززدایی می‌کنند. معیاری که برای این فیلترها به‌کار برده شده‌است، معیار MAP^۲ یا LLMMSE^۳ است. فیلترهای حوزه مکان که از معیار LLMMSE استفاده می‌کنند، Lee sigma و Lee, Frost, Frost, Koun بهبودیافته، Lee

¹ Object Detection

² Image Classification

³ Face Recognition

¹ Local Region

² Maximum A Posteriori

³ Local Linear Minimum Mean Square Error

شبکه CNN عکسی را به عنوان ورودی دریافت و آن را تجزیه و تحلیل نموده و در گروه‌های خاصی برای مثال، سگ، گربه، ببر، شیر و غیره طبقه‌بندی می‌کند. اما نکته مهم این است که کامپیوتر عکس را به شکلی نمی‌بیند که ما می‌بینیم. کامپیوتر عکس ورودی را به شکل آرایه‌ای از پیکسل‌ها می‌بیند. در واقع کامپیوتر آرایه‌ای به شکل $h \times w \times d$ می‌بیند که در آن h همان طول تصویر، w عرض تصویر و d ابعاد تصویر است. یک شبکه CNN از دو بخش کلی استخراج ویژگی^۱ و طبقه‌بندی تشکیل شده است. در واقع زمانی که یک عکس به یک شبکه CNN وارد می‌شود، ابتدا به مرحله استخراج ویژگی وارد می‌شود. در این مرحله هر عکس ورودی از چندین سری لایه کانولوشن و تابع فعال‌ساز ReLU و لایه pooling عبور می‌کند. سپس عکس‌های ورودی به طبقه‌بندی وارد می‌شوند. در این مرحله ابتدا مسطح‌سازی^۲ صورت می‌گیرد و سپس به یک لایه Fully Connected وارد می‌شوند و در نهایت یک تابع سافت مکس^۳ برای مسائل طبقه‌بندی چندکلاسه و یا تابع سیگموید^۴ برای مسائل طبقه‌بندی باینری روی آن اعمال می‌شود تا عکس‌ها براساس مقادیر احتمالی میان صفر و یک طبقه‌بندی شوند. در حقیقت شبکه‌های CNN بدین شکل عمل می‌کنند که آنها روی تصویر یا سیگنال دریافتی یک‌بعدی یا دوبعدی عمل فیلترینگ و تغییر مقیاس را به صورت متوالی انجام می‌دهند.

۵- الگوریتم ژنتیک

الگوریتم ژنتیک (GA) یکی از الگوریتم‌های فراابتکاری بوده که الهامی از علم ژنتیک و نظریه تکامل داروین است و بر اساس بقای برترین‌ها یا انتخاب طبیعی استوار است [۲۶]. الگوریتم ژنتیک یک روش بهینه‌سازی مبتنی بر جستجو بر اساس اصول ژنتیک و انتخاب طبیعی است. این الگوریتم برای یافتن راه‌حل‌های بهینه یا تقریباً بهینه برای مسائل سخت طراحی شده است. الگوریتم ژنتیک ابزار سودمندی در بازشناسی الگو، انتخاب ویژگی، درک تصویر و یادگیری ماشینی است. در الگوریتم‌های ژنتیکی، نحوه تکامل ژنتیکی موجودات زنده شبیه‌سازی می‌شود. این الگوریتم‌ها با الهام از روند تکاملی طبیعت مسائل را حل می‌نمایند. یعنی مانند طبیعت یک جمعیت از موجودات را تشکیل می‌دهند و با اعمالی بر روی این مجموعه به یک مجموعه بهینه و یا موجود بهینه دست می‌یابند. همچنین با توجه به خصوصیات خاص خودشان به خوبی از عهده حل مسائلی که نیاز به بهینه‌سازی دارند برمی‌آیند. برای آموزش الگوریتم ژنتیک بهتر است با تعریف بهینه‌سازی شروع کنیم. بهینه‌سازی روند بهتر کردن چیزی است. در هر فرآیندی، مجموعه‌ای از ورودی‌ها و خروجی‌ها را داریم که در شکل (۳) نشان داده شده است.



شکل (۳) مجموعه‌ای از ورودی‌ها و خروجی‌ها در الگوریتم ژنتیک

بهینه‌سازی به یافتن مقادیر ورودی‌ها به گونه‌ای اشاره دارد که بهترین مقادیر خروجی بدست آید. تعریف "بهترین" از مسئله‌ای به مسئله دیگر متفاوت است، اما در اصطلاح ریاضی، به حداکثر کردن^۵ یا کمینه کردن^۶ یک یا چند تابع هدف با تغییر پارامترهای ورودی اشاره دارد. به مجموعه‌ای از تمام راه-حل‌ها یا مقادیر ممکن که ورودی‌ها می‌توانند بگیرند، فضای جستجو گفته می‌شود. در این فضای جستجو، یک نقطه یا مجموعه‌ای از نقاط نهفته است که راه حل بهینه را ارائه می‌دهد. هدف از بهینه‌سازی یافتن آن نقطه یا مجموعه‌ای از نقاط در فضای جستجو است. الگوریتم ژنتیک توسط جان هالند و دانشجویان و همکارانش در دانشگاه میشیگان ابداع و توسعه یافت و از آن زمان بر روی مسائل مختلف بهینه‌سازی با درجه موفقیت بالایی آزمایش شده است. در الگوریتم ژنتیک، یک مجموعه یا جمعیتی از راه‌حل‌های ممکن برای یک مسئله را داریم. سپس این راه‌حل‌ها دچار نوترکیبی^۷ و جهش (مانند ژنتیک طبیعی) می‌شوند و فرزندان جدیدی تولید می‌شوند و این روند در نسل‌های مختلف تکرار می‌شود [۲۷]. به هر عضو (یا راه‌حل نامزد) یک مقدار تناسب (بر اساس مقدار تابع هدف) اختصاص داده می‌شود و به عضوهای مناسب شانس بیشتری برای جفت‌گیری و تولید اعضای "مناسب" داده می‌شود. (این عمل با نظریه داروین در مورد "بقای شایسته‌ترین‌ها" مطابقت دارد). به این ترتیب اعضا یا راه‌حل‌های بهتر در طول نسل‌ها به (تکامل) می‌رسند تا زمانی که به یک معیار توقف برسیم. الگوریتم ژنتیک از نظر ماهیت به اندازه کافی تصادفی است، همان چیزی که باعث پیدایش آفرینش شده- است. الگوریتم GA عملکرد بهتری نسبت به جستجوی تصادفی (که در آن ما فقط راه‌حل‌های تصادفی مختلفی را امتحان می‌کنیم) دارد، چون از اطلاعات گذشته نیز بهره می‌برد.

۵-۱- مزایای الگوریتم ژنتیک

الگوریتم GA دارای مزایای مختلفی است که باعث محبوبیت فوق العاده آن شده است. این مزایا عبارتند از:

- * به هیچ اطلاعات مشتق شده‌ای نیاز ندارد (که ممکن است در بسیاری از مسائل دنیای واقعی در دسترس نباشد) [۲۸].
- * در مقایسه با روش‌های سنتی سریع‌تر و کارآمدتر است.
- * قابلیت‌های موازی بسیار خوبی دارد.
- * توابع پیوسته و گسسته و همچنین مسائل چندهدفه را بهینه می‌کند.
- * فهرستی از راه‌حل‌های "خوب" و نه تنها یک راه حل را ارائه می‌دهد.
- * همیشه پاسخی برای مسئله می‌گیرد که با گذشت زمان بهتر می‌شود.
- * زمانی مفید است که فضای جستجو بسیار بزرگ است و تعداد زیادی پارامتر در آن دخیل باشد.

۵-۲- محدودیت‌های الگوریتم ژنتیک

مانند هر روش دیگر، الگوریتم ژنتیک نیز از محدودیت‌هایی برخوردار است. در آموزش الگوریتم ژنتیک بهتر است این محدودیت‌ها را بشناسید که عبارتند از: این الگوریتم برای همه مسائل مناسب نیستند به ویژه مسائلی که ساده هستند و اطلاعات مشتق شده برای آنها در دسترس است.

¹ Maximizing

² Minimizing

³ Recombination


⁴ Feature Extraction

⁵ Flattening

⁶ Softmax

⁷ Sigmoid

سریع باشد، زیرا در طول اجرای الگوریتم، بارها و بارها ارزش تابع تناسب محاسبه می‌شود. در شکل (۵) کدگذاری و کدگشایی نشان داده شده‌است.




شکل (۵) شماتیک فرآیند کدگذاری و کدگشایی کروموزوم در الگوریتم ژنتیک

تابع تناسب^۶: تابع تناسب تابعی است که راه‌حل را به عنوان ورودی می‌گیرد و مناسب بودن راه‌حل را به عنوان خروجی تولید می‌کند. در برخی موارد، تابع تناسب و تابع هدف ممکن است یکسان باشند، در حالی که در برخی مسائل دیگر ممکن است بر اساس شکل مسئله متفاوت باشند.

عملگرهای ژنتیک^۷: عملگرهای ژنتیک، ترکیب ژنتیکی فرزندان را تغییر می‌دهند که عبارتند از تقاطع، جهش، انتخاب و غیره.

۵-۴- ساختار الگوریتم ژنتیک

ساختار اصلی الگوریتم ژنتیک با جمعیت اولیه شروع می‌شود (که ممکن است به طور تصادفی ایجاد شود یا توسط سایر روش‌های اکتشافی ایجاد شود)، سپس والدین از بین این جمعیت برای جفت‌گیری انتخاب می‌شوند [۳۰]. عملگرهای Crossover و جهش روی والدین اعمال می‌شوند تا فرزندان جدید تولید شوند. در نهایت فرزندان جدید جایگزین اعضای موجود در جمعیت می‌شوند و این روند تکرار می‌شود. به این ترتیب الگوریتم ژنتیک در واقع سعی می‌کند تا حدی از تکامل انسان تقلید کند. در شکل (۶) ساختار الگوریتم ژنتیک نشان داده شده‌است.



شکل (۶) فلوجارت الگوریتم ژنتیک نشان‌دهنده مراحل اصلی و جریان تکاملی

* ارزش تابع هدف به طور مکرر محاسبه می‌شود که ممکن است برای برخی مسائل از نظر محاسباتی پرهزینه باشد.

* به دلیل تصادفی بودن، هیچ تضمینی در مورد بهینه بودن یا کیفیت راه‌حل وجود ندارد.

* اگر به درستی اجرا نشود، ممکن است به راه‌حل بهینه همگرا نشود.

۵-۳- مبانی الگوریتم ژنتیک

در این بخش اصطلاحات اساسی مورد نیاز برای درک الگوریتم معرفی می‌شود. در شکل (۴) تعدادی از مفاهیم پایه در الگوریتم ژنتیک نشان داده شده‌است.


جمعیت^۱: زیر مجموعه‌ای از همه راه‌حل‌های ممکن (کدگذاری شده) برای یک مسئله است. جمعیت برای یک الگوریتم GA مشابه جمعیت برای انسان است با این تفاوت که به جای انسان، ما راه‌حل‌های نامزدی داریم که نماینده انسان‌ها هستند [۲۹].

کروموزوم^۲: کروموزوم یکی از راه‌حل‌های مسئله در بین جمعیت است. ژن^۳: موقعیت یک عنصر از کروموزوم است.

Allele: مقداری است که یک ژن برای یک کروموزوم خاص می‌گیرد.

ژنوتایپ^۴: ژنوتایپ جمعیت در فضای محاسباتی است. در فضای محاسباتی، راه‌حل‌ها به گونه‌ای نمایش داده می‌شوند که به راحتی قابل درک و دستکاری با استفاده از یک سیستم محاسباتی باشند.

فنوتایپ^۵: فنوتایپ جمعیتی در فضای واقعی راه‌حل دنیای واقعی است که در آن راه‌حل‌ها به گونه‌ای نشان داده می‌شوند که در موقعیت‌های دنیای واقعی نشان داده می‌شوند.



شکل (۴) مفاهیم پایه در الگوریتم ژنتیک

کدگذاری^۶ و کدگشایی^۷: برای مسائل ساده، فضاهای فنوتایپ و ژنوتایپ یکسان هستند. اما در بیشتر موارد فضاهای فنوتایپ و ژنوتایپ متفاوت است. کدگشایی فرآیند تبدیل راه‌حل از ژنوتایپ به فضای فنوتایپ است، در حالی که کدگذاری فرآیند تبدیل از فنوتایپ به فضای ژنوتایپ است. کدگشایی باید

⁶ Encoding

⁷ Decoding

⁸ Fitness Function

⁹ Genetic Operators

¹ Population

² Chromosome

³ Gene

⁴ Genotype

⁵ Phenotype

۶- روش پیشنهادی CNN-GA

روش پیشنهادی در این پروژه، بهینه‌سازی پارامترهای شبکه عصبی CNN به کمک الگوریتم ژنتیک جهت طبقه‌بندی تصاویر MSTAR می‌باشد. در واقع یک شبکه عصبی اولیه وجود دارد که باید پارامترهای آن شبکه به کمک الگوریتم ژنتیک بهینه گردد. به منظور بهینه‌سازی شبکه CNN به کمک الگوریتم ژنتیک، تعداد فیلترها و اندازه فیلترها برای هر لایه کانولوشن به عنوان پارامترهای مسئله جهت بهینه‌سازی در نظر گرفته می‌شود.

۶-۱- ساختار کروموزوم ها

در ساختار شبکه CNN اولیه ۸ لایه کانولوشن وجود دارد. بنابراین 2×8 پارامتر در الگوریتم ژنتیک در نظر گرفته خواهد شد. در شکل (۷) ساختار کروموزوم‌ها در این الگوریتم نشان داده شده است.

Number of filter				Size of filter			
Layer 8	Layer 7	Layer 6	Layer 5	Layer 4	Layer 3	Layer 2	Layer 1
Layer 8	Layer 7	Layer 6	Layer 5	Layer 4	Layer 3	Layer 2	Layer 1

شکل (۷) ساختار کروموزوم و نحوه نمایش پارامترهای شبکه CNN برای الگوریتم ژنتیک

تعداد فیلترهای هر لایه می‌تواند یکی از توان‌های ۲ باشد، به عنوان مثال (۲، ۴، ۸ و ...) که یک ماکزیمم برای آن در نظر گرفته می‌شود. در اینجا مقدار ۶۴ را به عنوان بیشینه در نظر گرفته شده است. سائز فیلترها نیز می‌توانند بین یک تا ماکزیمم مقدار باشند که در اینجا ۷ در نظر گرفته شده است. اندازه Padding در هر لایه به میزان (نصف اندازه فیلتر) در نظر گرفته می‌شود و MaxPooling‌ها مانند ساختار اولیه با اندازه ۲ و stride با اندازه ۲ در نظر گرفته می‌شوند. بنابراین اگر کروموزومی مانند شکل (۸) داشته باشیم، ساختار شبکه CNN مرتبط با کروموزوم انتخابی به صورت شکل (۹) خواهد بود.

Number of filter				Size of filter			
64	16	8	2	16	16	64	1
64	16	8	2	16	16	64	1

شکل (۸) مثال عینی از یک کروموزوم و تفسیر مقادیر آن

ساختار شبکه CNN مرتبط با کروموزوم انتخابی	
imageInputLayer(InputImageSize)	
convolution2dLayer(1,64,'Padding',0)	
batchNormalizationLayer	
reluLayer	
maxPooling2dLayer(2,'Stride',2)	
convolution2dLayer(5,16,'Padding',2)	
batchNormalizationLayer	
reluLayer	
maxPooling2dLayer(2,'Stride',2)	
convolution2dLayer(1,8,'Padding',0)	
batchNormalizationLayer	
reluLayer	
maxPooling2dLayer(2,'Stride',2)	
convolution2dLayer(3,64,'Padding',1)	
batchNormalizationLayer	
reluLayer	
maxPooling2dLayer(2,'Stride',2)	
convolution2dLayer(3,2,'Padding',1)	
batchNormalizationLayer	
reluLayer	
maxPooling2dLayer(2,'Stride',2)	
convolution2dLayer(3,16,'Padding',1)	
batchNormalizationLayer	
reluLayer	
maxPooling2dLayer(2,'Stride',2)	
convolution2dLayer(3,16,'Padding',1)	
batchNormalizationLayer	
reluLayer	
maxPooling2dLayer(2,'Stride',2)	
convolution2dLayer(3,64,'Padding',1)	
batchNormalizationLayer	
reluLayer	
maxPooling2dLayer(2,'Stride',2)	
fullyConnectedLayer(8)	
softmaxLayer	
classificationLayer(1): %m	

شکل (۹) ساختار شبکه CNN مرتبط با کروموزوم انتخابی

۶-۲- تابع برازندگی


هر CNN متناظر با کروموزوم، با مجموعه داده آموزش، آموزش داده می‌شود و سپس مجموعه داده تست با شبکه آموزش داده شده مورد ارزیابی قرار می‌گیرند و مقدار 1-accuracy به عنوان مقدار برازندگی آن کروموزوم در نظر گرفته می‌شود. در واقع هرچه مقدار آن کمتر باشد آن کروموزوم برازنده تر است.

۶-۳- عملگر انتخاب

از عملگر انتخاب تورنمنت با اندازه ۲ استفاده می‌شود و همچنین با استفاده از روش نخبه‌گرایی بهترین کروموزوم مستقیماً به نسل بعد وارد می‌شود.

۶-۴- عملگر ترکیب

در عملگر ترکیب، در بازه عدد یک تا تعداد فیلترها دو عدد تصادفی ایجاد می‌شود و ژن‌های بین این دو کروموزوم از والد یک و سائز ژن‌ها از والد دوم برای فرزند کپی می‌شوند. همچنین در بازه سائز فیلترها (اینجا [۲۲-۳۰]) دو عدد تصادفی ایجاد می‌شود و ژن‌های فرزند بین این دو مقدار از والد اول و برای سایر مقادیر از والد دوم کپی می‌شود. در شکل (۱۰) این مفهوم نمایش داده شده است.



شکل (۱۰) شماتیک عملکرد عملگر تقاطع (Crossover) و نحوه تولید کروموزوم فرزند از والدین

۶-۵- عملگر جهش

در عملگر جهش مانند شکل (۱۱) عمل می‌شود. یعنی در بازه عدد یک تا تعداد فیلترها دو عدد تصادفی ایجاد می‌شود و ژن‌های متناظر با اعداد انتخاب شده با هم جابه‌جا می‌شوند. همچنین در بازه سائز فیلترها (اینجا [۲۲-۳۰]) دو عدد تصادفی ایجاد می‌شود و ژن‌های متناظر با اعداد انتخاب شده با هم جابه‌جا می‌شوند.

۷- پیاده‌سازی طبقه‌بندی تصاویر MSTAR

در این بخش در ابتدا نسبت به پیاده‌سازی و بررسی نتایج حاصل از طبقه‌بندی تصاویر با استفاده از شبکه CNN بر روی تصاویر نویزی و نویزدایی شده داده‌های MSTAR بحث خواهیم نمود. در ادامه در خصوص پیاده‌سازی و

۷-۱-۱- پیاده‌سازی طبقه‌بندی تصاویر نویزی MSTAR با CNN


فرآیند آموزش شبکه برای ۷۰٪ داده‌های آموزشی نویزی در شکل‌های (۱۳) و (۱۴) نشان داده شده‌است که برای تصاویر نویزی MSTAR دقت نهایی ۹۷.۲۵٪ برای شبکه CNN بدست آمد. دقت ۹۷.۲۵٪ حاصل از شبکه CNN پایه بر روی تصاویر نویزی، با وجود اینکه عددی بالا محسوب می‌شود، نشان‌دهنده چالش ذاتی نويز اسپکل در تصاویر SAR است. این نويز با ایجاد آرتیفک‌های تصویری و کاهش نسبت سیگنال به نويز (SNR)، استخراج ویژگی‌های تمایزدهنده را برای شبکه عصبی با دشواری مواجه می‌سازد. عملکرد بسیار خوب شبکه پایه CNN (بدون بهینه‌سازی پیشرفته) خود گواهی بر توانایی ذاتی این شبکه‌ها در یادگیری ویژگی‌های مرتبط، حتی در حضور نويز شدید، می‌باشد. با این حال، همان‌طور که در مقایسه‌های بعدی مقاله مشاهده خواهد شد، این رقم نقطه‌آغاز مناسبی برای نشان‌دادن تأثیر مثبت بهینه‌سازی هاپیرپارامترها با الگوریتم ژنتیک و همچنین پیش‌پردازش صحیح تصاویر است. این نتیجه به وضوح توجیه‌گر ضرورت استفاده از روش‌های پیشرفته‌تر، مانند چارچوب پیشنهادی این پژوهش، برای دستیابی به دقت‌های عملیاتی بالاتر در کاربردهای حساس است.

Training on single GPU.
Initializing input data normalization.

Epoch	Iteration	Time Elapsed (hh:mm:ss)	Mini-batch Accuracy	Mini-batch Loss	Base Learning Rate
1	1	00:00:05	6.25%	3.1847	0.1000
1	50	00:02:05	46.88%	1.4264	0.1000
1	100	00:04:07	31.25%	1.6228	0.1000
1	150	00:06:10	59.38%	1.1142	0.1000
1	200	00:08:16	75.00%	0.7473	0.1000
2	250	00:10:24	59.38%	0.7685	0.1000
2	300	00:12:32	59.38%	0.9522	0.1000
2	350	00:14:42	78.12%	0.5243	0.1000
2	400	00:17:03	84.38%	0.2938	0.1000
3	450	00:19:19	90.62%	0.3349	0.1000
3	500	00:21:39	81.25%	0.4957	0.1000
3	550	00:23:53	78.12%	0.5474	0.1000
3	600	00:26:12	93.75%	0.2340	0.1000
4	650	00:28:26	96.88%	0.1166	0.1000
4	700	00:30:40	84.38%	0.5485	0.1000
4	750	00:32:53	84.38%	0.3903	0.1000
4	800	00:35:02	93.75%	0.0916	0.1000
4	828	00:36:13	93.75%	0.1038	0.1000

accuracyNetwork = 0.9725


شکل (۱۳) فرآیند آموزش شبکه CNN برای داده‌های آموزشی ۷۰٪



شکل (۱۴) فرآیند آموزش شبکه CNN برای تصاویر نویزی

در شکل (۱۵) نمایش Matrix Confusion برای طبقه‌بندی تصاویر نویزی MSTAR نشان داده شده‌است. در شکل (۱۶) با استفاده از داده‌های تست، دقت شبکه CNN در طبقه‌بندی تصاویر مورد ارزیابی قرار گرفت که یک نمونه از تصاویر نویزی کلاس TWO_S1 را با دقت ۸۳.۶٪ پیش‌بینی نمود.

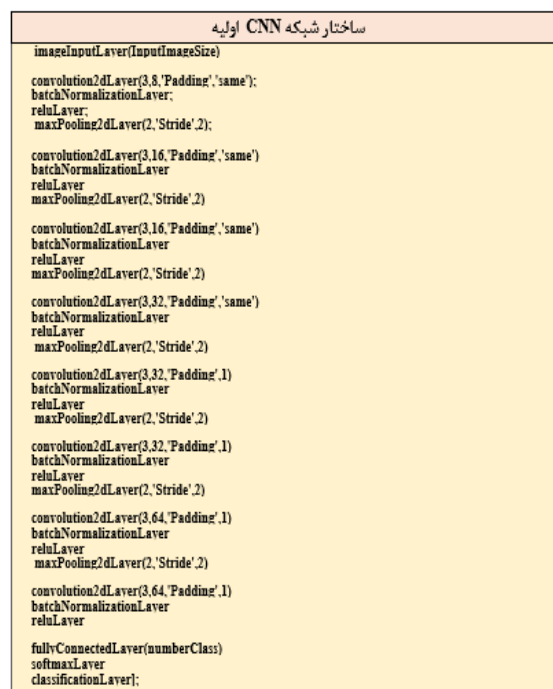
بررسی نتایج شبیه‌سازی روش پیشنهادی شبکه CNN-GA برای طبقه‌بندی تصاویر نویزی و نويززدایی شده داده‌های MSTAR صحبت خواهیم‌نمود. همچنین پیرامون بررسی و مقایسه نتایج حاصل از پیاده‌سازی طبقه‌بندی تصاویر با استفاده از شبکه CNN و شبکه CNN-GA بر روی ۱۰ تا ۹۰ درصد داده‌های MSTAR به‌عنوان داده‌های آموزشی صحبت خواهیم‌نمود. در آخر نتایج حاصل از شبکه CNN-GA را با سایر روش‌های مطرحه در مراجع مختلف مقایسه می‌کنیم.



شکل (۱۱) شمایک عملکرد عملگر جهش (Mutation) و ایجاد تغییرات تصادفی در کروموزوم

۷-۱-۲- پیاده‌سازی طبقه‌بندی تصاویر MSTAR با CNN

در این بخش نسبت به پیاده‌سازی و بررسی نتایج حاصل از طبقه‌بندی تصاویر با استفاده از شبکه CNN بر روی تصاویر نویزی و نويززدایی شده داده‌های MSTAR خواهیم‌پرداخت. در شکل (۱۲) ساختار شبکه CNN اولیه نشان داده شده‌است.




شکل (۱۲) معماری پایه و اولیه شبکه عصبی کانولوشنی (CNN) به کار رفته در پژوهش به عنوان مدل مرجع

و اندازه فیلترها در لایه های کانولوشنی، موفق به طراحی معماری شده است که توانایی بسیار بالاتری در استخراج ویژگی های مرتبط و مقاوم در برابر نویز از تصاویر خام SAR دارد. این نتیجه ثابت می کند که حتی بدون حذف نویز (فقط با بهینه سازی معماری شبکه)، می توان به دقت های بسیار بالایی دست یافت که به عملکرد مدل در شرایط واقعی و داده های خام نزدیک تر است. این موفقیت، پایه و توجیه محکمی برای نتایج برجسته تر مدل در مرحله بعد (پس از اعمال پیش پردازش) فراهم می سازد.


Epoch	Iteration	Time Elapsed (hh:mm:ss)	Mini-batch Accuracy	Mini-batch Loss	Base Learning Rate
1	1	00:00:16	23.44%	2.4940	0.1000
1	50	00:11:00	51.56%	1.3674	0.1000
1	100	00:21:34	70.31%	0.9011	0.1000
2	150	00:32:10	71.88%	0.7303	0.1000
2	200	00:43:08	89.06%	0.2756	0.1000
3	250	00:56:11	87.50%	0.2944	0.1000
3	300	01:08:31	92.19%	0.1694	0.1000
3	350	01:20:14	90.63%	0.1811	0.1000
4	400	01:33:03	90.63%	0.2612	0.1000
4	450	01:45:21	96.88%	0.0487	0.1000
5	500	01:57:32	95.31%	0.0641	0.1000
5	550	02:09:16	96.88%	0.0836	0.1000
5	600	02:21:45	100.00%	0.0300	0.1000
5	610	02:23:57	99.44%	0.0334	0.1000

شکل (۲۳) فرآیند آموزش CNN-GA برای داده‌های آموزشی ۷۰٪



شکل (۲۴) فرایند آموزش شبکه CNN-GA برای تصاویر نویزی

در شکل (۲۵) نمایش Matrix Confusion برای طبقه‌بندی تصاویر نویزی MSTAR برای شبکه CNN-GA نشان داده شده‌است.



شکل

(۲۵) نمایش Matrix Confusion برای طبقه‌بندی تصاویر نویزی
MSTAR برای شبکه CNN-GA

در شکل (۲۶) با استفاده از داده‌های تست، دقت شبکه CNN-GA در طبقه‌بندی تصاویر مورد ارزیابی قرار گرفت که یک نمونه از تصاویر نویزی کلاس ۲ BRDM را با دقت ۱۰۰٪ پیش‌بینی نمود.

۷-۲- پیاده سازی طبقه بندی MSTAR با شبکه CNN-GA

در این بخش در خصوص پیاده‌سازی و بررسی نتایج شبیه‌سازی برای طبقه‌بندی تصاویر MSTAR با استفاده از روش پیشنهادی شبکه CNN-GA صحبت خواهیم‌نمود. برای اجرای الگوریتم ژنتیک، ۶۰ درصد داده‌ها به‌عنوان داده‌های آموزشی و ۴۰ درصد داده‌ها به‌منظور داده‌های تست به‌صورت تصادفی انتخاب می‌شوند. ده کروموزوم در جمعیت اولیه وجود دارد و الگوریتم ژنتیک نیز تا ۱۵ نسل اجرا می‌گردد. پس از اتمام الگوریتم ژنتیک بهترین کروموزوم انتخاب می‌گردد که در شکل (۲۱) نشان داده شده‌است.

[illegible]

شکل (۲۱) بهترین کروموزوم انتخابی


با توجه به‌ترین کروموزوم انتخابی، ساختار CNN در شکل (۲۲) نشان داده شده‌است.

[illegible]

شکل (۲۲) ساختار شبکه CNN مطابق با بهترین کروموزوم انتخابی

۷-۲-۱ پیاده‌سازی طبقه‌بندی تصاویر نویزی **MSTAR** با **CNN-GA**


فرآیند آموزش شبکه پیشنهادی CNN-GA برای ۷۰٪ داده‌های آموزشی نویزی در شکل‌های (۲۳) و (۲۴) نشان داده شده‌است که برای تصاویر نویزی MSTAR دقت نهایی ۹۸٫۸۴٪ برای شبکه CNN-GA بدست آمد. دقت ۹۸/۸۴ درصد به دست آمده توسط معماری بهینه شده CNN-GA بر روی تصاویر نویزی، نشان دهنده یک جهش کیفی در مقایسه با دقت ۹۷/۲۵ درصد مدل پایه CNN است. این بهبود ۱/۵۹ درصدی، نقش حیاتی و اثربخشی الگوریتم ژنتیک در جستجوی خودکار فضای پیچیده هاپیرپارامترها را به وضوح تأیید می‌کند. الگوریتم ژنتیک با یافتن ترکیب بهینه‌ای از تعداد



شکل (۲۸) فرآیند آموزش CNN-GA برای تصاویر نویززدایی شده




شکل (۲۹) نمایش Matrix Confusion طبقه‌بندی تصاویر نویززدایی شده MSTAR شبکه CNN-GA



شکل (۳۰) تست شبکه CNN-GA با استفاده از داده تست نویززدایی شده BRDM_2 با دقت ۱۰۰٪

۷-۳- مقایسه شبکه‌های CNN و CNN-GA

در شکل های (۳۱) نمودار میله‌ای مقایسه بین طبقه‌بندی تصاویر نویزی و نویززدایی شده MSTAR با استفاده از شبکه CNN و روش پیشنهادی شبکه CNN-GA نشان داده شده‌است. همان‌طور که در شکل‌های مذکور مشخص است، بهترین دقت شبکه مربوط به طبقه‌بندی تصاویر نویززدایی شده MSTAR با روش پیشنهادی شبکه CNN-GA با دقت ۹۹.۳۳٪ می‌باشد. مقایسه کمی بین دو مدل CNN پایه و CNN-GA در شرایط مختلف (داده نویزی و نویززدایی شده) به وضوح برتری سیستماتیک چارچوب



شکل (۲۶) تست شبکه CNN-GA با استفاده از داده تست نویزی BRDM_2 با دقت ۱۰۰٪

۷-۲-۲- پیاده‌سازی طبقه‌بندی تصاویر نویززدایی شده CNN-GA با MSTAR

فرآیند آموزش شبکه برای ۷۰٪ داده‌های آموزشی نویززدایی شده در شکل-های (۲۷) و (۲۸) نشان داده شده‌است که برای تصاویر نویززدایی شده MSTAR دقت نهایی ۹۹.۳۳٪ برای شبکه CNN-GA بدست آمد. دقت ۹۹.۳۳٪ که توسط معماری بهینه‌شده CNN-GA بر روی تصاویر نویززدایی شده به دست آمده، نه تنها نقطه اوج عملکرد در این پژوهش محسوب می‌شود، بلکه نشان‌دهنده هم‌افزایی قدرتمند بین سه مؤلفه کلیدی است: ۱: (پیش‌پردازش هوشمند) فیلتر Lee برای حذف نویز، ۲: (قدرت استخراج ویژگی) شبکه (CNN)، و ۳: (بهینه‌سازی هوشمند معماری) الگوریتم ژنتیک. این نتیجه برتر حاکی از آن است که الگوریتم ژنتیک توانسته است با در اختیار داشتن داده‌های باکیفیت‌تر (خروجی مرحله پیش‌پردازش)، یک معماری بسیار کارآمدتر را کشف کند که به طور همزمان از داده‌های پاک‌تر بهتر یاد می‌گیرد و تعمیم می‌یابد. این دقت، یک بهبود ۰.۸۸ درصدی را حتی در مقایسه با عملکرد بسیار خوب همین مدل روی داده‌های نویزی (۹۸.۸۴٪) نشان می‌دهد که بر ضرورت یکپارچه‌سازی این دو مرحله (پیش‌پردازش و بهینه‌سازی معماری) تأکید می‌کند. دستیابی به چنین سطحی از دقت، سیستم پیشنهادی را به عنوان یک راه‌حل عملی و بسیار قابل اعتماد برای کاربردهای حساس واقعی در حوزه پردازش تصاویر SAR مطرح می‌سازد.

Training on single CPU.
Initializing input data normalization.


Epoch	Iteration	Time Elapsed (hh:mm:ss)	Mini-batch Accuracy	Mini-batch Loss	Base Learning Rate
1	1	00:00:24	12.50%	3.1016	0.1000
1	50	00:04:41	65.62%	0.8241	0.1000
1	100	00:08:39	81.25%	0.5118	0.1000
2	150	00:12:27	71.88%	0.5579	0.1000
2	200	00:16:23	95.31%	0.0941	0.1000
3	250	00:21:04	96.88%	0.0855	0.1000
3	300	00:25:16	96.88%	0.0808	0.1000
4	350	00:28:54	98.44%	0.0514	0.1000
4	400	00:32:34	100.00%	0.0111	0.1000
5	450	00:36:19	100.00%	0.0190	0.1000
5	500	00:40:02	98.44%	0.0240	0.1000
5	515	00:41:06	100.00%	0.0150	0.1000

accuracyNetworkResult = 0.9933

شکل (۲۷) فرآیند آموزش CNN-GA برای داده‌های آموزشی ۷۰٪

در شکل (۲۹) نمایش Matrix Confusion برای طبقه‌بندی تصاویر نویززدایی شده MSTAR برای شبکه CNN-GA نشان داده شده‌است. در شکل (۳۰) با استفاده از داده‌های تست، دقت شبکه CNN-GA در طبقه‌بندی تصاویر مورد ارزیابی قرار گرفت که یک نمونه از تصاویر نویززدایی شده کلاس BRDM_2 با دقت ۱۰۰٪ پیش‌بینی نمود.


را کاهش داده و منجر به تعمیم‌پذیری بهتر می‌شود. این یافته، ارزش چارچوب پیشنهادی را فراتر از صرفاً دستیابی به دقت اوج، و به عنوان یک راه‌حل مقیاس‌پذیر و قدرتمند در سناریوهای داده‌ای محدود نیز تثبیت می‌کند.



شکل (۳۲) نمودار میله‌ای مقایسه دقت شبکه‌های CNN و CNN-GA برای داده‌های آموزشی ۱۰-۹۰ درصد


۷-۵- مقایسه انواع روش‌های طبقه‌بندی تصاویر

در این بخش سعی داریم نتایج حاصل از پیاده‌سازی شبکه CNN-GA را با سایر روش‌های مطرحه در مراجع مقایسه کنیم. در شکل (۳۳) نمودار میله‌ای مقایسه دقت روش‌های طبقه‌بندی پیشنهادی در مراجع [۳۱-۳۷] با شبکه CNN-GA نشان داده شده‌است که بهترین دقت شبکه مربوط به شبکه CNN-GA با دقت ۹۹.۳۳٪ می‌باشد. این مقایسه نهایی، جایگاه چارچوب پیشنهادی CNN-GA را در گستره تحقیقات این حوزه به وضوح مشخص می‌کند. دستیابی به دقت ۹۹.۳۳٪ و برتری آن نسبت به سایر روش‌های معتبر، تنها یک پیشرفت عددی کوچک نیست، بلکه نشان‌دهنده بلوغ رویکرد ارائه‌شده‌است. این موفقیت، قدرت پارادایم «جستجوی خودکار معماری (Neural Architecture Search)» را در مقایسه با روش‌های سنتی که بر طراحی دستی معماری و تنظیم تجربی هایپرپارامترها متکی هستند، اثبات می‌کند. رویکرد ترکیبی این پژوهش با بهره‌گیری از هوش محاسباتی (الگوریتم ژنتیک) برای هدایت یادگیری عمیق (CNN)، توانسته است به نقطه بهینه‌تری در معماری شبکه دست یابد که از قابلیت تعمیم و استحکام بالاتری برخوردار است. این برتری، صلاحیت روش پیشنهادی برای حل مسائل پیچیده و واقعی در حوزه سنجش از دور و پردازش تصاویر SAR را تأیید می‌کند و آن را به عنوان یک مرجع قوی و یک پایه اساسی برای تحقیقات آتی در این زمینه مطرح می‌سازد.



شکل (۳۳) نمودار میله‌ای مقایسه دقت روش‌های طبقه‌بندی تصاویر در مراجع مختلف با شبکه CNN-GA

پیشنهادهای را تأیید می‌کند. عملکرد پایدار و برتر CNN-GA در هر دو سناریو ثابت می‌کند که بهینه‌سازی هایپرپارامترها یک نیاز اساسی است، نه یک گزینه اختیاری. نکته کلیدی این است که شکاف عملکردی بین دو مدل در داده‌های نویزی (۱.۵۹٪) بیشتر از داده‌های نویززدایی شده (۰.۸۸٪) است. این مشاهده حاکی از آن است که قدرت اصلی الگوریتم ژنتیک در شرایط سخت‌تر (وجود نویز) خود را بیشتر نشان می‌دهد، زیرا توانایی ذاتی آن برای یافتن معماری‌های مقاوم‌تر و قوی‌تر (Robust) در چنین شرایطی به حداکثر می‌رسد. در مقابل، زمانی که داده‌ها از قبل پاک‌سازی می‌شوند (داده‌های نویززدایی شده)، چالش یادگیری برای هر دو مدل ساده‌تر شده و در نتیجه شکاف عملکردی بین آن‌ها کمی کاهش می‌یابد، اگرچه مدل بهینه‌شده همچنان عملکرد مطلق بهتری دارد. این یافته‌ها به طور قاطع از فرضیه اصلی این پژوهش مبنی بر کارایی چارچوب ترکیبی CNN-GA برای طبقه‌بندی تصاویر SAR پشتیبانی می‌کند.



شکل (۳۱) نمودار میله‌ای مقایسه دقت شبکه‌های CNN و CNN-GA برای تصاویر MSTAR

۷-۴- مقایسه طبقه‌بندی تصاویر MSTAR برای داده‌های آموزشی مختلف

در این بخش نتایج حاصل از پیاده‌سازی طبقه‌بندی تصاویر با استفاده از شبکه‌های CNN و CNN-GA بر روی ۱۰ تا ۹۰ درصد تصاویر نویزی و نویززدایی شده داده‌های MSTAR به‌عنوان داده‌های آموزشی بررسی و مقایسه گردید که در شکل‌های (۳۲) نمودار میله‌ای مقایسه بین هر دو روش نشان داده شده‌است. بهترین دقت شبکه مربوط به طبقه‌بندی تصاویر نویززدایی شده MSTAR با روش پیشنهادی شبکه CNN-GA می‌باشد که دقت آن ۹۹.۳۳٪ می‌باشد. نتایج این بخش یک برتری کلیدی و عملی چارچوب CNN-GA را نشان می‌دهد: عملکرد برتر در تمامی سطوح مختلف داده آموزشی. بر خلاف مدل پایه CNN که با کاهش حجم داده آموزشی، افت دقت قابل توجهی را تجربه می‌کند، مدل بهینه‌شده توسط الگوریتم ژنتیک، انعطاف‌پذیری و کارایی بالاتری را از خود نشان می‌دهد. این امر ثابت می‌کند که معماری پیدا شده توسط الگوریتم ژنتیک نه تنها بهینه، بلکه کارآمدتر است؛ به این معنی که این معماری قادر است با استفاده از حجم کمتری از داده، ویژگی‌های بهتری را استخراج و یادگیری کند. این خاصیت برای کاربردهای واقعی که دسترسی به داده‌های آموزشی حجیم و برچسب‌دار همیشه میسر نیست، از اهمیت فوق‌العاده‌ای برخوردار است. در واقع، CNN-GA با ارائه یک معماری «خوب» از پایه، وابستگی مدل به حجم عظیم داده

در بخش پیش پردازش با بررسی نتایج حاصل از اعمال تعدادی از فیلترهای معروف کاهش نویز Speckle، مشاهده گردید که فیلتر Lee به نسبت سایر فیلترهای حوزه مکان نویززدایی بهتری از تصاویر MSTAR داشته و لبه های تصاویر را بهتر حفظ می نماید. لذا در مرحله پیش پردازش داده های MSTAR، از فیلتر Lee بدلیل بهبود کیفیت تصویر استفاده گردید. در خصوص پیاده سازی و بررسی نتایج شبیه سازی طبقه بندی تصاویر MSTAR با استفاده از شبکه CNN و نیز روش پیشنهادی شبکه CNN-GA صحبت گردید و نتایج آنها بررسی گردید. برای تصاویر نویزی MSTAR دقت نهایی ۹۷.۲۵٪ و برای تصاویر نویززدایی شده، دقت نهایی ۹۸.۴۵٪ برای شبکه CNN بدست آمد. برای تصاویر نویزی MSTAR دقت نهایی ۹۸.۸۴٪ و برای تصاویر نویززدایی شده، دقت نهایی ۹۹.۳۳٪ برای شبکه CNN-GA بدست آمد. مقایسه نتایج بدست آمده نشان دهنده آن است که شبکه پیشنهادی CNN-GA از عملکرد بهتری نسبت به شبکه CNN برخوردار می باشد و بهترین دقت شبکه مربوط به طبقه بندی تصاویر نویززدایی شده MSTAR با شبکه CNN-GA با دقت ۹۹.۳۳٪ می باشد. در ادامه پیرامون بررسی و مقایسه نتایج حاصل از پیاده سازی طبقه بندی تصاویر با استفاده از شبکه CNN و شبکه CNN-GA بر روی ۱۰ تا ۹۰ درصد داده های MSTAR به عنوان داده های آموزشی صحبت گردید و پس از بررسی نتایج حاصله مشخص گردید که بهترین دقت شبکه مربوط به طبقه بندی تصاویر نویززدایی شده MSTAR با شبکه CNN-GA بر روی داده های آموزشی ۷۰٪ با دقت ۹۹.۳۳٪ می باشد. در آخر نتایج حاصل از پیاده سازی شبکه CNN-GA با سایر روش های مطروحه در مراجع مقایسه گردید که بهترین دقت شبکه مربوط به شبکه CNN-GA با دقت ۹۹.۳۳٪ می باشد.

مراجع

- [9] K. Deb, "A review of evolutionary multi-objective optimization algorithms," *IEEE Trans. Evol. Comput.*, vol. ۲, no. ۳, pp. ۴۲۴-۴۱۱, ۲۰۲۱.
- [10] Z. Lu, I. Whalen, and Y. Dhebar, "Multi-objective neural architecture search for deep learning," *IEEE Trans. Evol. Comput.*, vol. ۲۶, no. ۴, pp. ۶۶۷-۶۵۲, ۲۰۲۲.
- [11] R. C. D. Pauca et al., "AI-based automatic target recognition for defense applications: Recent advances and challenges," *IEEE Aerosp. Electron. Syst. Mag.*, vol. ۳۷, no. ۵, pp. ۴۹-۳۶, ۲۰۲۲.
- [12] M. J. Islam et al., "Deep learning for disaster monitoring from satellite imagery: A systematic review," *Int. J. Disaster Risk Reduct.*, vol. ۷۶, p. ۱۰۲۹۸۵, ۲۰۲۲.
- [13] Y. Wang, L. Zhang, and P. Tang, "All-weather and all-time: Why SAR is indispensable for modern earth observation," *IEEE Geosci. Remote Sens. Mag.*, vol. ۹, no. ۳, pp. ۴۳-۲۲, ۲۰۲۱.
- [14] A. M. Alhassan et al., "Smart farming using SAR imagery and deep learning: A comprehensive survey," *Comput. Electron. Agric.*, vol. ۱۹۳, p. ۱۰۶۶۸۹, ۲۰۲۲.
- [15] X. Li et al., "A hybrid genetic algorithm and CNN approach for SAR target recognition," *IEEE Trans. Geosci. Remote Sens.*, vol. ۶۱, pp. ۱۵-۱, ۲۰۲۳.
- [16] Y. Zhao et al., "Particle swarm optimization for deep learning hyperparameter tuning in SAR image classification," *IEEE J. Sel. Topics Appl. Earth Observ. Remote Sens.*, vol. ۱۵, pp. ۲۳۵۸-۲۳۴۵, ۲۰۲۲.
- [17] H. Wang et al., "Deep learning-based speckle noise reduction in SAR images with structural preservation," *IEEE Geosci. Remote Sens. Lett.*, vol. ۲۰, pp. ۵-۱, ۲۰۲۳.
- [18] M. Chen and L. Zhang, "Comparative study of speckle reduction filters for SAR image classification," *Remote Sens.*, vol. ۱۴, no. ۵, p. ۱۲۵۶, ۲۰۲۲.
- [19] R. Yang et al., "Comprehensive evaluation of SAR target recognition methods on MSTAR dataset," *IEEE Trans. Aerosp. Electron. Syst.*, vol. ۵۹, no. ۲, pp. ۱۲۴۸-۱۲۳۴, ۲۰۲۳.
- [20] S. Liu et al., "Attention-based deep learning for SAR image classification with high accuracy," *ISPRS J. Photogramm. Remote Sens.*, vol. ۱۸۵, pp. ۷۸-۶۷, ۲۰۲۲.
- [21] I. G. Cumming and F. H. Wong, *Digital Processing of Synthetic Aperture Radar Data*. Norwood, MA, USA: Artech House, 2005.
- [22] B. Ravichandran, A. Gandhe, R. Smith, and R. Mehra, "Robust automatic target recognition using learning classifier systems," *Inf. Fusion*, vol. 8, no. 3, pp. 252-265, 2007.
- [23] L. Gagnon and A. Jouan, "Speckle filtering of SAR images - a comparative study between complex-wavelet-based and standard filters," in *Proc. SPIE*, Applications Signal Image Process. V*, vol. 3164, pp. 80-90, Oct. 1997.
- [24] L. G. Hafemann, R. Sabourin, and L. S. Oliveira, "Writer-independent feature learning for offline signature verification using deep convolutional neural networks," in *Proc. Int. Joint Conf. Neural Netw. (IJCNN)**, Vancouver, BC, Canada, 2016, pp. 2576-2583.
- [25] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "ImageNet classification with deep convolutional neural networks," in *Adv. Neural Inf. Process. Syst.*, 2012, pp. 1097-1105.
- [26] Y.-L. Boureau, J. Ponce, and Y. LeCun, "A theoretical analysis of feature pooling in visual recognition," in *Proc. 27th Int. Conf. Mach. Learn. (ICML)**, Haifa, Israel, 2010, pp. 111-118.
- [27] D. Scherer, A. Müller, and S. Behnke, "Evaluation of pooling operations in convolutional architectures for object recognition," in *Proc. Int. Conf. Artif. Neural Netw. (ICANN)**, Thessaloniki, Greece, 2010, pp. 92-101.
- [28] S. N. Sivanandam and S. N. Deepa, *Introduction to Genetic Algorithms**. Berlin, Germany: Springer, 2008.
- [29] A. P. Engelbrecht, *Computational Intelligence: An Introduction**, 2nd ed. Chichester, UK: John Wiley & Sons, 2007.
- [30] A. Ebrahimzadeh and A. Khazaei, "A high efficient system for automatic classification of the electrocardiogram beats," *Ann. Biomed. Eng.*, vol. 39, no. 3, pp. 996-1011, 2011.
- [31] S.-N. Yu and K.-T. Chou, "Selection of significant independent components for ECG beat classification," *Expert Syst. Appl.*, vol. 36, no. 2, pp. 2088-2096, 2009.
- [1] Masood, U., Azeem, M. K., Ahmad, I., & ul Jabbar, A. (2023). Robust adaptive nonlinear control of plugin hybrid electric vehicles for vehicle to grid and grid to vehicle power flow with hybrid energy storage system. *ISA transactions**, 139, 406-424.
- [2] Mobayen, S., Bayat, F., ud Din, S., & Vu, M. T. (2023). Barrier function-based adaptive nonsingular terminal sliding mode control technique for a class of disturbed nonlinear systems. *ISA transactions**, 134, 481-496.
- [3] M. Schmitt et al., "Toward a systematic workflow for efficient SAR-specific deep learning," *IEEE Trans. Geosci. Remote Sens.*, vol. ۶۰, pp. ۱۹-۱, ۲۰۲۲.
- [4] J. Ma, Y. Liu, and X. Xu, "Deep learning in SAR image processing: A review," *ISPRS J. Photogramm. Remote Sens.*, vol. ۱۸۰, pp. ۱۶-۱, ۲۰۲۱.
- [5] K. Chen, Z. Zhou, and H. Li, "Automatic target recognition in SAR images: A comprehensive survey," *IEEE Trans. Geosci. Remote Sens.*, vol. ۵۹, no. ۵, pp. ۳۷۹۵-۳۷۷۵, ۲۰۲۱.
- [6] L. Zhang et al., "Big data in remote sensing: A comprehensive review," *Int. J. Appl. Earth Observ. Geoinf.*, vol. ۱۰۲, p. ۱۰۲۴۱۱, ۲۰۲۱.
- [7] S. Wang, R. Wang, and D. Li, "CNN-based methods for SAR image interpretation: A systematic review," *IEEE Access*, vol. ۹, pp. ۱۰۰۵۸۳-۱۰۰۵۶۴, ۲۰۲۱.
- [8] P. Wang, J. Zhang, and W. J. Emery, "Automated CNN architecture design using meta-learning for SAR image classification," *IEEE Trans. Geosci. Remote Sens.*, vol. ۵۸, no. ۸, pp. ۵۷۳۵-۵۷۲۱, ۲۰۲۰.

- [32] U. R. Acharya, S. V. Sree, J. S. Suri, "Automatic identification of cardiac health using modeling techniques: A comparative study," **Inf. Sci.**, vol. 178, no. 24, pp. 4571–4582, 2008.
- [33] F. Gao, T. Wang, J. Wang, and X. Li, "A new algorithm of SAR image target recognition based on improved deep convolutional neural network," **Cogn. Comput.**, vol. 11, pp. 795–807, 2019.
- [34] K. Miller, J. Z. Kolter, and S. J. Wright, "Graph-based active learning for semi-supervised classification of SAR data," **arXiv**, preprint arXiv:2204.00000, 2022.
- [35] X. Fan and W. Zhu, "Research on SAR image target recognition based on convolutional neural network," in **J. Phys., Conf. Ser.**, vol. 1213, no. 4, 2019, Art. no. 042001.
- [36] F. Gao, Y. He, J. Wang, and J. Hussain, "A few-shot learning method for SAR images based on weighted distance and feature fusion," **Remote Sens.**, vol. 14, no. 18, p. 4583, 2022.
- [37] L. Zhao, J. Li, K. Liu, and H. Li, "Selecting pseudo supervision for unsupervised domain adaptive SAR target classification," **IEEE Trans. Geosci. Remote Sens.**, early access, 2022.
- [۳۸] ف. شریفزاده، "طبقه‌بندی اهداف مصنوعی در تصاویر SAR با استفاده از شبکه‌های عصبی کانولوشنی"، دانشگاه شهید چمران اهواز، شهریور ۱۳۹۷.
- [۳۹] س. رضایی‌فر، "تشخیص خودکار هدف در تصاویر رادار روزنه مصنوعی"، دانشگاه صنعتی شاهرود، ۱۳۹۲.