

علمی- پژوهشی

تشخیص اهداف راداری با استفاده از شبکه عصبی عمیق GMDH

سعید طلعتی^۱، میلاد اکبری ثانی^۱، محمدرضا حسینی آهنگر^{۳*}

۱- دانشگاه علوم و فنون هوایی شهید ستاری،

۲- دانشجوی دکتری مهندسی برق جنگ الکترونیک و ۳- دانشیار دانشگاه جامع امام حسین^(ع)، تهران، ایران

(دریافت: ۱۳۹۸/۱۰/۱۷، پذیرش: ۱۳۹۹/۰۶/۰۳)

چکیده

رادار وسیله الکترومغناطیسی است که برای تشخیص و تعیین موقعیت هدف‌ها به کار می‌رود. اساسی‌ترین وظیفه رادار استخراج اطلاعات در مورد هدف، به وسیله اندازه‌گیری مشخصات میدان الکترومغناطیسی امواج بازگشتی از هدف است. محیط راداری هر کشور جزو محدوده‌های امنیتی و راهبردی هر کشور می‌باشد. حفظ امنیت این محیط و شناسایی اهداف موجود در آن می‌تواند یکی از الزامات مهم محسوب گردد. در تشخیص اهداف راداری چالش‌ها و مشکلاتی همچون عدم دقت، صحت تشخیص و خطای بالا مطرح می‌باشد. روش‌های مختلفی تاکنون از جمله روش‌های مبتنی بر فرکانس‌های تشدید طبیعی هدف، پلاریزاسیون سیگنال بازگشتی، روش‌های یادگیری ماشین و غیره به‌منظور تشخیص اهداف راداری مطرح شده است. با وجود کاربردهای فراوانی که این روش‌ها داشته‌اند، اما هنوز نتوانسته‌اند چالش‌های موجود در رادار را برطرف نمایند. از این‌رو، در این مقاله با به کارگیری الگوریتم یادگیری عمیق GMDH اقدام به تشخیص اهداف راداری نموده‌ایم. با شبیه‌سازی روش پیشنهادی و مقایسه آن با سایر روش‌هایی همچون (RIN, SAE, SCAE, SDAE, CNN, LSVM, K-SVD)، به‌طور میانگین ۵ درصد بهبود حاصل شده است.

کلیدواژه‌ها: خوشه‌بندی، اهداف راداری، یادگیری عمیق GMDH^۱

عملکرد رادار در رزولوشن پایین، شناسایی نوع هدف را دچار مشکل می‌کند. رادارهای مجهز به الگوریتم‌های شناسایی و طبقه‌بندی نوع هدف، می‌توانند مانند چشم انسان که علاوه بر دیدن موقعیت اشیاء، نوع آن را هم تشخیص می‌دهد، به کاربر در تصمیم‌گیری صحیح کمک کنند.

در تشخیص اهداف راداری توسط روش‌های مختلف، چالش و مشکلاتی وجود دارد. از جمله مهم‌ترین چالش‌های موجود در تشخیص اهداف راداری، عدم دقت مطلوب تشخیص، خطای بالا، تخریب سیگنال، وجود نویز در دریافت تصاویر راداری و غیره می‌باشد. تاکنون روش‌های متعددی همچون روش‌های مدولاسیون هدف روی سیگنال ارسال (Bell et al, 1993; Martin et al, 1990; Cilliers et al, 2008)، استفاده از فرکانس‌های تشدید طبیعی هدف (Lim et al, 2011; Lee et al, 2005; Berni, 1975; Chuang et al, 1976; Aldhubaib et al, 2010)، پلاریزاسیون سیگنال بازگشتی (Copeland, 1960; Xuesong et al, 1997) و روش‌های یادگیری ماشین (Michie et al, 1994; Watt et al, 2020; Buskirk, 2020; Wang et al, 2019) جهت رفع چالش‌های موجود در زمینه تشخیص اهداف راداری ارائه شده است. از میان روش‌های مطرح شده، الگوریتم‌های یادگیری ماشین با قابلیت‌های کشف الگوهای پنهان از محبوبیت بیشتری برخوردار هستند.

۱- مقدمه

رادار یک دستگاه الکترومغناطیسی است که جهت تشخیص و تعیین موقعیت هدف استفاده می‌شود. رادار بر اساس ارسال شکل موج‌های ویژه به سمت هدف و تحلیل بازتاب آن عمل می‌کند (Reddy et al, 2020; Gallagher et al, 2019). رادار جهت پیشبرد قابلیت‌های حسی چندگانه انسانی برای مشاهده محیط اطراف، مخصوصاً حس بصری استفاده شده است (Elfrgani et al, 2019). دستگاه‌های راداری قادر به تهیه اطلاعات بیشتری درباره هدف می‌باشد. آشکارسازی و تشخیص هدف، نشانه پی‌بردن به وجود هدف در محدوده رادار است (Luong et al, 2019; Schneider et al, 2019). شناسایی و تشخیص اهداف راداری در محدوده هوایی هر کشور از اهمیت به‌سزایی برخوردار است. با شناسایی اهداف راداری می‌توان امنیت پرواز و امنیت هوایی یک کشور را حفظ نمود. رادارهای مراقبت زمینی عموماً اطلاعی از نوع هدف مشاهده شده را در اختیار کاربر قرار نمی‌دهند که این مورد نقیصه مهمی برای آن‌ها تلقی می‌شود.

*ایانامه نویسنده مسئول: mrhassani@ihu.ac.ir

¹ Group Method of Data Handling

گردید. مدل پیشنهادی از مشخصات متوسط به عنوان اصطلاحات تصحیح در شبکه‌ها استفاده کرده و ماتریس کواریانس هر فریم HRRP است. نتایج حاصل از آزمایش داده‌های HRRP اندازه‌گیری شده نشان می‌دهد که مدل پیشنهادی در مقایسه با مدل‌های دیگر بر اساس استخراج ویژگی، عملکرد بهتری نشان داده است (Feng et al, 2017).

کارین و همکارانش در سال ۲۰۱۷، شناسایی هدف در تصاویر راداری با استفاده از نمایه وزن دار مبتنی بر فرهنگ لغت آماری وزنی را بررسی نمودند. در این بررسی یک رویکرد عمومی جدید برای تشخیص هدف خودکار رادار در هر دو رادار دیافراگم مصنوعی معکوس (ISAR)^۳ یا تصاویر رادار دیافراگم مصنوعی (SAR)^۴ ارائه گردید. ابتدا یک فرهنگ لغت آماری با استفاده از مجموعه آموزش ساخته می‌شود. این با برآورد پارامترهای آماری میزان ضریب DT-CWT^۵ با استفاده از یک مدل غیر گاوسی انجام می‌شود. در این زمینه، توزیع گاما و وبل با هم مقایسه گردید. با توجه به یک نمونه آزمایشی برای طبقه‌بندی، وزن یک نمونه آموزشی را طبق KLD^۶ بین پارامترهای آماری نمونه آزمون و نمونه آموزشی محاسبه گردید که در نتیجه، یک فرهنگ لغت آماری وزنی ایجاد می‌شود. آزمایشاتی که بر روی پایگاه داده‌های تصاویر ISAR و SAR انجام شده است، نشان می‌دهد که رویکرد پیشنهادی منجر به بهبود در سطح تشخیص می‌شود (Karine et al, 2017).

کارین و همکارانش در سال ۲۰۱۸، در مقاله‌ای تشخیص هدف رادار با استفاده از توصیف گره‌ای کلید واژه برجسته مورد بررسی قرار دادند. در این مقاله یک رویکرد جدید برای شناخت اهداف راداری در رادار دیافراگم مصنوعی معکوس و تصاویر رادار دیافراگم مصنوعی پیشنهاد گردید. این رویکرد مبتنی بر توصیف کننده‌های کلید واژه برجسته و طبقه‌بندی مبتنی بر نمایش پراکنده چند وظیفه‌ای بود. برای توصیف اهداف در تصاویر راداری، از ویژگی تبدیل متغیر (SIFT)^۷ استفاده گردید. هدف از این ترکیب، کاهش تعداد کلیده‌های اصلی SIFT تنها با نگه داشتن آنهایی است که در منطقه مورد نظر (منطقه برجسته) قرار دارند. این طبقه‌بندی کننده مشکل نمایندگی پراکنده برای هر کار بر روی فرهنگ لغت را حل می‌کند و کلاس تصویر رادار را مطابق با همه خطاهای بازسازی پراکنده (باقیمانده) تعیین می‌کند. اثربخشی روش پیشنهادی توسط مجموعه‌ای از نتایج تجربی گسترده در پایگاه داده‌های تصاویر ISAR و SAR نشان داده شده است (Karine et al, 2018).

از جمله مهم‌ترین روش‌های مبتنی بر یادگیری ماشین، الگوریتم شبکه عصبی عمیق است (Mane et al, 2020). شبکه عصبی عمیق قابلیت یادگیری الگوهای پیچیده را نیز داشته و به دلیل قدرت و دقت بالای این الگوریتم، در بسیاری از مسائل دنیا واقعی به کار گرفته شده است. یادگیری عمیق نوعی شبکه عصبی مصنوعی است که با استفاده از تکنیک‌های ریاضی ساختاری مشابه با ساختار مغز انسان را ارائه می‌کند. از طرفی پیشرفت فن آوری باعث شده است تا الگوریتم‌هایی برای بهینه سازی شبکه‌های عصبی معمولی پیشنهاد شود که بتوان تعداد لایه‌های نورونی شبکه‌های عصبی را از چند لایه به هزاران لایه و هزاران نورون در هر لایه رساند که تا چند سال پیش امکان ایجاد چنین ساختاری وجود نداشت. معمولاً شبکه‌های عمیق طوری طراحی می‌شوند که در ساختار خود از نوع یادگیری بدون نظارت استفاده کنند؛ زیرا داده‌های امروزی که برای پردازش آن‌ها از هوش مصنوعی استفاده می‌کنند بسیار زیاد شامل میلیون‌ها داده است و تهیه این داده‌ها به صورت دستی عملاً غیرممکن است. از این رو شبکه‌های عمیق، خود داده‌های ورودی را پردازش کرده و شروع به تعلیم خود می‌کنند و هر چه داده‌های بیشتری در اختیار آن قرار بگیرد قدرتمند تر می‌شود و به راحتی بسیار هوشمندتر از انسان عمل می‌کند.

بنابراین، در این مقاله از شبکه عصبی عمیق به منظور طبقه‌بندی و تشخیص اهداف راداری استفاده می‌شود. داده‌ها و اطلاعات راداری به عنوان ورودی به شبکه عصبی عمیق GMDH ارائه می‌گردد. شبکه عصبی عمیق بر اساس داده‌های ورودی آموزش دیده و مدلی را مبتنی بر لایه‌های پنهان و ساختار عصبی تولید می‌کند. سپس نمونه‌ها و اهداف راداری را جهت تشخیص و ارزیابی دریافت نموده و با استفاده از مدل تولید شده اقدام به شناسایی اهداف راداری می‌نماید. ادامه این مقاله به این صورت تقسیم بندی شده است: در بخش دوم سوابق پیشین مورد بررسی قرار گرفته، در بخش سوم روش مطرح شده توصیف می‌گردد. در بخش چهارم و پنجم نتایج بدست آمده و نتیجه گیری نهایی مطرح شده است.

۲- سوابق پیشین

فنگو همکارانش در سال ۲۰۱۷، مقاله‌ای با عنوان شناسایی هدف HRRP^۱ رادار با شبکه‌های عمیق ارائه نمودند. در این مقاله، شبکه‌های عمیق به عنوان یک روش استخراج ویژگی جدید برای تشخیص خودکار هدف رادار مبتنی بر HRRP تحلیل و مورد استفاده قرار گرفت و یک معماری جدید به نام SCAE^۲ پیشنهاد

^۳ Inverse Synthetic Aperture Radar

^۴ Synthetic Aperture Radar

^۵ Dual-Tree Complex Wavelet Transform

^۶ Kullback-Leibler divergence

^۷ Scale-invariant Feature Transform

^۱ High-Resolution Range Profile

^۲ Stacked Correctionive Autoencoders

مجموعه داده‌های شناسایی و دستیابی به هدف در حال حرکت و ثابت و مقایسه آن با چندین روش برتر، اعتبار روش پیشنهادی را نشان می‌دهد (Liu & Yang, 2018).

گوا و همکارانش در سال ۲۰۱۹، یک روش شناسایی هدف رادار جدید بر اساس شبکه عمیق یک بعدی برای یک پروفایل با وضوح بالا (HRRP) را ارائه نمودند. یک الگو بر اساس کرنل تک قطبی یک بعدی و یک لایه استحکام پیشنهاد گردید. شایان ذکر است که عمل جابه‌جایی یک بعدی و هسته استحکام، توانایی غلبه بر حساسیت ترجمه و حساسیت جنبه هدف HRRP را دارد و هر دو آنها می‌توانند پارامترها را به شدت کاهش داده و عملکرد کلی سازی مدل را بهبود بخشند. علاوه بر این، یک تابع جدید برای تقویت بیشتر تفکیک ویژگی‌ها پیشنهاد شده است. نتایج تجربی نشان می‌دهد که در مقایسه با چهار مدل عمیق دیگر، مدل پیشنهادی می‌تواند در صحت تشخیص و استحکام عملکرد خوبی داشته باشد (Guo et al, 2019).

لونگ و همکارانش در سال ۲۰۱۹، در پژوهشی تشخیصی هدف، ردیابی، تصویربرداری فناوری پیشرفته رادار با وضوح بالا را مورد بررسی قرار دادند. رادارهای با وضوح بالا (HRR) به ترتیب از سیگنال‌های پهنای باند و دیافراگم‌های مصنوعی برای افزایش دامنه و وضوح زاویه‌ای ردیابی استفاده می‌کنند. آن‌ها همچنین تصاویر با وضوح بالا یک، دو و حتی سه بعدی حاوی اطلاعات ویژگی اهداف را تولید می‌کنند. از این طریق می‌توان اهداف را به طور دقیق طبقه بندی و شناسایی کرد. الگوریتم‌های پیشرفته پردازش سیگنال در HRR اطلاعات مهمی مانند تصویربرداری دامنه-دایره‌ای، عمق از فاز و ویژگی‌های حرکات میکرو بدست می‌آورند. با این حال، مزایا و کاربردهای HRR با عواملی مانند کاهش نسبت سیگنال به نویز (SNR) از اهداف نقطه چند پراکنده، کاهش دقت ردیابی اهداف نقطه چند پراکنده، تقاضای زیاد جبران حرکت و پایین بودن محدود می‌شود. نتایج در این پژوهش تحقیقات مبتنی بر HRR و پیشرفت آینده آن را نشان می‌دهد (Long et al, 2019).

کیوآی و همکارانش در سال ۲۰۱۹، یک روش مبتنی بر دیافراگم مصنوعی PCANet^۶ جهت تشخیص تصاویر رادار را ارائه نمودند. شناخت خودکار اهداف (ATR)^۸ برای تصویر رادار دیافراگم مصنوعی بسیار مهم است. شبکه تجزیه و تحلیل مؤلفه‌های اصلی (PCANet) یک شبکه کم عمق است که در انجام کار تشخیص عملکرد خوبی دارد و نیازی به انتخاب ویژگی‌های دستی ندارد. اگرچه این شبکه کاربردهای گسترده‌ای در تصاویر طبیعی ایجاد کرده است، اما به ندرت در تصاویر SAR

یان در سال ۲۰۱۸، تشخیص هدف رادار را با استفاده از شبکه‌های عصبی مورد بررسی قرار داد. در این مقاله شناسایی رادار دیافراگم مصنوعی مبتنی بر شبکه‌های عصبی حلقوی (CNN)^۱ با استفاده از نمونه‌های تمرینی تقویت شده پیشنهاد گردید. برای تقویت استحکام CNN از تصاویر اصلی آموزش برای تولید نمونه‌های پرسروصدا در نسبت‌های مختلف سیگنال (SNR)^۲، بازنمایی‌های چندرسانه‌ای و تصاویر جزئی قطع شده استفاده گردید. سپس از تصاویر تولید شده به همراه تصاویر اصلی برای آموزش یک CNN طراحی شده برای تشخیص هدف استفاده می‌شود. نمونه‌های آموزش پیشرفته می‌توانند به طور محرمانه استحکام CNN آموزش دیده را به EOC^۳های تحت پوشش، یعنی نویز، واریانس وضوح و انسداد جزئی بهبود بخشند. نتایج نشان داد که روش پیشنهادی عملکرد بهتری را نشان می‌دهد (Yan et al, 2018).

پالسون و همکارانش در سال ۲۰۱۸، در مقاله‌ای یک الگوریتم تشخیص خودکار هدف رادار دیافراگم مصنوعی را ارائه دادند. در این مقاله یک الگوریتم خط پایه اتوماتیک تشخیص رادار (SAR) دیافراگم مصنوعی (SAR) با استفاده از یک الگوریتم تطبیق مقیاس خاکستری کمی (QGM)^۴ پیشنهاد گردید. QGM یک طبقه‌بندی کننده است که از یک روش تطبیق الگو برای شناسایی هدف استفاده می‌کند. این پیاده سازی QGM به همراه قابلیت تولید داده مصنوعی به محققان این امکان را می‌دهد تا حساسیت QGM را در شرایط عملیاتی مختلف آزمایش کنند و علاوه بر این، الگوریتم پایه‌ای برای مقایسه فراهم می‌کند (Paulson et al, 2018).

لیو و همکارانش در سال ۲۰۱۸، شناسایی هدف در تصاویر رادار دیافراگم مصنوعی با استفاده از فیوژن تصمیم چندتایی مشترک را مورد پژوهش و بررسی قرار دادند. فیوژن تصمیم چند منظوره، یک روش مؤثر برای ارتقاء عملکرد تشخیص هدف تصاویر رادار دیافراگم مصنوعی (SAR) است. در این مقاله یک استراتژی تلفیق تصمیم چند منظوره مشترک برای شناسایی هدف در تصاویر SAR بر اساس سنجش فشاری چند وظیفه (MtCS)^۵ ارائه شده است. روش پیشنهادی می‌تواند با اعمال محدودیت در الگوی کمبود، از روابط متقابل بین ویژگی‌های مختلف سوءاستفاده کند. علاوه بر این، مصرف زمان برای MtCS تقریباً مشابه با طبقه بندی فشاری مبتنی بر ویژگی‌های واحد، مانند طبقه بندی نمایشی پراکنده است. آزمایش‌های مربوط به

^۱ Convolutional Neural Networks

^۲ Signal to Noise Ratio

^۳ Extended Operating Conditions

^۴ Quantized Grayscale Matching

^۵ Multitask Compressive Sensing

^۶ High Resolution Radars

^۷ Principal Component Analysis Network

^۸ Automatic Targets Recognition

نمونه‌برداری تصادفی یکی از ساده‌ترین روش‌های نمونه‌برداری است که به‌صورت تصادفی عمل کرده و به میزان مورد نظر، نمونه‌هایی را از داده‌های اصلی به‌عنوان داده‌های آموزشی و آزمایشی تفکیک می‌نماید. یکی از معایب این روش این است که در آن ممکن است از یک دسته خاص، هیچ داده‌ای نمونه‌برداری نشود و در نهایت منجر به کاهش دقت طبقه‌بندی داده‌ها و اعتبارسنجی روش مطرح شده گردد. روش نمونه‌برداری طبقه‌بندی شده نیز یکی از روش‌های بهبود یافته روش تصادفی می‌باشد. این روش فرآیند نمونه‌برداری را مبتنی بر احتمال انجام داده و همچنان نمونه‌ها را به‌صورت درصدی انتخاب می‌کند. این روش از نمونه‌برداری نیز دارای مشکلاتی می‌باشد. مثلاً ممکن است نمونه‌هایی را مبتنی بر احتمال انتخاب نکند. روش نمونه‌برداری متعادل، از جمله روش‌هایی است که نمونه‌های مورد نیاز را به‌صورت متعادل از بین دسته‌ها و طبقه‌های موجود انتخاب می‌کند. این روش، مشکل روش‌های قبل را نداشته و در نهایت داده‌ها و نمونه‌های متعادلی را از بین نمونه‌های موجود، انتخاب می‌کند. روش نمونه‌برداری استفاده شده در این مقاله به‌منظور تفکیک داده‌های آموزشی و داده‌های آزمایشی، روش متعادل^۲ است. از این رو ۷۰٪ از نمونه‌ها به‌عنوان نمونه‌های آموزشی و ۳۰٪ به‌عنوان نمونه‌های آزمایشی تفکیک می‌گردد.

۳-۲ اعمال الگوریتم شبکه عصبی عمیق GMDH

شبکه عصبی یادگیری عمیق، یکی از دسته‌بندی‌های مهم در زمینه پیش‌بینی و تشخیص اهداف راداری می‌باشد. ساختار این طبقه‌بندی در ادامه بررسی می‌گردد. در شبکه عصبی مورد استفاده در روش پیشنهادی، از ۴ نوع لایه استفاده خواهند شد که در ادامه مورد بررسی قرار خواهند گرفت.

۳-۲-۱- لایه ورودی

پارامترهایی که در بخش قبل از جنبه معنایی مورد بررسی قرار گرفت، به‌صورت نرمال شده^۳ به عنوان ورودی شبکه عصبی عمیق اعمال می‌گردد. عصب‌های این لایه بیانگر بردار داده‌های ورودی حاصل از مرحله استخراج ویژگی می‌باشند.

۳-۲-۲- لایه‌های نهان

در حالت معمول، آموزش شبکه عصبی به روش نظارت‌شده^۴، وزن‌های اولیه از طریق یک توزیع گاوسی^۵ یا توزیع نرمال، وارد شبکه می‌شوند. با اجرای روش انتشار خطا به عقب، این وزن‌ها به‌روزرسانی شده و مجدداً در شبکه مورد استفاده قرار می‌گیرند. این نوع آموزش بسیار کند بوده و بروز مشکل جواب کمینه محلی^۶ به جای کمینه عمومی^۱، همواره از چالش‌های این روش

مورد استفاده قرار می‌گیرد. نتیجه آزمایشی مجموعه داده‌های دستیابی و شناسایی هدف های متحرک و ثابت (MSTAR)^۱ نشان می‌دهد که PCANet می‌تواند بیش از ۹۹٪ دقت را در اهداف ده طبقه بدست آورد. این نتیجه بهتر از الگوریتم‌های سنتی است و به نتایج حاصل از روش‌های یادگیری عمیق بسیار نزدیک است (Qi et al, 2019).

با بررسی سوابق پیشین و پژوهش‌هایی که در زمینه تشخیص اهداف راداری انجام شده است، مشاهده گردید که علی‌رغم کاربردهای فراوانی که هر روش در زمینه تشخیص اهداف راداری داشته است؛ اما هنوز نتوانسته‌اند چالش‌های موجود در اهداف راداری همچون عدم دقت مطلوب تشخیص اهداف راداری، خطای بالا، تخریب سیگنال، وجود نویز در دریافت تصاویر راداری را مرتفع نمایند. در این مقاله از شبکه عصبی عمیق به منظور طبقه‌بندی و تشخیص اهداف راداری استفاده می‌شود. داده‌ها و اطلاعات راداری به عنوان ورودی به شبکه عصبی عمیق ارائه می‌گردد. شبکه عصبی عمیق بر اساس داده‌های ورودی، آموزش دیده و مدلی را مبتنی بر لایه‌های پنهان و ساختار عصبی تولید می‌کند. سپس نمونه‌ها و اهداف راداری را جهت تشخیص و ارزیابی دریافت نموده و با استفاده از مدل تولید شده اقدام به شناسایی اهداف راداری می‌نماید.

۳- روش پیشنهادی

در این بخش به ارائه الگوریتم شبکه عصبی عمیق GMDH به‌منظور تشخیص اهداف راداری پرداخته می‌شود. دو مورد از فازهای مهم روش پیشنهادی پس از اعمال مجموعه داده اهداف راداری به سامانه پیشنهادی به شرح ذیل می‌باشد: بخش اول نمونه‌ها برای آموزش نمونه الگوریتم‌های موجود در سیستم یادگیری عمیق به کار گرفته می‌شود و بخش دوم آن‌ها نیز به‌عنوان نمونه‌های آزمایشی برای آزمون روش پیشنهادی جهت شناسایی اهداف راداری، مورد استفاده قرار می‌گیرند.

۳-۱- تفکیک نمونه‌های آموزشی و آزمایشی

یکی از فازهای مهمی که برای آموزش الگوریتم شبکه عصبی عمیق GMDH می‌بایست اعمال شود، تفکیک نمونه‌ها به دو بخش اصلی است. نمونه‌برداری از داده‌های مورد نظر، یکی از مراحل داده‌کاوی است که در این راه‌کار پیشنهادی مورد توجه قرار گرفته است. روش‌های مختلف نمونه‌برداری وجود دارد که سه مورد از مهم‌ترین آن‌ها عبارت‌اند از:

- نمونه‌برداری تصادفی

- نمونه‌برداری طبقه‌بندی شده

- نمونه‌برداری متعادل

^۲ Balancing

^۳ Normalized

^۴ Supervised Learning

^۵ Gaussian Distribution

^۶ Local Minimum

^۱ Moving and Stationary Target Acquisition and Recognition

با این حال، در دسته‌بندی، یک تابع اتصال^۸ یکنواخت به فرم رابطه (۴)، انتظار را به ترکیب خطی تشخیص دهنده‌ها، منتقل می‌کند. مدل‌هایی به این شکل، مدل‌های خطی تعمیمی نامیده می‌شوند. در حالت رگرسیون منطقی، تابع اتصال به صورت لگاریتمی و طبق رابطه (۳) انتخاب می‌شود.


$$g(a) = \ln \frac{a}{1-a} \quad (3)$$

معکوس تابع لگاریتمی تابعی منطقی است که به صورت رابطه (۴) انتخاب می‌شود.

$$h_{\theta}(x) = \frac{1}{1 + \exp(-\theta^T \cdot x)} \quad (4)$$

در این روش، شاخص‌های مدل یعنی θ ، توسط تابع هزینه به صورت رابطه (۵) بهینه‌سازی می‌شوند.

$$(\theta) = - \left\{ \sum_{i=1}^m \left[y^{(i)} \cdot \ln(h_{\theta}(x^{(i)})) + (1 - y^{(i)}) \cdot \ln(1 - h_{\theta}(x^{(i)})) \right] \right\} \quad (5)$$



شکل (۱): معماری پایه شبکه عصبی عمیق

رگرسیون نرم‌افزاری، تعمیم‌یافته رگرسیون منطقی است و هنگامی به کار می‌رود که بیش از یک کلاس داده وجود داشته باشد. با توجه به توضیحات داده شده در این قسمت، می‌توان معماری شبکه عصبی مورد استفاده در این مطالعه را مطابق شکل (۲)، نشان داد. در این شکل، تعداد عصب‌های لایه‌ی ورودی ۴ عصب فرض شده است که با توجه به ویژگی‌های به دست آمده در مرحله استخراج ویژگی‌ها ممکن است این تعداد متفاوت با این رقم باشد. تعداد ۳ لایه با ۳ عصب در هر لایه برای لایه‌های نهان در نظر گرفته شده است که این تعداد نیز بسته به جواب دهی و سرعت شبکه و نیز دقت مورد نیاز، ممکن است در مرحله اجرا دستخوش تغییر شود.

۳-۳- روش شبکه عصبی عمیق GMDH

عملکرد الگوریتم پیشنهادی در این مقاله، مبتنی بر یادگیری عمیق است. بدین صورت که مجموعه داده‌های آموزشی به هسته الگوریتم شبکه عصبی عمیق GMDH وارد شده و مدل این الگوریتم، تولید می‌شود. سپس داده‌های تست به مدل این الگوریتم، وارد می‌گردد و برای هر نمونه تست یک پاسخ را صادر می‌کند. هر پاسخ بیانگر این است که یک نمونه، آیا اهداف راداری

بوده است. هیلتون^۲ در سال ۲۰۰۶، نشان داد که استفاده از پیش آموزش هرلایه با استفاده از یک روش غیرنظارتی^۳، می‌تواند این مشکل را حل نماید. از این رو، در این مقاله از معماری شبکه عصبی عمیق با استفاده از روش مطرح شده توسط هیلتون، استفاده شده است. معماری شبکه عصبی عمیق و همچنین توضیحات مربوط به آن که در این مقاله مورد استفاده قرار گرفته، در ادامه و در شکل (۱) قابل مشاهده است.

۳-۲-۳- لایه خروجی

در این قسمت، از دو نوع لایه خروجی استفاده می‌شود. در ادامه به منظور بازسازی شبکه، از یک لایه خروجی که با نام لایه خروجی ۱ مطرح می‌شود، استفاده می‌گردد. این لایه از جنس ورودی بوده و تنها به منظور آموزش شبکه عصبی مورد استفاده قرار می‌گیرد. این لایه، اطلاعات ورودی خود را از آخرین لایه‌ی لایه‌های نهان گرفته و خطای آموزش را به عقب انتشار می‌دهد. لایه خروجی دیگری در این مقاله مورد استفاده قرار خواهد گرفت که در ادامه با نام لایه خروجی ۲ مطرح خواهد شد. لایه نرم‌افزاری^۴ می‌باشد. این لایه به منظور استفاده از رگرسیون به شیوه نرم‌افزاری تعبیه شده است. این شیوه رگرسیون داده‌ها، تعمیم‌یافته رگرسیون به شیوه منطقی^۵ می‌باشد.

این روش هنگامی مورد استفاده قرار می‌گیرد که با چند کلاس داده سر و کار داشته باشیم. خروجی این روش، احتمال تعلق به هر کلاس از داده‌ها را مشخص می‌کند.

۳-۲-۴- تابع رگرسیون نرم‌افزاری

در رگرسیون منطقی، تابع رگرسیون دارای یک رابطه غیرخطی با ترکیب خطی متغیرهای توصیفی است. این رابطه با تابع پروبیت^۶ مدل‌سازی می‌شود. در تعاریف دسته‌بندی، پاسخ یک متغیر دودویی است، یعنی:

$$y_i \in \{-1, +1\} \quad (1)$$

پاسخ داده برای منظم‌سازی یک متغیر تصادفی برنولی Y با احتمال موفقیت η است. احتمال موفقیت وابسته به یک تشخیص دهنده^۷، یعنی $\eta = \eta(x)$ در نظر گرفته می‌شود. اگر تشخیص دهنده برای منظم‌سازی یک متغیر تصادفی، X در نظر گرفته شود، سپس $\eta(x)$ انتظار شرطی Y است. که در این صورت در رابطه (۲) داریم:

$$E\{Y|X\} = \eta(x) \quad (2)$$

¹ Global Minimum

² Hilton

³ Unsupervised Learning

⁴ Softmax Layer

⁵ Logistic Regression

⁶ Probit

⁷ Predictor

⁸ Link Function

defined تعریف می‌شود، به گونه‌ای که می‌تواند به جای عملکرد واقعی f ، برای پیش‌بینی خروجی \hat{y} برای یک بردار ورودی داده شده $X = (x_1, x_2, x_3, \dots, x_n)$ تا جایی که ممکن است به خروجی واقعی y نزدیک شود. بنابراین، با توجه به نمونه‌های M ، از جفت داده‌های تک خروجی چند ورودی روابط زیر را تعریف می‌کنند.

$$y_i = f(x_{i1}, x_{i2}, x_{i3}, \dots, x_{in}), \quad i = 1, 2, \dots, M. \quad (6)$$

یک شبکه‌عصبی از نوع GMDH ممکن است اکنون برای پیش‌بینی مقادیر خروجی آموزش داده شود.

$$X = (x_{i1}, x_{i2}, x_{i3}, \dots, x_{in}) \quad (7)$$

به این معنی است که :

$$\hat{y}_i = \hat{f}(x_{i1}, x_{i2}, x_{i3}, \dots, x_{in}), \quad i = 1, 2, \dots, M \quad (8)$$

اکنون به منظور به حداقل رساندن مربع تفاوت بین خروجی پیش‌بینی شده و واقعی، مشکل تعیین یک شبکه عصبی از نوع شبکه عصبی عمیق وجود دارد:

$$\sum_{k=1}^M [(f(x_{i1}, x_{i2}, x_{i3}, \dots, x_{in}) - y_i)^2] \rightarrow \text{Min}. \quad (9)$$

چند جمله‌ای به شکل پیچیده که در هسته شبکه عصبی عمیق استفاده شده است می‌تواند برای نمایش ارتباط کلی بین متغیرهای ورودی و خروجی استفاده شود. در رابطه (۱۰) چند جمله‌ای پیچیده فرم نشان داده شده است:

$$\hat{y} = a_0 + \sum_{i=1}^m a_i x_i + \sum_{i=1}^m \sum_{j=1}^m a_{ij} x_i x_j + \sum_{i=1}^m \sum_{j=1}^m \sum_{k=1}^m a_{ijk} x_i x_j x_k + \dots \quad (10)$$


که به چند جمله‌ای ایواخنکو معروف است (Feng et al, 2017). با این حال، بیشتر برنامه‌ها برای پیش‌بینی میزان خروجی y از فرم متغیر دو متغیر به شکل زیر استفاده می‌کنند:

$$\hat{y} = G(x_i, x_j) = a_0 + a_1 x_i + a_3 x_i^2 + a_4 x_j^2 + a_5 x_i x_j \quad (11)$$

با استفاده از تکنیک‌های رگرسیون، ضرایب a_i در رابطه (۱۱) محاسبه می‌شود تا اختلاف بین بازده واقعی \hat{y} محاسبه شود. برای هر جفت (x_i, x_j) به‌عنوان ورودی به حداقل برسد. در حقیقت متغیرها، نشان می‌دهد که با استفاده از فرم درجه دوم در رابطه (۱۴)، که ضرایب آن در حداقل مربعات به‌دست می‌آید، درخت چندجمله‌ای ساخته می‌شود. بنابراین، ضرایب هر تابع درجه دوم G_i به‌دست آمده است تا مقدار بهینه را در کل جفت ورودی - خروجی مجموعه قرار دهد:

تشخیص داده شده است یا خیر. بنابراین پاسخ یا بله است یا خیر. هسته داخلی این الگوریتم در قالب ذیل ارائه شده است.

روش گروهی تغییر داده‌ها (GMDH) خانواده‌ای از الگوریتم‌های القایی برای مدل‌سازی ریاضی مبتنی بر رایانه از مجموعه داده‌های چند پارامتری است که دارای بهینه‌سازی ساختاری و پارامتری کاملاً خودکار مدل‌های استفاده شده GMDH در زمینه‌هایی مانند داده کاوی، کشف دانش، پیش‌بینی، مدل‌سازی سیستم‌های پیچیده، بهینه‌سازی و شناخت الگو می‌باشد. نتایج تحقیقات لی و همکارانش در سال ۲۰۱۷، نشان داد که شبکه عصبی GMDH عملکرد بهتری نسبت به الگوریتم‌های پیش‌بینی کلاسیک مانند هموارسازی تک‌نمایی^۱، هموارسازی مضاعف نمایی^۲ و شبکه عصبی باز انتشار دارد. الگوریتم‌های GMDH با روش استقرایی انجام می‌شوند که مرتب سازی مدل‌های چند جمله‌ای به تدریج پیچیده را انجام می‌دهد و بهترین راه حل را با استفاده از معیار به اصطلاح خارجی انتخاب می‌کند (Farlow, 1981). در شکل (۲) ساختار شبکه GMDH در مدل پیشنهادی مورد استفاده ارائه شده است.



شکل (۲): ساختار شبکه GMDH استفاده شده در روش پیشنهادی.

همانطور که از شکل (۲) مشاهده می‌شود، $X = (x_1, x_2, \dots, x_n)$ به عنوان یک بردار ورودی به شبکه عصبی مصنوعی وارد می‌شود. بر اساس ورودی‌های X ، مجموعه‌ای از عصب‌ها در لایه‌های مخفی تشکیل شده و مدل شبکه عصبی را تولید می‌کنند. شبکه عصبی مصنوعی دارای یک بردار ورودی، تعدادی لایه مخفی و یک بردار خروجی است.

مجموعه‌ای از نوروها می‌توانند الگوریتم مشترک GMDH را نشان دهند. آنها در هر لایه دارای جفت‌های مختلفی از سلول‌های عصبی هستند و با استفاده از چند جمله‌ای درجه دوم به آن‌ها ملحق می‌شوند. نتیجه این ارتباط نوروها جدید در لایه بعدی است. از این طریق می‌توان برای مدل‌سازی ورودی‌های نقشه‌برداری به خروجی‌ها استفاده کرد. مشکل شناسایی به‌طور رسمی به‌عنوان روشی برای یافتن یک تابع

¹ Single Exponential Smooth

² Double Exponential Smooth

استفاده شده مشابه به مقاله (Guo et al, 2019) بوده و در شرایط یکسان پیاده‌سازی شده است. در فرآیند ارزیابی از معیارهای ارزیابی زیر به منظور ارزشیابی عملکرد مدل پیشنهادی استفاده شده است.

۴-۱- معیارهای ارزیابی در روش پیشنهادی

با توجه به قابلیت‌های ابزارهایی همچون متلب و جاوا، در این مقاله از این دو ابزار به منظور تجزیه و تحلیل داده‌ها و شبیه‌سازی، استفاده شده است. همچنین معیارهایی که در این مقاله جهت ارزیابی روش پیشنهادی با سایر روش‌ها استفاده شده عبارتند از:

$$Precision = \frac{TP}{TP + FP} \quad (16)$$

از رابطه (۱۶) جهت بررسی میزان صحت روش پیشنهادی استفاده می‌شود. پارامتر TP^۱ بیانگر تعداد نمونه‌هایی است که به درستی طبقه‌بندی شده‌اند. پارامتر FP^۲ نیز بیانگر تعداد نمونه‌هایی است که به درستی طبقه‌بندی نشده‌اند.

$$Recall = \frac{TP}{TP + FN} \quad (17)$$

رابطه (۱۷) بیانگر میزان فراخوانی روش پیشنهادی است که پارامتر FN بیانگر تعداد نمونه‌هایی است که به عنوان تصاویر راداری بوده اما غیره راداری طبقه‌بندی شده است.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (18)$$

از رابطه (۱۸) برای محاسبه دقت روش پیشنهادی استفاده می‌گردد و تنها پارامتری که در آن تشریح نشده، TN است که بیانگر تعداد نمونه‌هایی است که راداری نبوده ولی به عنوان تصاویر راداری طبقه‌بندی شده است. در نهایت نیز میزان خطای روش پیشنهادی براساس رابطه (۲۰) محاسبه می‌گردد.

$$Error = 100 - \frac{(TP + TN)}{(TP + TN + FP + FN)} \quad (19)$$

۴-۲- مقایسه نتایج روش پیشنهادی

در این بخش به تشریح نتایج روش پیشنهادی جهت تشخیص اهداف راداری و مقایسه با نتایج مقاله (Guo et al, 2019) در شرایط یکسان پرداخته می‌شود.

در شکل (۳) نتایج دقت، خطا، صحت، فراخوانی، MAE، RMSE، انحراف معیار و Mape بدون اعمال روش‌های معنایی نشان داده شده است.

$$r^2 = \frac{\sum_{i=1}^M (y_i - G_i)}{\sum_{i=1}^M y_i^2} \rightarrow M \text{ in} \quad (12)$$

($y_i, i = 1, 2, \dots, M$) ساختار چند جمله‌ای رگرسیون در رابطه (۱۲) به خوبی می‌تواند نمونه‌های وابسته $p, q \in \{1, 2, \dots, M\}$ برای اختلاف $\binom{n}{2} = n(n-1)/2$ به معنای حداقل مربعات جای دهد $\{(y_i, x_{ip}, x_{iq}), (i = 1, 2, \dots, M)\}$ این بدان معناست که امکان ساخت سه‌گانه داده M وجود دارد. $p, q \in \{1, 2, \dots, M\}$ از نمونه‌های این چنینی استفاده کند.

$$\begin{bmatrix} x_{1p} & x_{1q} & \vdots & y_1 \\ x_{2p} & x_{2q} & \vdots & y_2 \\ \dots & \dots & \dots & \dots \\ x_{Mp} & x_{Mq} & \vdots & y_M \end{bmatrix}$$

در صورت استفاده از زیر واحد درجه دوم در قالب رابطه (۱۳)، برای هر ردیف از داده‌های M، رابطه ماتریسی زیر به دست می‌آید:

$$Aa = Y \quad (13)$$

که در آن برداری از ضرایب مجهول چند جمله‌ای درجه دوم در معادله (۱۱) است:

$$a = \{a_0, a_1, a_2, a_3, a_4, a_5\} \quad (14)$$

$$Y = \{y_1, y_2, y_3, \dots, y_M\}^T$$

بردار مقادیر خروجی از نمونه‌ها است. این امر نشان می‌دهد:

$$A = \begin{bmatrix} 1 & x_{1p} & x_{1q} & x_{1p}x_{1q} & x_{1p}^2 & x_{1q}^2 \\ 1 & x_{2p} & x_{2q} & x_{2p}x_{2q} & x_{2p}^2 & x_{2q}^2 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ 1 & x_{Mp} & x_{Mq} & x_{Mp}x_{Mq} & x_{Mp}^2 & x_{Mq}^2 \end{bmatrix}$$

روش حداقل مربعات از تحلیل رگرسیون چندگانه منجر به حل معادلات نرمال به شکل زیر می‌شود:

$$a = (A^T A)^{-1} A^T Y \quad (15)$$


این که بردار بهترین ضرایب معادله درجه دوم مطابق با رابطه (۱۱) را برای کل مجموعه سه گانه داده M تعیین می‌کند. با این حال، این راه‌حل به طور مستقیم که از معادلات نرمال حاصل می‌شود، تقریباً قادر به دور زدن خطاها است. بنابراین با این هسته، فرآیند تولید مدل و تشخیص اهداف راداری صورت می‌گیرد.

۴- تحلیل نتایج

برای ارزیابی راه کار پیشنهادی از مجموعه داده اهداف راداری و از ابزار متلب و نسخه a ۲۰۱۵ به منظور ارزیابی نتایج و شبیه‌سازی روش پیشنهادی استفاده گردیده است. اولین مرحله از شناخت مسئله پیشنهادی و مراحل انجام کار، ورود مجموعه داده اهداف راداری می‌باشد. این مجموعه داده دارای حدود ۱۷/۲۳۲ هزار نمونه و ۸۶۹ ویژگی می‌باشد. لازم به ذکر است که مجموعه داده

^۱ True Positive


^۲ False Positive



شکل (۳): نتایج دقت، خطا، صحت، فراخوانی و خطای روش پیشنهادی جهت تشخیص اهداف راداری.

به مقایسه روش پیشنهادی با سایر روش‌های مطرح شده در مقاله (Guo et al, 2019) پرداخته می‌شود. در مقاله (Guo et al, 2019) از انواع روش‌های یادگیری عمیق به منظور تشخیص اهداف راداری همچون CNN, SVM و غیره استفاده شده است.

همان‌طور که از شکل (۳) مشاهده می‌گردد، میزان دقت تشخیص اهداف راداری با استفاده از مدل پیشنهادی برابر ۹۹/۸۲۲٪ است. میزان صحت مدل پیشنهادی برابر با ۷۹/۴۳٪، نرخ فراخوانی مدل پیشنهادی برابر با ۲۰/۸٪، میزان خطای مدل پیشنهادی برابر با ۰/۱۷۷٪ می‌باشد. با این تفاسیر در بخش بعد



شکل (۴): مقایسه دقت روش پیشنهادی جهت تشخیص اهداف راداری با سایر روش‌های مطرح شده در (Guo et al, 2019)

مطابق با آمار ارائه شده در شکل (۴) نتایج به شرح ذیل می‌باشد:

جدول (۱): مقایسه دقت روش پیشنهادی جهت تشخیص اهداف راداری با سایر روش‌های مطرح شده در (Guo et al, 2019)

	درصد بهبود روش پیشنهادی					
	SNR=۱۵ dB	SNR=۱۰ dB	SNR=۵ dB			
K-SVD	۸۸/۷۲	۸۶/۱۹	۸۱/۵۸	٪۹۱/۱۴	٪۱۱/۸۳	٪۱۱/۱
LSVM	۸۴/۸۲	۷۸/۴۵	۷۲/۱۱	٪۲۴/۴۱	٪۱۹/۵۷	٪۱۵
CNN	۹۶/۲۲	۹۴/۳۶	۹۳/۰۱	٪۳/۵۱	٪۳/۶۶	٪۳/۶
SDAE	۹۶/۰۵	۷۹/۳۹	۹۱/۵۸	٪۴/۹۴	٪۰/۶۳	٪۳/۷۷
SCAE	۹۶/۱۲	۹۴/۴۷	۹۱/۳۷	٪۵/۲۵	٪۳/۵۵	٪۳/۷
SAE	۹۵/۳۶	۹۳/۷۲	۹۰/۹۴	٪۵/۵۸	٪۴/۳	٪۴/۴۶
RIN	۹۸/۳۲	۹۶/۹۸	۹۴/۶۵	٪۱/۸۷	٪۱/۰۴	٪۱/۵
روش پیشنهادی	۹۹/۸۲	۹۸/۰۲	۹۶/۵۲			

به‌عنوان پیشنهاداتی برای آینده می‌توان به این اشاره نمود که به منظور بهبود نتایج و یافته‌های پیشنهادی بهتر از الگوریتم‌هایی همچون الگوریتم فازی بهبود یافته Growcut جهت تقسیم‌بندی ناحیه هدف راداری استفاده نموده و از نتایج آن برای الگوریتم شبکه عصبی عمیق GMDH استفاده نمود.

۶- مراجع

- [1] Reddy, A. V., & Borkar, V. G. (2020). Design and Simulation of Microstrip Branch Line Coupler and Monopulse Comparator for Airborne Radar Applications. In *Advances in Decision Sciences, Image Processing, Security and Computer Vision* (pp. 10-18). Springer, Cham.
- [2] Gallagher, K., Hedden, A., & Ranney, K. (2019, May). Issues associated with radar applications on software defined radios. In *Radar Sensor Technology XXIII* (Vol. 11003, p. 110031D). International Society for Optics and Photonics.
- [3] Elfrgani, A., & Reddy, C. J. (2019, March). Near-Field RCS for Automotive Radar Applications. In 2019 International Workshop on Antenna Technology (iWAT) (pp. 217-220). IEEE.
- [4] Luong, D., & Balaji, B. (2019, May). Radar applications of quantum squeezing. In *Signal Processing, Sensor/Information Fusion, and Target Recognition XXVIII* (Vol. 11018, p. 110181C). International Society for Optics and Photonics.
- [5] Schneider, D. A., Rösch, M., Tessmann, A., & Zwick, T. (2019). A Low-Loss W-Band Frequency-Scanning Antenna for Wideband Multichannel Radar Applications. *IEEE Antennas and Wireless Propagation Letters*, 18(4), 806-810.
- [6] Bell, M. R., & Grubbs, R. A. (1993). JEM modeling and measurement for radar target identification. *IEEE Transactions on Aerospace and Electronic Systems*, 29(1), 73-87.
- [7] Martin, J., & Mulgrew, B. (1990, May). Analysis of the theoretical radar return signal form aircraft propeller blades. In *IEEE International Conference on Radar* (pp. 569-572). IEEE.
- [8] Cilliers, A., & Nel, W. A. J. (2008, September). Helicopter parameter extraction using joint time-frequency and tomographic techniques. In *2008 International Conference on Radar* (pp. 598-603). IEEE.

همانطور که از جدول (۱) مشاهده می‌گردد، میزان دقت روش پیشنهادی در حالتی که نسبت سیگنال به نویز داده‌ها ۵dB است برابر با ۹۶٫۵۲٪ می‌باشد که به ترتیب نسبت به روش‌های شبکه عصبی عمیق همچون K-SVD، LSVM، CNN، SDAE، SCAE، SAE، RIN به میزان ۱۴/۹۴، ۲۴/۴۱، ۳/۵۱، ۴/۹۴، ۵/۲۵، ۵/۵۸، ۱/۸۷ درصد بهبود داشته است. همچنین میزان دقت روش پیشنهادی در حالتی که نسبت سیگنال به نویز داده‌ها ۱۰dB است برابر با ۹۸/۰۲٪ می‌باشد که به ترتیب نسبت به روش‌های شبکه عصبی عمیق همچون K-SVD، LSVM، CNN، SDAE، SCAE، SAE، RIN به میزان ۱۱/۸۳، ۱۹/۵۷، ۳/۶۶، ۰/۶۳، ۳/۵۵، ۴/۳، ۱/۰۴ درصد بهبود داشته است. در نهایت میزان دقت روش پیشنهادی در حالتی که نسبت سیگنال به نویز داده‌ها ۱۵ dB است برابر با ۹۹٫۸۲٪ می‌باشد که به ترتیب نسبت به روش‌های شبکه عصبی عمیق همچون K-SVD، LSVM، CNN، SDAE، SCAE، SAE، RIN به میزان ۱/۱۱، ۱/۵، ۳/۶، ۳/۷۷، ۳/۷، ۴/۴۶، ۱/۵ درصد بهبود داشته است.

۵- نتیجه‌گیری

با شبیه‌سازی روش پیشنهادی مشاهده گردید که میزان دقت، صحت، فراخوانی و خطای روش پیشنهادی مبتنی بر الگوریتم شبکه عصبی عمیق GMDH به‌منظور تشخیص اهداف راداری نسبت به جدیدترین روش‌های مطرح شده تا کنون بهبود قابل ملاحظه‌ای داشته است و توانسته به خوبی چالش‌هایی همچون عدم دقت مطلوب تشخیص، خطای بالا، تخریب سیگنال، وجود نویز در دریافت تصاویر راداری را مرتفع نمایند. بنابراین، می‌توان به این نتیجه نهایی رسید که بهتر است در پردازشگر سیستم‌ها و گیرنده‌های شنود راداری از روش‌های یادگیری ماشین و به خصوص الگوریتم شبکه عصبی عمیق GMDH استفاده نموده و چالش‌ها و مشکلات موجود را مرتفع نمود.

- [21] Feng, B., Chen, B., & Liu, H. (2017). Radar HRRP target recognition with deep networks. *Pattern Recognition*, 61, 379-393.
- [22] Karine, A., Toumi, A., Khenchaf, A., & El Hassouni, M. (2017). Target recognition in radar images using weighted statistical dictionary-based sparse representation. *IEEE Geoscience and Remote Sensing Letters*, 14(12), 2403-2407.
- [23] Karine, A., Toumi, A., Khenchaf, A., & El Hassouni, M. (2018). Radar Target Recognition Using Salient Keypoint Descriptors and Multitask Sparse Representation. *Remote Sensing*, 10(6), 843
- [24] Yan, Y. (2018). Convolutional neural networks based on augmented training samples for synthetic aperture radar target recognition. *Journal of Electronic Imaging*, 27(2), 023024.
- [25] Paulson, C., Wilson, J., & Lewis, T. (2018, April). Synthetic aperture radar quantized grayscale reference automatic target recognition algorithm. In *Algorithms for Synthetic Aperture Radar Imagery XXV* (Vol. 10647, p. 106470P). International Society for Optics and Photonics.
- [26] Liu, S., & Yang, J. (2018). Target recognition in synthetic aperture radar images via joint multifeature decision fusion. *Journal of Applied Remote Sensing*, 12(1), 016012.
- [27] Guo, C., He, Y., Wang, H., Jian, T., & Sun, S. (2019). Radar HRRP target recognition based on deep one-dimensional residual-inception network. *IEEE Access*, 7, 9191-9204.
- [28] Long, T., Liang, Z., & Liu, Q. (2019). Advanced technology of high-resolution radar: target detection, tracking, imaging, and recognition. *Science China Information Sciences*, 62(4), 40301.
- [29] Qi, B., Jing, H., Chen, H., Zhuang, Y., Yue, Z., & Wang, C. (2019). Target recognition in synthetic aperture radar image based on PCANet. *The Journal of Engineering*, 2019(21), 7309-7312.
- [30] Farlow, S. J. (1981). The GMDH algorithm of Ivakhnenko. *The American Statistician*, 35(4), 210-215.
- [31] Guo, C., He, Y., Wang, H., Jian, T., & Sun, S. (2019). Radar HRRP target recognition based on deep one-dimensional residual-inception network. *IEEE Access*, 7, 9191-9204.
- [9] Lim, H., & Myung, N. H. (2011). High resolution range profile-jet engine modulation analysis of aircraft models. *Journal of Electromagnetic Waves and Applications*, 25(8-9), 1092-1102.
- [10] Lee, J. H., & Kim, H. T. (2005). Radar target discrimination using transient response reconstruction. *Journal of Electromagnetic Waves and Applications*, 19(5), 655-669.
- [11] Berni, A. J. (1975). Target identification by natural resonance estimation. *IEEE Transactions on Aerospace and Electronic systems*, (2), 147-154.
- [12] Chuang, C. W., & Moffatt, D. L. (1976). Natural resonances of radar targets via Prony's method and target discrimination. *IEEE Transactions on Aerospace and Electronic Systems*, (5), 583-589.
- [13] Aldhubaib, F., & Shuley, N. V. (2010). Radar target recognition based on modified characteristic polarization states. *IEEE Transactions on Aerospace and Electronic Systems*, 46(4), 1921-1933.
- [14] Copeland, J. R. (1960). Radar target classification by polarization properties. *Proceedings of the IRE*, 48(7), 1290-1296.
- [15] Xuesong, W., Shunping, X., Huamin, T., & Zhaowen, Z. (1997). Polarization radar target recognition based on curve fitting under the least square criterion using improved simulated annealing algorithm.
- [16] Michie, D., Spiegelhalter, D. J., & Taylor, C. C. (1994). *Machine learning. Neural and Statistical Classification*, 13.
- [17] Watt, J., Borhani, R., & Katsaggelos, A. (2020). *Machine learning refined: foundations, algorithms, and applications*. Cambridge University Press.
- [18] Buskirk, T. D. (2020). *MACHINE LEARNING FOR SURVEY DATA*. Presented at RTI International.
- [19] Wang, P., Li, Y., & Reddy, C. K. (2019). Machine learning for survival analysis: A survey. *ACM Computing Surveys (CSUR)*, 51(6), 110.
- [20] Mane, D. T., & Kulkarni, U. V. (2020). A survey on supervised convolutional neural network and its major applications. In *Deep Learning and Neural Networks: Concepts, Methodologies, Tools, and Applications* (pp. 1058-1071). IGI Global.

Identifying Radar Targets using the GMDH Deep Neural Network

S. Talati, M. Akbari Sani, M. R. Hassani Ahangar^{*}

^{*} Imam Hossein University, Tehran, Iran

(Received: 07/01/2020, Accepted: 24/08/2020)

Abstract

Radar is an electromagnetic device used to detect and determine the position of targets. The most basic task of radar is to extract information about the target by measuring the electromagnetic field characteristics of the return waves from the target. The radar environment of each country is one of the security and strategic areas of each country. Maintaining the security of this environment and identifying its goals can be one of the important requirements. Challenges and problems such as inaccuracy and inaccuracy of detection and high error are raised in the detection of radar targets. Various methods have been proposed so far, such as techniques based on target natural intensification frequencies, reversible signal polarization, machine learning methods, etc., to detect radar targets. Despite the many uses of these methods, they have not yet been able to meet the challenges of radar. Therefore, in this paper, we have identified radar targets using the GMDH Deep Learning Algorithm. By simulating the proposed method and comparing it with other methods such as RIN, SAE, SCAE, SDAE, CNN, LSVM, K-SVD, the average has improved by 5%.

Keywords: Clustering, Radar Targets, Deep Learning GMDH

^{*} Corresponding author E-mail: mrhassani@ihu.ac.ir