



Investigation and Improvement of the Performance of Radar Target Detection Schemes Based on Artificial Neural Networks and Deep Learning Techniques

Pedram Pakravan

Ph.D. Student in Power Electronics, Power Research Group, Faculty of Electrical Engineering, Amirkabir University of Technology, Tehran, Iran (Corresponding Author).

Email: pedram.pakravan.317@gmail.com

Payam Pakravan

Graduate in Digital Electronics Engineering, Electronics Research Group, Faculty of Electrical Engineering, University of Tehran, Tehran, Iran

Abstract

Upgrading and improving radar systems within the defense system chain is of great importance because radar target detection is vital to the proper and effective functioning of defense processes and other related activities. Failure to detect radar targets is associated with increased defense costs, reduced defense capabilities, and greater exposure to enemy threats. Therefore, the main objective of the present study was to propose solutions for improving target detection in neural-network-based radar systems. Radar target detection (RTD) is a fundamental process in radar systems that is designed to distinguish and measure targets against a complex background. Artificial intelligence and deep learning methods have attracted considerable attention and have become practical solutions in radar signal processing. Compared with conventional radar target detection methods, artificial-intelligence-based methods can automatically extract features and produce more accurate results. The use of artificial intelligence in radar target detection is considered a relatively new concept. In this study, the applications of neural networks in radar target detection were reviewed, and their potential limitations were discussed. Because maintaining the security of defense systems and detecting existing targets are among the essential requirements of every country, challenges such as insufficient detection accuracy, inadequate detection reliability, and high error rates must be addressed. Accordingly, a filter was first designed and implemented to improve the quality of the input signals. Subsequently, the VHDL code for the proposed neural network was developed in the ISE environment and implemented on a Spartan-6 FPGA to address radar target detection problems.

Keywords: Radar Target Recognition, Radar Signal Processing, Deep Learning Models, Artificial Neural Network, Deep Neural Network





سال نهم، شماره دوم (پیاپی ۳۰)، تابستان ۱۴۰۵، صص. ۲۳۴-۲۰۱
تاریخ دریافت: ۱۴۰۴/۰۴/۱۷ - تاریخ پذیرش: ۱۴۰۴/۰۷/۱۸

مقاله پژوهشی

بررسی و بهبود عملکرد طرح‌های تشخیص هدف رادار بر اساس شبکه‌های عصبی مصنوعی و تکنیک‌های یادگیری عمیق

پدram پاکروان

دانشجوی دکتری مهندسی الکترونیک قدرت، گروه پژوهشی قدرت، دانشکده برق، دانشگاه صنعتی امیرکبیر، تهران، ایران (نویسنده مسئول)
Email: pedram.pakravan.317@gmail.com

پیام پاکروان

دانش‌آموخته مهندسی الکترونیک دیجیتال، گروه پژوهشی الکترونیک، دانشکده برق، دانشگاه تهران، تهران، ایران

چکیده

ارتقا و بهبود سامانه راداری در زنجیره سامانه دفاعی از اهمیت بسیاری برخوردار است؛ زیرا تشخیص هدف رادار برای عملکرد صحیح و مؤثر فرایندهای پدافند و سایر فعالیت‌های مرتبط با آن حیاتی است. عدم تشخیص هدف رادار با افزایش هزینه‌های دفاعی، کاهش توان دفاعی و افزایش تهدیدات دشمنان همراه است؛ بنابراین هدف اصلی پژوهش حاضر، ارائه راهکارهایی جهت بهبود تشخیص هدف در رادار مبتنی بر شبکه عصبی است. شناسایی هدف راداری (شناسایی هدف راداری) یک فرایند اساسی، اما مهم در سامانه راداری است که برای تمایز و اندازه‌گیری اهداف از یک پس‌زمینه پیچیده طراحی شده است. روش‌های هوش مصنوعی و یادگیری عمیق در حال حاضر توجه زیادی را به خود جلب کرده‌اند و به‌عنوان راه‌حل‌های عملی در پردازش سیگنال رادار تبدیل شده‌اند. در مقایسه با روش‌های مرسوم شناسایی هدف راداری، روش‌های مبتنی بر هوش مصنوعی می‌توانند ویژگی‌ها را به‌طور خودکار استخراج کرده و نتایج دقیق‌تری به دست آورند. استفاده از هوش مصنوعی در شناسایی هدف راداری به‌عنوان یک مفهوم جدید در نظر گرفته می‌شود. در این تحقیق، کاربردهای شبکه عصبی در حوزه شناسایی هدف راداری بررسی شده و محدودیت‌های احتمالی نیز بیان گردیده است. این کار به دلیل افزایش تعداد آثار تحقیقاتی منتشر شده در سال‌های اخیر انجام شده است. حفظ امنیت سامانه دفاعی و شناسایی اهداف موجود یکی از الزامات اصلی هر کشوری محسوب می‌گردد. از آنجاکه در تشخیص اهداف راداری چالش‌ها و مشکلاتی همچون عدم دقت، صحت تشخیص و خطای بالا مطرح است. از این‌رو در این پژوهش در ابتدا یک فیلتر برای بهبود سیگنال‌های ورودی طراحی و پیاده‌سازی شده است و در نهایت کد VHDL شبکه عصبی پیشنهادی برای رفع مشکلات تشخیص اهداف در نرم ISE نوشته و بر روی تراشه اسپارتن ۶ پیاده‌سازی شده است.

کلیدواژه‌ها: شناسایی هدف راداری، پردازش سیگنال راداری، مدل‌های یادگیری عمیق، شبکه عصبی مصنوعی، شبکه عصبی عمیق

دانشگاه عالی دفاع ملی ♦ پژوهشکده آماد، فناوری دفاعی و عرصه‌های نوپدید / فصلنامه آماد و فناوری دفاعی



20.1001.1.28212606.1405.9.2.7.1

<https://amfad.sndu.ac.ir/> E-ISSN: 2980-8073



صحت مطالب بر عهده نویسنده مقاله است و بیانگر دیدگاه دانشگاه عالی دفاع ملی نیست.



مقدمه و بیان مسئله

پژواک‌های راداری که از اهداف بازمی‌گردند معمولاً صدای غوطه‌ور، گنگ یا سیگنال پارازیت هستند. شناسایی هدف راداری یک فرایند اساسی، اما مهم به‌منظور تمایز و اندازه‌گیری اهداف از پس‌زمینه پیچیده است. تشخیص صحیح هدف رادار به‌طور گسترده‌ای برای تعیین این‌که آیا سیگنال است یا نویز استفاده می‌شود. از آنجایی‌که سیگنال‌های راداری منعکس‌شده از اهداف اغلب در پس‌زمینه‌های پیچیده غوطه‌ور می‌شوند (به‌عنوان مثال، نویز، به‌هم‌ریختگی، حتی پارازیت)، روش‌های سنتی پردازش سیگنال اغلب برای افزایش «نسبت سیگنال به نویز (SNR)»^۱ استفاده می‌شوند (ریچارد، ۲۰۰۵)، درحالی‌که «نرخ هشدار نادرست ثابت (CFAR)»^۲ یک روش مفید برای تشخیص در محیط نویز براساس آزمون فرضیه (کی، ۲۰۱۳) است. همچنین یکی از مراحل اساسی در طراحی سامانه پردازشی رادار، استفاده از تمامی اطلاعات در دسترس در جهتی است که سیگنال ارسالی از فرستنده به‌گونه‌ای انتخاب گردد که منجر به بهترین نتایج در تخمین پارامترهای اهداف شود. از این‌رو، بهینه‌سازی شکل موج ارسالی در رادار مورد توجه زیادی قرار گرفته است. روش‌های تشخیص سنتی مبتنی بر «CFAR»^۳، مدل‌های هدف یا محیط را به‌عنوان یک فرایند تصادفی در نظر می‌گیرند که معمولاً براساس تئوری آماری است. با این حال، با توجه به محیط تشخیص پیچیده و انواع هدف‌های متنوع، یافتن اهداف در یک صحنه پیچیده یک کار بسیار چالش‌برانگیز است و بنابراین یک روش شناسایی هدف راداری قابل اعتماد و قوی یکی از پیگیری‌های کلیدی تحقیقات بوده است. در سال‌های اخیر از مدل‌های «یادگیری عمیق» در حوزه‌های بسیاری نظیر «ترجمه ماشین»، صنایع هوا و فضا تشخیص بیماری با استفاده از اشعه ایکس، تشخیص تصاویر برای ماشین‌های خودران، پیش‌بینی بازار سهام و سایر حوزه‌های دیگر استفاده شده است (پاکروان، ۲۰۱۸). معماری مدل‌های یادگیری عمیق از ساختاری با عنوان «شبکه عصبی» تشکیل شده است که با نام «شبکه عصبی مصنوعی» نیز شناخته می‌شوند (لانگ، ۲۰۱۹). موفقیت یادگیری


1. Signal-to-Noise Ratio

2. Constant False Alarm Rate

3. Constant False Alarm Rate



عمیق عمدتاً به دلیل در دسترس بودن داده‌های بزرگ، بهبود قدرت محاسباتی و توانایی پردازش داده‌ها است (لکون، ۲۰۱۵). فناوری‌های مختلف شبکه عصبی عمیق با موفقیت مورد استفاده قرار گرفته‌اند، از جمله شبکه‌های عصبی عمیق، شبکه‌های عصبی کانولوشنال، شبکه‌های عصبی بازگشتی، شبکه‌های باور عمیق و غیره (پاکروان، ۲۰۲۰). اگرچه فناوری یادگیری عمیق (گودفلو، ۲۰۱۶) طی چند سال گذشته روند توسعه‌ای زیادی را نشان داده است، پتانسیل کامل آن برای کاربرد رادار هنوز کشف نشده است. در مرجع (بنگیو، ۲۰۱۳)، محققان مشکلات کاربرد رادار را که می‌توان با روش‌های مبتنی بر یادگیری عمیق حل کرد، به ترتیب در سه دسته کلی دسته‌بندی کردند: سنجش رادار، پردازش سیگنال راداری و شناسایی خودکار هدف راداری که در شکل (۱)، فهرست شده‌اند. سنجش راداری و پردازش سیگنال راداری پیش‌نیازها و رویه‌های لازم برای شناسایی خودکار هدف راداری رادار است.



شکل ۱: وظایف راداری

شناسایی و تشخیص هدف راداری یک فرایند اساسی و مهم در سامانه راداری است که برای تمایز و اندازه‌گیری اهداف از یک پس‌زمینه پیچیده طراحی شده است.

سیستم‌های راداری مدرن، به‌عنوان حسگرهای قدرتمند، نقش حیاتی در کاربردهای دفاعی (مانند شناسایی پهپادها، هواپیماها و شناورها)، نظارتی و حفاظتی ایفا می‌کنند. خروجی اصلی این سیستم‌ها، غالباً یک نگاهت دوبعدی به‌نام تصویر رادار روزنه مصنوعی (SAR) یا داده‌های حوزه برداری-داپلر (Range-Doppler) است.

اگرچه روش‌های مبتنی بر یادگیری عمیق مانند شبکه‌های کانولوشنی CNNs و Transformer ها موفقیت‌های اولیه در پردازش تصاویر اپتیکال و در نتیجه، در تشخیص اهداف در تصاویر SAR داشته‌اند، اما چندین چالش بنیادی و حل نشده، عملکرد عملی این مدل‌ها را به شدت محدود می‌کند.

الف. وابستگی شدید به زاویه دید (Aspect Angle Dependency) شکل و نمای هدف در تصویر رادار به طور قابل توجهی به زاویه بین رادار و هدف بستگی دارد. یک مدل آموزش دیده بر روی داده‌های با زوایای خاص، در تشخیص همان اهداف از زوایای ناشناخته، دچار افت شدید دقت می‌شود. این مسئله، تعمیم‌پذیری (Generalization) مدل را تضعیف می‌کند.

ب. تعداد کم داده‌های برچسب‌خورده با کیفیت جمع‌آوری و برچسب‌زنی داده‌های راداری واقعی، پرهزینه، زمان‌بر و اغلب به دلایل امنیتی با محدودیت مواجه است. این کمبود داده، منجر به بیش‌برازش (Overfitting) مدل‌های پیچیده یادگیری عمیق می‌شود؛ به طوری که مدل بر روی داده‌های آموزشی به خوبی عمل می‌کند؛ اما بر روی داده‌های تست جدید عملکرد ضعیفی دارد. (معمولاً داده‌های مربوط به آموزش سامانه، جامع نیست).

ج. شرایط محیطی و اغتشاش داده‌های راداری، دارای نویز، بازتاب‌های زمین (Clutter) و اهداف کاذب (غیرواقعی) هستند. مدل‌های فعلی اغلب در تمایز قائل شدن بین یک هدف واقعی و یک توده اغتشاش قوی (مثلاً یک ساختمان یا یک موج بلند در دریا) در سناریوهای پیچیده، دچار اشتباه می‌شوند.

د. تشخیص اهداف با ابعاد بسیار کوچک؛ اهداف کوچک مانند پهپادهای کوچک، تنها چند پیکسل از تصویر رادار را اشغال می‌کنند. شبکه‌های عصبی رایج که برای تشخیص اشیا با ابعاد متوسط طراحی شده‌اند، در استخراج ویژگی‌های معنادار از این اهداف ریز بسیار ناکارآمد هستند و آن‌ها را نادیده می‌گیرند.

این چالش‌ها منجر به کاهش نرخ تشخیص (Recall) و افزایش هشدارهای کاذب در محیط‌های واقعی می‌شوند که در کاربردهای حساس، غیرقابل قبول است. بنابراین، یک خلأ



آشکار در توسعه چهارچوب‌های هوشمند تشخیص هدف وجود دارد که بتوانند به‌طور هم‌زمان، مستقل از زاویه دید، با داده آموزشی محدود، مقاوم در برابر اغتشاش و دقیق برای اهداف کوچک عمل کنند. روش‌های یادگیری عمیق در حال حاضر توجه زیادی را به خود جلب کرده‌اند و به راه‌حل‌های عملی در پردازش سیگنال راداری تبدیل شده‌اند. در مقایسه با روش‌های مرسوم RTD، روش‌های مبتنی بر یادگیری عمیق می‌توانند ویژگی‌ها را به‌طور خودکار استخراج کرده و نتایج دقیق‌تری به دست آورند. استفاده از یادگیری عمیق در RTD به‌عنوان یک مفهوم جدید در نظر گرفته می‌شود و وانگ و همکاران CNN ها را برای تشخیص شکل موج راداری اعمال کرد. طبق (سیستو، ۲۰۱۸)، روش‌های یادگیری عمیق می‌توانند مشکل پیچیدگی محاسباتی بالای بهینه‌سازی پارامتر آنتن را حل کنند. طراحی آنتن‌های آرایه‌ای توسط شبکه‌های عصبی مصنوعی (میسون، ۲۰۱۷) پرداخته شده است. انتخاب آنتن رادار شناختی نیز با روش‌های یادگیری عمیق حل شده است (وانگ، ۲۰۱۷). گائو و همکاران یک استخراج کننده ویژگی مبتنی بر CNN و یک رمزگذار خودکار پشته‌ای (SAE) را برای تشخیص سیگنال‌های مدوله شده رادار، از جمله LFM، NLFM، BPSK، FRANK، COSTAS، P1، P2، P3 و P4 و ... بررسی کرد. تشخیص هدف خودکار ساده‌ترین راه است و کاربرد گسترده یادگیری عمیق در رادار، به‌ویژه برای مصنوعی رادار دیافراگم (SAR) (سینگال، ۲۰۱۷). داده‌های راداری «شبه تصویر» مختلف به‌منظور استخراج ویژگی و طبقه‌بندی شناسایی خودکار هدف راداری به‌خوبی مورد مطالعه قرار گرفته‌اند. مدل‌های یادگیری عمیق بر روی «پروفایل‌های راداری با وضوح بالا (HRRP)»^۱ برای «شناسایی خودکار هدف راداری»^۲ ساخته شده‌اند (دینگ، ۲۰۱۶). شناسایی خودکار هدف راداری در مشخصه‌های میکرو داپلر راداری نیز می‌تواند در نظر گرفته شود. یادگیری عمیق همچنین می‌تواند برای تشخیص فعالیت‌های انسانی با استفاده از اثر مشخصه‌های داپلر، از جمله تشخیص حرکات دست سنجش علائم حیاتی، تشخیص فعالیت‌های معمول و غیره استفاده شود. استفاده از پروفیل‌های رادار Range-Doppler برای A شناسایی خودکار هدف راداری ارسال-دریافت با


1. High Resolution Range Profile
2. Automatic target recognition

مدل «حافظه کوتاه مدت (CLSTM)»^۱ را بررسی کرد (گنگ، ۲۰۱۵). یک روش مبتنی بر یادگیری عمیق در رادارهای Range-Doppler برای تشخیص حرکت انسان پیشنهاد شده است (لئو، ۲۰۱۶). پردازش سیگنال رادار یک روش میانی بین سنجش رادار و شناسایی خودکار هدف راداری است. یکی از مهم ترین اهداف پردازش سیگنال راداری، شناسایی اهداف است. الگوریتم های طبقه بندی کننده مبتنی بر یادگیری ماشین، مانند «ماشین های بردار پشتیبان (SVM)»^۲ و «k-نزدیک ترین همسایه (kNN)»^۳، برای شناسایی هدف راداری همان طور که قبلاً ذکر شد، شناسایی هدف راداری یک آزمایش فرضیه دودویی است که می تواند به عنوان یک مسئله طبقه بندی باینری در نظر گرفته شود، یعنی این که آیا هدف وجود دارد یا وجود ندارد. براساس این فرض، شناسایی هدف راداری را می توان به عنوان یک برنامه شناسایی خودکار هدف راداری در نظر گرفت. از آنجایی که مدل های یادگیری عمیق در شناسایی خودکار هدف راداری به عملکرد خوبی دست یافته اند، بررسی مدل های مبتنی بر یادگیری عمیق در شناسایی هدف راداری امکان پذیر و معقول است. به عنوان یکی از قابل اطمینان ترین طبقه بندی کننده ها، شبکه عصبی مصنوعی برای بهبود عملکرد تشخیص رادار استفاده شده است. بسیاری از مقالات اخیر از شبکه عصبی عمیق برای مقابله با شناسایی هدف راداری و همچنین ارائه بهبود عملکرد استفاده می کنند. سیستم های راداری را می توان براساس کاربرد طراحی شده نیز به انواع مختلفی تقسیم نمود. شکل شماره (۲)، تقسیم بندی رادار را نشان می دهد و در نهایت این پژوهش در پاسخ به چالش های مدرن سیستم های راداری پهنای باند کوچک، اهداف با سطح مقطع راداری کم، اهداف متحرک با الگوهای پیچیده و محیط های عملیاتی چالش برانگیز (کوهستانی، شهری) با نگاه عملیات نمودن روش شناسایی خودکار هدف

-
1. Convolutional Long Short-Term
 2. Support vector machine
 3. k-nearest neighbors



راداری ضمن بررسی کامل و مقایسه‌ای روش یادگیری عمیق به پیاده‌سازی سخت‌افزاری روش پیشنهادی برای رفع موارد ذکر شده اقدام نموده است.



شکل ۲: تقسیم‌بندی انواع رادار

با توجه به (راوات، ۲۰۱۲)، روش‌های یادگیری عمیق می‌توانند مشکل پیچیدگی محاسباتی بالای بهینه‌سازی پارامتر آنتن را حل کنند. طراحی آنتن‌های آرایه‌ای توسط شبکه‌های عصبی مصنوعی مورد بررسی قرار گرفته است (البیر، ۲۰۱۹). انتخاب آنتن رادار شناختی نیز حل شده است. با روش‌های یادگیری عمیق یک استخراج‌کننده ویژگی مبتنی بر CNN و یک رمزگذار خودکار پشته‌ای (SAE) برای تشخیص سیگنال‌های مدوله‌شده رادار، از جمله LFM، NLFM، BPSK، FRANK، COSTAS، P1، P2، P3، P4 و ... کاوش کرد. شناسایی هدف خودکار ساده‌ترین و پرکاربردترین کاربرد یادگیری عمیق در رادار، به‌ویژه برای رادار دیافراگم مصنوعی است (اختر، ۲۰۱۹). داده‌های راداری «شبیه تصویر» مختلف به‌منظور استخراج ویژگی و طبقه‌بندی شناسایی خودکار هدف راداری به‌خوبی مورد مطالعه قرار گرفته‌اند. مدل‌های یادگیری عمیق بر روی پروفایل‌های برد راداری با وضوح بالا (HRRP) برای شناسایی خودکار هدف راداری ساخته شدند. شناسایی خودکار هدف راداری

در مشخصه‌های میکرو داپلر راداری نیز می‌تواند در نظر گرفته شود. یادگیری عمیق همچنین می‌تواند برای تشخیص فعالیت‌های انسانی با استفاده از مشخصه‌های میکرو داپلر، از جمله تشخیص حرکات دست، حس علائم حیاتی، تشخیص فعالیت‌های معمول و ... استفاده شود. استفاده از پروفیل‌های رادار Range-Doppler برای شناسایی خودکار هدف راداری با مدل کانولوشنال شبکه‌های حافظه کوتاه‌مدت را بررسی شده است. یک روش مبتنی بر یادگیری عمیق در رادارهای Range-Doppler برای تشخیص حرکت انسان نیز ارائه شده است. پردازش سیگنال رادار یک روش میانی بین سنجش رادار و شناسایی خودکار هدف راداری است. یکی از مهم‌ترین اهداف پردازش سیگنال راداری، شناسایی اهداف است. الگوریتم‌های طبقه‌بندی‌کننده مبتنی بر یادگیری ماشین، مانند ماشین‌های بردار پشتیبان برای شناسایی هدف راداری استفاده شده است. همان‌طور که قبلاً ذکر شد، شناسایی هدف راداری یک آزمایش فرضیه باینری است که می‌تواند به‌عنوان یک مشکل طبقه‌بندی باینری در نظر گرفته شود، یعنی این‌که آیا هدف وجود دارد یا وجود ندارد. براساس این فرض، شناسایی هدف راداری را می‌توان به‌عنوان یک برنامه شناسایی خودکار هدف راداری در نظر گرفت. از آنجایی‌که مدل‌های یادگیری عمیق در شناسایی خودکار هدف راداری به عملکرد خوبی دست یافته‌اند، بررسی مدل‌های مبتنی بر یادگیری عمیق در شناسایی هدف راداری امکان‌پذیر و معقول است.

۱. مبانی نظری پژوهش

استفاده از شبکه‌های عصبی مصنوعی و یادگیری عمیق در تشخیص هدف رادار، نه تنها یک بهبود تدریجی، بلکه یک تحول ابرانگاره (پارادایمی) محسوب می‌شود این رویکرد، به‌ویژه در کاربردهای حساس دفاعی و امنیتی که حداقل خطا و حداکثر دقت مورد نیاز است، به یک ضرورت راهبردی تبدیل شده است.



۱-۱. بررسی انواع روش شناسایی هدف راداری


روش‌های پردازش سنتی برای شناسایی هدف راداری در سناریوی پیچیده‌ای از شناسایی هدف راداری، سیگنال‌های اکو رادار اغلب در نویز، پارازیت و درهم‌ریختگی و ... غوطه‌ور می‌شوند که در شکل (۳)، نشان داده شده است. روش‌هایی مانند فیلتر کردن همسان، انباشت منسجم، سرکوب درهم و برهمی، تشخیص CFAR و ... می‌توان نام برد.



شکل ۳: شماتیک شناسایی هدف راداری در یک صحنه پیچیده

سیگنال‌های رادار دریافتی با نرخ مشخصی نمونه‌برداری می‌شوند و پالس‌ها توسط فیلتر همسان فشرده می‌شوند تا وضوح برد بالا و عرض پالس باریک به دست آید. نشانگر هدف متحرک (MTI) برای سرکوب به‌هم‌ریختگی استاتیک انجام می‌شود.

سپس، پردازش داپلر یا تجمع منسجم بر روی پالس‌های متعدد در هر واحد محدوده اعمال می‌شود تا طیف Range-Doppler به دست آید. دامنه سیگنال بازتاب‌شده برای هر Range-Doppler در سلول‌های جداگانه ذخیره می‌شود، پس از آن آشکارساز CFAR برای نشان دادن یکی که دامنه آن از آستانه تشخیص بیشتر است استفاده می‌شود. بنابراین، اطلاعات مربوط به سرعت و موقعیت را می‌توان اندازه‌گیری کرد. فلوجارت در شکل (۴)، ارائه شده است.




شکل ۴: نمودار پردازش سیگنال رادار پالس داپلر

یکی از مهم‌ترین اهداف طراحی آشکارساز راداری، تشخیص اهداف از سیگنال‌های نویز، درهم و پارازیت است. باید در انتهای آشکارساز تصمیم گرفت که آیا پژواک رادار حاوی هدف است یا خیر. روش کلاسیک برای ایجاد یک آستانه تشخیص تطبیقی براساس مدل‌های آماری است که با توجه به نویز و انرژی درهم‌آبی متفاوت است. به‌منظور به حداقل رساندن نرخ هشدار نادرست (P_{fa}) و به حداکثر رساندن احتمال تشخیص (PD)، معیار نیمین-پیرسون برای تصمیم‌گیری استفاده می‌شود. عملکرد معمولی مورد نیاز یک سامانه راداری به $PD \geq 0.8$ و $P_{fa} \leq 10^{-4}$ نیاز دارد. این مشکل معمولاً با استفاده از یک آشکارساز CFAR حل می‌شود که به‌طور تطبیقی یک آستانه بهینه محلی را تعیین می‌کند و P_{fa} را به‌عنوان یک مقدار از پیش تعیین شده ثابت نگه می‌دارد. نمونه‌های ورودی توسط سلول به سلول آشکارساز ارسال می‌شوند و انرژی بین سلول تحت آزمایش (CUT) تخمین زده می‌شود. آشکارساز CFAR مقدار آماری را با توجه به تغییر انرژی در سلول‌های مرجع n_2 تنظیم می‌کند. انرژی CUT با نتیجه آماری z پردازنده CFAR مقایسه می‌شود که با مقیاس ثابت α مقیاس شده است. بنابراین، آستانه تشخیص به‌صورت αz نمایش داده می‌شود. تعیین این‌که آیا هدف مطابق (۱) وجود دارد یا خیر:

$$\begin{cases} y \leq \alpha z, & \text{هدف موجود نیست} \\ y > \alpha z, & \text{هدف موجود است} \end{cases}$$

به‌منظور یافتن یک آستانه تشخیص تطبیقی، بسیاری از روش‌های مبتنی بر CFAR مورد مطالعه قرار گرفته‌اند که می‌توانند آستانه را با تغییرات پس‌زمینه تطبیق دهند و یک P_{fa} را ثابت نگه دارند. نمودار پردازنده‌های معمولی CFAR نیز در شکل (۵)، نشان داده شده است.



شکل ۵: نمودار آشکارسازهای معمولی CFAR

در مقایسه با تشخیص دامنه یک‌بعدی، انباشت همدوس زیرفاز تشخیص دوبعدی شامل محدوده و تشخیص داپلر است.

آشکارسازهای مبتنی بر CFAR در طول سال‌های گذشته به‌خوبی مورد مطالعه قرار گرفته‌اند، بااین‌حال، هنوز یک مبادله بین فناوری‌های مختلف CFAR وجود دارد. CFAR میانگین سلولی (CA CFAR) پرکاربردترین روشی است که بیشترین قابلیت تشخیص را در زمینه همگن دارد بااین‌حال، در حضور یک هدف مداخله‌گر یا یک تغییر ناگهانی در پس‌زمینه درهم، کاهش شدید عملکرد را نیز نشان می‌دهد. بزرگ‌ترین آشکارسازهای CFAR (GO-CFAR) و کوچک‌ترین آشکارسازهای CFAR (SO-CFAR) برای بهبود عملکرد تشخیص تحت شرایط مختلف غیرایده‌آل مانند پس‌زمینه غیرهمگن و محیط‌های هدف چندگانه توسعه داده شدند رولینگ آمار مرتب CFAR (OS-CFAR) را برای کنترل آستانه تشخیص توسعه داد، حتی اگر سیگنال‌های تداخلی دیگر در سلول مرجع رخ دهد. روش‌های CFAR هنوز در دست بررسی هستند، مانند آشکارساز سطح متوسط سانسور شده CFAR (CMLD-CFAR) و آشکارساز میانگین CFAR (TM-CFAR) که برای بهبود عملکرد ضد استنتاج معرفی شدند. بااین‌حال، هر یک از آن الگوریتم‌های CFAR تنها به موارد خاصی محدود می‌شوند که کلیت ندارند.

۲-۱. کمبودها و چالش‌ها در رویکردهای مرسوم

شناسایی هدف راداری یک مشکل نسبتاً پیچیده در کاربردهای عملی است. اگرچه روش‌های مرسوم در برخی شرایط به‌خوبی کار می‌کنند، کمبودها و چالش‌ها هنوز وجود دارد. در حال حاضر، مشکلات دشوار شناسایی هدف راداری هنوز عمدتاً در پردازش اهداف با وضوح بالا، سرکوب درهم‌تنیدگی، فناوری ضد پارازیت و هدف «کم-کوچک-کُند» است. تشخیص (زاویه نگاه کم، اندازه کوچک، کند یا ثابت) و ... (کیم، ۲۰۰۷).

روش‌های متداول مبتنی بر CFAR در سیستم‌های راداری عمدتاً به فرضیه‌های آماری بستگی دارد؛ ۱. در شناسایی هدف راداری واقعی، فقط نوع خاصی از هدف در زیر زمین خاص عملکرد تشخیص خوبی دارد، زیرا پارامترهای از پیش تعریف شده آشکارسازها مانند حاشیه، آستانه، اندازه محافظ و پنجره‌های مرجع، دقت تشخیص را تعیین می‌کنند. باین‌حال، رادار همیشه در صحنه‌های متنوع کار می‌کند؛ ۲. علاوه بر این، روش‌های سنتی از نظر محاسباتی، گران هستند و انعطاف‌پذیر نیستند، زیرا ورودی‌ها را سلول به سلول پردازش می‌کنند و نیاز به تغییر دستی اندازه پنجره به اهداف تطبیقی با وضوح‌های مختلف دارند؛ ۳. مهم‌تر از همه، در بیشتر موارد، نه هدف و نه محیط (نویز، درهم و برهم، تداخل) مدل‌های آماری شناخته شده‌ای ندارند. یافتن پارامترهای مناسب برای طراحی آشکارساز رادار، به غیر از پیش‌بینی دقیق عملکرد آن، دشوار است. به‌طور خلاصه، روش‌های آماری سنتی دیگر برای صحنه‌های پیچیده قابل استفاده نیستند و انتخاب مجموعه پارامترهای بهینه بسیار چالش‌برانگیز است. توسعه یک رویکرد یادگیری عمیق مبتنی بر داده برای شناسایی هدف راداری منطقی و اجتناب‌ناپذیر به نظر می‌رسد.

۳-۱. شبکه‌های عصبی مصنوعی و مدل‌های مبتنی بر یادگیری عمیق برای

شناسایی هدف راداری


شبکه عصبی مصنوعی توسط ساختار بیولوژیکی مغز انسان ایجاد می‌شود. به‌طور کلی، یک شبکه عصبی متشکل از نورون، بردار وزن، بایاس، تابع فعال‌سازی و ... است. پرسپترون



چندلایه (MLP) نوعی شبکه عصبی است که از چندین لایه پنهان تشکیل شده است که نورون‌ها در لایه‌هایی به یکدیگر متصل هستند. شبکه‌های عصبی به دلیل توانایی یادگیری می‌توانند در شناسایی هدف راداری مورد استفاده قرار گیرند. درواقع، مشکل شناسایی هدف راداری را می‌توان به عنوان یک مشکل تشخیص الگو در نظر گرفت که به خوبی با امکاناتی که یک شبکه عصبی مصنوعی ارائه می‌دهد مطابقت دارد. چندین رویکرد پیشنهاد کرده‌اند که در نظر گرفتن شبکه عصبی مصنوعی‌ها به عنوان آشکارسازهای غیرخطی می‌تواند عملکرد تشخیص را بهبود بخشد. یک آشکارساز شبکه عصبی مصنوعی معمولی در شکل (۶)، نشان داده شده است. خروجی هر نورون را می‌توان به صورت زیر ارائه کرد:

$$X^{k+1} = f(W^k \cdot X^k + b^k)$$

یک طرح تشخیص NN-CFAR برای ارائه عملکرد قوی در مواجهه با از دست دادن سلول‌های مرجع ارائه شده است.



شکل ۶: آشکارساز شبکه عصبی مصنوعی

با استفاده از چندین لایه برای دستیابی به تعمیم و انتزاعات قوی‌تر، شبکه عصبی عمیق تمام روش‌های یادگیری ماشین را انجام نمی‌دهد. شبکه عصبی کم‌عمق سنتی به یک فرایند استخراج ویژگی تجربی برای کاهش بار محاسباتی شبکه نیاز دارد. اگر ویژگی‌ها باید به طور خودکار توسط شبکه استخراج شوند، یک شبکه عمیق با قابلیت آموزش قدرتمند ضروری

است. در حال حاضر، توسعه قدرت کامپیوتر و حافظه، امکان آموزش شبکه‌های بسیار بزرگ را فراهم کرده است. اندازه‌های مختلفی از لایه‌ها برای ارائه درجات مختلف انتزاع و تعمیم استفاده می‌شود.

افزایش محبوبیت یادگیری عمیق باعث افزایش انتشارات تحقیقاتی مرتبط با شناسایی هدف راداری با مدل‌های یادگیری عمیق در چند سال گذشته شده است. چهارچوب‌های شبکه طراحی شده ویژه برای شناسایی هدف راداری در محیط‌های نویز و پس‌زمینه‌های درهم در این کار گنجانده خواهد شد. علاوه بر این، چندین شبکه عصبی عمیق مختلف در این مقاله بررسی خواهند شد و هر یک از آن‌ها برای شناسایی هدف راداری عملکرد خوبی دارند. افزایش تعداد انتشارات مرتبط، انگیزه معتبر و فزاینده جامعه پژوهشی را در مورد وظایف شناسایی هدف راداری تأیید می‌کند.

علاوه بر این، یک سامانه راداری شایسته و کامل باید یک PD بالا با Pfa پایین را فراهم کند که اصل اصلی استفاده از آشکارسازهای استاندارد CFAR است. اختر و اولسن یک شبکه عصبی مصنوعی ارائه کردند که تحت یک آشکارساز CA-CFAR برای یک روش تشخیص هدف نوسانی با پس‌زمینه نویز آموزش دیده است. اگر یک هدف واقعی در حذف وجود داشته باشد و CA-CFAR یک تشخیص مثبت را برگرداند یا شبکه نتایج مثبتی را نشان ندهد، آشکارساز شبکه عصبی مصنوعی به‌صورت مشروط نتایج مثبت را خروجی می‌دهد. یکی از مزایای برجسته آشکارساز شبکه عصبی مصنوعی این است که نتیجه ممکن است به‌عنوان معیار PD در نظر گرفته شود و لزوماً ۰ یا ۱ نباشد. همچنین نشان داده شد که چنین طرحی می‌تواند عملکرد تشخیص هدف کمی پایین‌تر یا قابل مقایسه را به دست آورد؛ اما با Pfa قابل توجهی کم‌تر از آشکارساز سنتی CA-CFAR. آشکارساز CFAR، آمورس و همکاران است. همچنین استدلال کردند که شبکه عصبی مصنوعی می‌تواند استحکام آشکارساز راداری را بهبود بخشد. نتایج نشان می‌دهد که اگرچه عملکرد تشخیص شبکه آموزش دیده با افزایش تعداد نورون‌های پنهان افزایش می‌یابد، MLP های دارای لایه پنهان با ۲۴ واحد می‌توانند آشکارسازهای بسیار قوی را برای SNR کم‌تر از ۱۰ دسی‌بل پیاده‌سازی کنند. برای بیش از




۲۴ نورون پنهان، بهبود عملکرد بی‌اهمیت است، درحالی‌که هزینه محاسباتی مرتبط همچنان در حال رشد است.

۲. روش‌شناسی پژوهش

در مقایسه با پس‌زمینه نویز، تشخیص هدف در پس‌زمینه شلوغی مشکلی رایج‌تر، اما چالش‌برانگیز است؛ زیرا سیگنال‌های برگشتی از اهداف به‌شدت توسط پراکندگی پس‌زمینه از درهم‌کاری غوطه‌ور می‌شوند. با توجه به تجزیه و تحلیل نظری، عملکرد تشخیص CFAR با افزایش تعداد سلول‌های مرجع افزایش می‌یابد. همان‌طور که عدد به بی‌نهایت نزدیک می‌شود، آشکارساز CFAR به آشکارساز بهینه نزدیک می‌شود. با این حال، تخریب جدی در PD آشکارساز سنتی CFAR به دلیل کاهش تعداد واحدهای مرجع موجود است. این کاهش ممکن است به دلیل وضوح بالا وجود سیگنال‌های تداخل یا وصله‌های درهم باشد. در طرح CFAR، نیاز به یک پنجره مرجع بزرگ‌تر، یا سلول‌های مرجع بیشتر، ناشی از الزامات آماری برای پارامترهایی است که برای نمایش استفاده می‌شود. پس‌زمینه درهم و نوسان هدف از دست دادن اطلاعات ناشی از کاهش اندازه پنجره را می‌توان با معرفی برخی پارامترهای اضافی جبران کرد. آموزگار و همکاران در اوایل سال ۱۹۹۴، یک روش تشخیص CFAR مبتنی بر NN ارائه کرد که عملکرد قوی برای جبران از دست دادن سلول‌های مرجع ارائه می‌دهد. لایه ورودی شامل نه پارامتر آماری خاص است که نشان‌دهنده ویژگی‌های هدف و شلوغی است.

برای تشخیص هدف از درهم و برهمی، روش معنی‌دار دیگر این است که به دنبال ویژگی‌های ذاتی خاصی از پژواک‌های برگشتی بگیرد تا تفاوت بین هدف و درهم‌کاری را توصیف گردد. کالانگان و همکاران بزرگی هر یک از ویژگی‌های پیکسل برد-داپلر را از نقشه‌های Range-Doppler انتخاب کرد و آن‌ها را با الگوریتم‌های SVM و KNN پردازش کرد تا اهداف دریایی کوچک را از درهم و برهمی دریا متمایز کند. سه ویژگی عملاً متمایز را کاوش و استخراج کرد، یعنی نسبت اوج فرکانس به میانگین، توان هر ست زمانی و آنتروپی

اطلاعات زمانی، از اکو رادار در حوزه‌های زمان و فرکانس برای ساخت فضای ویژگی. یک آشکارساز مبتنی بر SVM که می‌تواند به‌طور انعطاف‌پذیر Pfa را کنترل کند برای تشخیص هدف در داخل دریا طراحی شده است. نتایج تجربی نشان داد که احتمال تشخیص آشکارساز پیشنهادی به‌وضوح بالاتر از آشکارسازهای کلاسیک تحت شرایط نسبت سیگنال به درهم‌آبی پایین و موارد Pfa پایین است. همه این پارامترهای آماری که ویژگی‌های هدف و درهم‌کاری را نشان می‌دهند ممکن است به‌عنوان ورودی آشکارساز مبتنی بر NN در ادبیات گنجانده شوند. با این حال، از آنجایی که ویژگی‌های به‌هم‌ریختگی به‌شدت به محیط واقعی و پارامترهای رادار بستگی دارد، موارد فوق پارامترها یا ویژگی‌های استخراج شده اغلب زمانی که محیط تشخیص تغییر می‌کند، بی‌اثر می‌شوند. در مقایسه با روش‌های یادگیری ماشینی که نیاز به انتخاب تجربی ویژگی‌ها دارند، شبکه عصبی مصنوعی برای استخراج ویژگی‌های با ابعاد بالا مناسب‌تر است و به‌عنوان روشی برای تشخیص سیگنال راداری مورد استفاده قرار گرفته است. در ادامه از معماری‌های شبکه عصبی مصنوعی مختلف برای ارزیابی مشکل شناسایی هدف راداری در یک درهم‌ریختگی توزیع شده K با نویز حرارتی استفاده کردند. آن‌ها معماری MLP را با الگوریتم ژنتیک و انتشار معکوس به‌عنوان روش‌های آموزشی در نظر گرفتند و تابع پایه شعاعی (RBF) که تا حد زیادی در پردازش سیگنال استفاده شده است، در آشکارساز عصبی نیز به‌کار گرفته شد. یک مجموعه آموزشی استفاده شد که می‌تواند توزیع درهم و برهم را به‌خوبی توصیف کند و معماری آشکارسازهای شبکه عصبی مصنوعی CFAR نشان داده شده در شکل (۷)، نتایج نشان می‌دهد که آشکارساز شبکه عصبی مصنوعی CFAR با ساختار MLP در مقایسه با OS-CFAR و CA کلاسیک عملکرد بهتری از آشکارسازهای CFAR دارد.



شکل ۷: ساختار آشکارساز شبکه عصبی مصنوعی

کارهای قبلی، همان‌طور که ذکر شد تلاش کردند تا عملکرد تشخیص هدف را براساس روش‌های سنتی CFAR بهبود بخشند. یکی از اهداف جایگزینی آشکارساز مبتنی بر CFAR به‌طور کامل با شبکه‌های عصبی برای بهینه‌سازی فرایند تشخیص است. در سال ۲۰۱۹، اختر و اولسن به پیشنهاد یک راهبرد آموزشی کلی‌تر ادامه دادند که در آن آشکارسازهای معمولی GO-CFAR به‌طور متقابل برای شناسایی اهداف در درهم و برهمی توزیع شده K کار می‌کنند. این فرایند همچنین به یک شبکه عصبی مصنوعی با چهار لایه پنهان و ۱۹ گره در هر لایه، با $\tanh$ به‌عنوان تابع فعالیت منتقل می‌شود. راهبرد آموزشی مربوط به است و ساختار شبکه عصبی مصنوعی مشابه ساختار است. داده‌های آموزشی کامل شامل ۲۰۰۰ نقشه محدوده داپلر مستقل با میانگین سنی SNR در تمام CPI ها از ۴۰ دسی بل تا ۷۵ دسی بل، درحالی‌که میانگین SCR از ۶۰ دسی بل تا ۶۰ دسی بل متغیر بود. نتایج تجربی نشان می‌دهد که حداقل برای صحنه‌های آموزش‌دیده، عملکرد تشخیص کلی شبکه عصبی مصنوعی می‌تواند به‌طور قابل‌توجهی بهتر از آشکارساز GO-CFAR، یعنی افزایش PD با کاهش Pfa، بهتر عمل کند.

از کار بالا، این روش‌های مبتنی بر شبکه عصبی مصنوعی، اهداف را از پس‌زمینه ناهمگونی نویز متمایز می‌کنند و نتایج بهتر و قوی‌تری نسبت به روش‌های آماری معمولی ارائه می‌دهند. علاوه بر این، معماری چندلایه عملکرد بهتری را نشان می‌دهد، به‌ویژه در یک محیط درهم

و برهم مخلوط. با این حال، شبکه‌های عصبی مصنوعی کلاسیک یک محدودیت عمده نیز دارند؛ یعنی به دلیل تعداد کم نورون‌ها و لایه‌ها، ممکن است عملکرد رضایت‌بخشی در هنگام برخورد با مشکلات طبقه‌بندی و رگرسیون حاصل نشود.

۱-۲. بررسی یادگیری عمیق در عملکرد رادار

اگرچه رویکردهای مبتنی بر یادگیری عمیق کاربردهای موفقیت‌آمیزی در زمینه شناسایی هدف راداری داشته‌اند، چالش‌های زیر همچنان باقی است:

❖ کمبود مجموعه داده

یکی از مشکلات در به‌کارگیری روش‌های مبتنی بر یادگیری عمیق در شناسایی هدف راداری، فقدان داده‌های برچسب‌دار در دسترس عموم است. تفاوت با سایر برنامه‌ها هزینه بالای جمع‌آوری داده‌های رادار است. در حال حاضر، مدل‌سازی شبیه‌سازی سامانه راداری روشی برای حل مشکل است؛ اما از نظر محاسباتی سخت و چالش‌برانگیز برای تولید داده‌های جایگزین است زیرا عوامل متعددی باید در نظر گرفته شوند، مانند تضعیف چندگانه، سلول‌های گسسته و بازتاب‌های چندمسیره. به عبارت دیگر، حتی در صورت حذف تمامی مسائل فوق، اتکا به مدل‌های ریاضی برای شبیه‌سازی اجتناب‌ناپذیر است که ممکن است مشکل وفاداری مدل را مطرح کند. نادرستی مشابهی در ظاهر شده است. ما هنوز امیدواریم که داده‌های کافی برای آموزش را از سیستم‌های رادار دنیای واقعی به دست آوریم که مطمئناً مدل تشخیص را قابل اعتمادتر می‌کند. به‌منظور پیشبرد بیشتر تحقیقات شناسایی هدف راداری در غیاب داده‌های راداری واقعی، رویکردهای زیر را می‌توان در نظر گرفت:

۱. تقویت داده‌ها؛

۲. توسعه الگوریتم‌های مبتنی بر یادگیری عمیق قوی‌تر با داده‌های آموزشی ناکافی،

مانند شبکه‌های متخاصم مولد؛

۳. به نظر می‌رسد ایجاد چهارچوب‌های پیشرفته‌تر شناسایی هدف راداری یک روند

جدید باشد؛



۴. توسعه روش‌های مبتنی بر یادگیری، مانند فرایادگیری و یادگیری انتقالی که می‌تواند بر محدودیت داده‌های ناکافی و عدم حساسیت به تغییرات محیط تشخیص رادار غلبه کند؛

۵. مدل‌های متنوع در وظایف پیچیده.

اگرچه استفاده از فناوری یادگیری عمیق در شناسایی هدف راداری پیشرفت قابل توجهی داشته است، مقالات موجود در مورد شبکه عصبی مصنوعی و شبکه عصبی عمیق‌های شناسایی هدف راداری هنوز نسبتاً پراکنده هستند و به اندازه کافی بالغ نیستند. به عنوان مثال، یک جنبه مشترک که در بسیاری از مقالات ذکر شده در بالا یافت می‌شود، اندازه متوسط شبکه عصبی مصنوعی است که در آن شبکه‌های پیشنهادی در تنها حاوی یک لایه پنهان هستند. علاوه بر این، اگرچه بسیاری از معماری‌های دیگر در شبکه عصبی عمیق پیشنهاد شده است، تنها CNN به طور گسترده در شناسایی هدف راداری استفاده می‌شود. بنابراین، فضای زیادی برای کشف شبکه عصبی عمیق‌های مختلف در شناسایی هدف راداری وجود دارد. سامانه پردازش سیگنال که می‌تواند به طور مؤثری نوسانات RCS هدف، نویز، درهم‌ریختگی و پارازیت را سرکوب کند، همیشه به عنوان یکی از جهت‌گیری‌های کلیدی تحقیق و توسعه رادار در نظر گرفته می‌شود. نحوه تشخیص مؤثر اهداف از سیگنال‌های گیرکرده فعال هنوز در دست بررسی است. نحوه تأیید این که دیگر معماری‌های یادگیری عمیق می‌توانند در شناسایی هدف راداری بهتر عمل کنند نیز باید در نظر گرفته شود. این‌ها همچنین حاکی از آن است که طرح‌های یادگیری جدیدتر، متنوع‌تر اما کاربردی‌تر برای کارهای پیچیده‌تر نیاز فوری دارند. پیشرفت در قدرت محاسباتی امکان آموزش مدل‌های یادگیری عمیق در مقیاس بزرگ را بر روی داده‌های عظیم فراهم می‌کند. پیشرفت قابل توجه در الگوریتم‌های یادگیری عمیق و پیشرفت‌های زیاد در سامانه رادار به نفع یکدیگر خواهد بود. جایگزینی کل پردازش سیگنال رادار با روش‌های یادگیری عمیق ارزش کاوش را دارد.

۲-۲. روش پیاده‌سازی تحقیق

♦ پیاده‌سازی سامانه آشکارساز

پیاده‌سازی پردازش سیگنال رادار با FPGA (آرایه دروازه‌ای قابل برنامه‌ریزی میدانی) روشی قدرتمند برای انجام محاسبات پیچیده مورد نیاز در سیستم‌های راداری بلادرنگ ارائه می‌دهد. FPGA ها در پردازش موازی برتری دارند و همین امر آن‌ها را برای کارهایی مانند تبدیل فوریه سریع (FFT)، فیلتر کردن و تشخیص CFAR (نرخ هشدار کاذب ثابت) که برای تجزیه و تحلیل سیگنال رادار بسیار مهم هستند، ایده‌آل می‌کند.

برد انتخابی Spartan-6 است، این برد از خانواده FPGA های شرکت Xilinx است که به‌منظور ارائه قابلیت‌های یکپارچه‌سازی سامانه با هزینه نسبتاً کم برای کاربردهای با حجم بالا و دقت بالا طراحی شده است.

بهبود منبع کلاک با استفاده از واحدهای CMT (Clock Management Tile) که علاوه بر DCM (Digital Clock Manager) حاوی یک واحد PLL (Phase Locked Loop) نیز هستند (برخلاف SPARTAN-3 که تنها دارای DCM است).

معماری رادار موج پیوسته (CW) کم‌هزینه برای تشخیص سرعت جسم در این تحقیق ارائه شده است. از یک پردازنده FPGA (آرایه دروازه‌ای قابل برنامه‌ریزی میدانی) برای پیاده‌سازی رادار CW به‌طور قابل اعتماد و بهینه استفاده می‌شود. رویکرد پیشنهادی از یک بانک فیلتر که به‌طور خاص برای استخراج اطلاعات سرعت از سیگنال‌های رادار برای محاسبه سرعت هدف ساخته شده‌اند، استفاده می‌کند. بسته به نیازهای کاربرد خاص، داده‌های به‌دست‌آمده یا تحت پردازش اضافی قرار گرفته‌اند یا به روشی قابل فهم ارائه شده‌اند. طرح پیاده‌سازی شده به‌صورت بلادرنگ با یک اسکوپ تراشه بررسی می‌شود، به‌صورت عملکردی شبیه‌سازی می‌شود و سپس با ابزارهای آزمایشگاهی برای مقایسه تمام نتایج شبیه‌سازی شده و پیاده‌سازی شده بررسی می‌شود. کاربردهای متعددی، مانند اتوماسیون صنعتی، نظارت و سیستم‌های خودرو که در آن‌ها تشخیص دقیق سرعت بسیار مهم است و طراحی کم‌هزینه مورد نیاز است، می‌توانند از این مفهوم بهره‌مند شوند.




پیاده‌سازی سخت‌افزاری پردازنده پیشنهادی عمدتاً به سه مرحله تقسیم می‌شود؛ مرحله اول تأیید سیگنال دریافتی با استفاده از FPGA، مرحله دوم تأیید و پیاده‌سازی مشخصات بانک فیلتر و مرحله سوم محاسبات سرعت هدف و نمایش نتیجه است.

❖ فیلترهای آنالوگ برای تبدیل داده‌ها

تقریب‌های فیلتر زیادی وجود دارد که می‌توان از آن‌ها برای پیاده‌سازی یک فیلتر بازسازی پایین‌گذر استفاده کرد. در هر صورت، پهنای باند فیلتر باید با پهنای باند مورد انتظار سیگنال بازسازی‌شده مطابقت داشته باشد. در این مقاله، یک راهبرد جدید برای طراحی فیلترهای بازسازی برای مبدل‌های دیجیتال به آنالوگ ارائه شده است. این راهبرد مبتنی بر استفاده از یک فیلتر پایین‌گذر باترورث جبران‌شده از نظر تأخیر است که پاسخ آن در حوزه زمان با تغییر پارامترهای فیلتر، شتاب می‌یابد. هدف اصلی تقریب باترورث، دستیابی به یک پاسخ دامنه حداکثر مسطح در باند عبور فیلتر است. پاسخ دامنه فیلتر پایین‌گذر باترورث به صورت زیر نوشته می‌شود:



$$|H_F(j\omega)|^2 = \frac{h_0}{1 + \left(\frac{\omega}{\omega_c}\right)^{2n}}$$

که در آن n مرتبه فیلتر، h_0 بهره DC (بهره در فرکانس صفر) و فرکانس حد ۳ دسی‌بل است. باین‌حال، برای این دسته از فیلترها، پاسخ فاز آن غیرخطی است.



شکل ۸: نمودار بلوکی یک سامانه DSP FPGA

قبل از مواجهه با مبدل آنالوگ به دیجیتال، سیگنال ورودی با یک فیلتر پایین‌گذر الکترونیکی پردازش می‌شود تا تمام فرکانس‌های بالاتر از فرکانس نایکوئیست (نصف نرخ نمونه‌برداری) حذف شود. این کار برای جلوگیری از ایجاد اعوجاج در طول نمونه‌برداری انجام می‌شود و به همین ترتیب فیلتر آنتی‌آلیین نامیده می‌شود. در انتهای دیگر، سیگنال دیجیتال شده از یک مبدل دیجیتال به آنالوگ و یک فیلتر پایین‌گذر دیگر که روی فرکانس نایکوئیست تنظیم شده است، عبور می‌کند. این فیلتر خروجی، فیلتر بازسازی نامیده می‌شود و ممکن است شامل تقویت فرکانس با نگه‌داشتن مرتبه صفر باشد. متأسفانه، یک مشکل جدی در این مدل ساده وجود دارد: محدودیت‌های فیلترهای الکترونیکی می‌تواند به اندازه مشکلاتی که سعی در جلوگیری از آن‌ها دارند، بد باشد. از این‌رو فیلتر طراحی شده تا حد امکان از اعوجاج جلوگیری می‌نماید. این فیلتر یک نقطه توازن عالی بین صافی باند عبور و شیب قطع ارائه می‌دهد.



شکل ۹: پیکربندی‌های فیلتر پیشنهادی

۳. یافته‌های پژوهش

بر اساس نتایج پژوهش‌های پیشین می‌توان چنین تبیین کرد که با وجود پیشرفت سیستم‌های تشخیص هدف رادار هنوز چالش‌ها و مشکلاتی همچون عدم دقت، صحت تشخیص و خطای بالا مطرح است. روش‌های مختلفی تاکنون از جمله روش‌های مبتنی بر فرکانس‌های تشدید طبیعی هدف، روش‌های یادگیری ماشین و ... به‌منظور تشخیص اهداف راداری مطرح شده است. با وجود کاربردهای فراوانی که این روش‌ها داشته‌اند؛ اما هنوز نتوانسته‌اند



چالش‌های و مشکلات موجود در رادار را برطرف نمایند. شناسایی تشخیص اهداف راداری ضرورتی است که برای هر کشور از اهمیت بالایی برخوردار است. با شناسایی اهداف راداری می‌توان امنیت هوایی و امنیت پرواز یک کشور را حفظ و ایمن نمود. رادارهای مراقبت زمینی عموماً اطلاعی کمی را برای کاربر مشخص می‌نماید و از نوع هدف مشاهده شده اطلاعاتی مشخص نمی‌نماید. یکی از نقش‌های کلیدی هر سامانه پدافند، تصمیم‌گیری در موقعیت‌های پرتنش و اضطراب‌ها است که بخش عمده آن به فرایندهای شناخت و ابعاد دقیق هدف و در نتیجه، تشخیص اهداف راداری وابسته است.

با توجه به اهمیت تشخیص اهداف راداری و تأثیر آن بر ظرفیت امنیت کشور، تجزیه و تحلیل دقیق هدف یکی از راهکارهایی است که برای شناسایی هدف استفاده می‌شود. با بررسی تحقیقات و مقالات 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 مشکلات موجود در اهداف راداری همچون عدم دقت مطلوب تشخیص اهداف راداری وجود نویز در دریافت، خطای بالا، تخریب سیگنال، تصاویر راداری را مرتفع نمایند. در این پژوهش از شبکه عصبی به‌منظور طبقه‌بندی و تشخیص اهداف راداری استفاده می‌شود. داده‌ها و اطلاعات راداری به‌عنوان ورودی به شبکه عصبی ارائه می‌گردد. شبکه عصبی عمیق براساس 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 سامانه تولید شده اقدام به شناسایی اهداف راداری می‌نماید.

۳-۱. بررسی روش پیشنهادی

برای ارزیابی راهکار پیشنهادی از مجموعه داده هدف‌های راداری و از ابزار متلب نسخه R2025a به‌منظور ارزیابی نتایج و شبیه‌سازی روش پیشنهادی استفاده شده است.

در این قسمت به ارائه الگوریتم شبکه عصبی پیشنهادی به منظور تشخیص اهداف راداری پرداخته می‌شود. دو بخش اصلی و مهم روش پیشنهادی پس از اعمال مجموعه داده اهداف راداری به سامانه پیشنهادی به شرح ذیل است: بخش اول نمونه‌ها برای آموزش نمونه الگوریتم موجود در سیستم یادگیری به کار گرفته می‌شود و بخش دوم، آن‌ها نیز به عنوان نمونه‌های تست برای آزمون روش پیشنهادی جهت شناسایی اهداف راداری، مورد استفاده قرار می‌گیرند. شبکه عصبی، یکی از روش‌های مهم در زمینه پیش‌بینی و تشخیص اهداف راداری است. ساختار پیشنهادی برای پیش‌بینی پاسخ‌های خروجی سیستم‌های پیچیده است. در شبکه عصبی مورد استفاده در روش پیشنهادی، از ۳ نوع لایه استفاده شد که شامل موارد ذیل است:

۱. لایه ورودی (داده‌های ورودی، به صورت نرمال شده)؛
۲. لایه‌های پنهان (لایه‌هایی هستند که بین لایه ورودی و لایه خروجی قرار دارند و وظیفه اصلی پردازش داده‌ها و استخراج ویژگی‌ها را بر عهده دارند) در این لایه پارامترها یا وزن‌ها بین زمان‌ها به اشتراک گذاشته می‌شوند. به این معنا که همان وزن‌ها برای هر مرحله زمانی استفاده می‌شوند و توصیف‌های غیرخطی را یاد می‌گیرد؛
۳. لایه خروجی (مقادیر خروجی).

تابع فعال‌سازی جزء اصلی گره‌های شبکه عصبی محسوب می‌گردد. توابع فعال‌سازی در شبکه‌های عصبی تعیین می‌کنند که آیا گره باید غیرفعال یا فعال باشد. به عبارتی دیگر، این توابع، با استفاده از محاسبات پیچیده ریاضی مشخص می‌کنند که آیا ورودی گره برای شبکه مهم است یا باید آن را نادیده گرفت. نقش تابع فعال‌سازی در شبکه‌های عصبی این است که با استفاده از مقادیر ورودی گره، مقداری در خروجی تولید کند. به بیان جزئی‌تر، تابع فعال‌سازی مقدار مجموع ورودی وزن‌دار گره را به مقادیری بین ۰ تا ۱ نگاشت می‌کند. سپس، این تابع، مقدار نهایی خود را به لایه بعد منتقل می‌کند. به همین دلیل، به این تابع، تابع انتقال نیز گفته می‌شود. در روش پیشنهادی از تابع فعال‌سازی Swish استفاده شده است.



تابع فعال‌سازی Swish که به صورت $f(x) = x * \text{sigmoid}(\beta x)$ تعریف می‌شود، یک تابع دارای مشتق‌های پیوسته در یک دامنه معین و غیریکنواخت است که در مدل‌های یادگیری عمیق کارآمد بوده و اغلب در وظایف طبقه‌بندی تصویر از ReLU بهتر عمل می‌کند. این تابع به‌ویژه به دلیل توانایی‌اش در بهبود دقت در شبکه‌های عمیق‌تر قابل توجه است. لازم به ذکر است که برای بهبود کیفیت سیگنال‌های ورودی، یک فیلتر با قابلیت حذف نویز بالا در ورودی داده ورودی طراحی شده است. مهم‌ترین ویژگی‌های تشخیص اهداف راداری با استفاده از روش پیشنهادی را می‌توان به این ترتیب خلاصه کرد:


- ❖ بهبود کیفیت سیگنال‌های ورودی با فیلتر پیشنهادی؛
- ❖ افزایش میزان دقت تشخیص اهداف راداری با استفاده از مدل پیشنهادی؛
- ❖ کاهش نویز سیگنال؛
- ❖ کاهش تخریب سیگنال.

یکی از بزرگ‌ترین مزایای شبکه عصبی کارایی بالای آن در شرایط مختلف تشخیص هدف است. این مدل توانایی تجزیه و تحلیل تصاویر با دقت پایین را دارد، حتی در شرایطی که داده‌ها نویز یا اختلالات دارند. این قابلیت‌ها روش پیشنهادی را به گزینه‌ای ایدئال برای استفاده در زمینه‌هایی نظیر رادار تبدیل کرده است، جایی که دقت بالا در تشخیص و تجزیه و تحلیل تصویرها حیاتی است. در کل روش پیشنهادی، به دلیل معماری منحصر به فرد خود، مزایای متعددی در مقایسه با دیگر شبکه‌های عصبی دارند.

به‌طور کلی از نظر سیگنال کارآمدتر هستند، به این معنی که برای دستیابی به دقت مشابه به تعداد کمتری از پارامترها در مقایسه با دیگر معماری‌های شبکه‌های عصبی نیاز دارند. در نهایت، یک طراحی سطح انتقال ثبات (RTL)، برای الگوریتم پیشنهادی، با استفاده از تراشه FPGA پیاده‌سازی شده است.

۲-۳. ارزیابی روش پیشنهادی

برای تحلیل روش پیشنهادی از مجموعه داده اهداف راداری و از نرم‌افزار متلب نسخه ۲۰۲۴ به منظور ارزیابی نتایج و شبیه‌سازی روش پیشنهادی استفاده شده است. برای مقایسه نیز از روش SAE مقاله (گوئو ۲۰۱۹) استفاده شده است که در شکل (۱۰)، نشان داده شده است. همچنین با پایین آمدن SNR از دقت عملکرد هر دو شبکه کاسته شده است.



شکل ۱۰: مقایسه دقت روش پیشنهادی با SAE

شماتیک کلی اولیه سامانه که شامل ورودی-خروجی‌های مدار است در شکل (۱۱)، نشان داده شده است. در این بخش یک نمودار بلوکی RTL (سطح انتقال ثبات) سطح بالا برای مدل پیشنهادی طراحی شده است. با این حال، توجه داشته باشید که مدل پیشنهادی اصلی یک مدل یادگیری عمیق است که در نرم‌افزار ISE پیاده‌سازی شده است. برای طراحی RTL، باید پیاده‌سازی سخت‌افزاری را در نظر گرفته شود که امری بدیهی است و به منابع قابل توجهی داده نیاز دارد.


ورودی‌های RTL، نمونه‌های دیجیتال شده سیگنال رادار که توسط فیلتر پیشنهادی تولید شده است.



```

entity radar_detector is
port (
    -- ورودی RTL
    clk      : in  std_logic;
    rst      : in  std_logic;
    radar_i  : in  std_logic_vector(15 downto 0);
    config_mode : in std_logic;
    start_detection : in std_logic;

    -- خروجی RTL
    target_detected : out std_logic;
    target_range    : out std_logic_vector(11 downto 0);
);
end entity radar_detector;
    
```



شکل ۱۱: شماتیک RTL (سطح انتقال-ثبات)

با شبیه‌سازی و پیاده‌سازی روش پیشنهادی مشاهده گردید که میزان دقت، زمان محاسبه، قدرت پیش‌بینی، فراخوانی و خطای روش پیشنهادی به‌منظور تشخیص اهداف راداری نسبت به جدیدترین روش‌های مطرح شده تاکنون بهبود قابل ملاحظه‌ای داشته است. به‌عنوان نمونه در حالتی که نسبت سیگنال به نویز داده‌ها ۱۰ دسی‌بل است، میزان دقت پیشنهادی ۹۷/۶۷ و SAE با توجه به (گوئو، ۲۰۱۹) ۹۳/۷۲ است.

این پژوهش، چهارچوب محکمی برای تشخیص هدف راداری ارائه می‌دهد. برای افزایش قابلیت‌های سامانه در محیط‌های عملیاتی و رفع چالش‌هایی مانند اهداف ناشناخته، عدم تعادل داده و وابستگی زاویه‌ای، تلفیق راهکارهای فوق پیشنهاد شده است. به‌طور خاص، «جایگزینی معماری شبکه با CNN-BERT یا Transformer»^۱ سبک‌وزن می‌تواند بهره‌وری استخراج ویژگی را به‌طور چشمگیری افزایش دهد. ادغام الگوریتم تشخیص مرز بسته در مرحله تصمیم‌گیری، سامانه را برای مواجهه با دنیای واقعی آماده‌تر می‌سازد. استفاده از توابع هزینه ترکیبی مانند Weighted-Focal Loss می‌تواند بدون تغییر در معماری، دقت تشخیص در شرایط نامتعادل را بهبود بخشد. این راهکارها نه‌تنها عملکرد کلی سامانه را ارتقا می‌دهند، بلکه قابلیت اطمینان و استحکام آن را در سناریوهای عملیاتی پیچیده تضمین می‌کنند.

۴. نتیجه‌گیری

به‌طورکلی از مقاله حاضر نتیجه می‌گردد که ایده استفاده از روش شبکه عصبی نسبت به روش متداول آشکارسازی دارای عملکرد بهتری است. شبیه‌سازی روش پیشنهادی نشان می‌دهد که میزان دقت، صحت، فراخوانی و خطای روش مبتنی بر الگوریتم شبکه عصبی عمیق به‌منظور تشخیص اهداف راداری نسبت به جدیدترین روش‌های مطرح شده تاکنون بهبود قابل ملاحظه‌ای داشته است و توانسته به‌خوبی 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

1. Bidirectional Encoder Representations from Transformers



سیستم‌ها و گیرنده‌های راداری از روش‌های یادگیری ماشین و به‌خصوص الگوریتم شبکه عصبی عمیق استفاده نموده و چالش‌ها و مشکلات موجود را مرتفع نمود. معماری‌های مختلف شبکه‌ها برای طرح‌های کاربردی مختلف مورد بررسی قرار گرفته‌اند. نتایج به‌دست‌آمده نشان داده است که آشکارسازهای مبتنی بر هوش مصنوعی تا حدی در برخی موارد خاص بهتر از روش‌های پردازش سنتی عمل می‌کنند. اگرچه مطالعه یادگیری عمیق در زمینه شناسایی هدف راداری در مرحله اولیه است و هنوز با چالش‌هایی روبه‌رو است؛ اما بدون شک تحقیق و استفاده از روش‌های مبتنی بر یادگیری عمیق در شناسایی هدف راداری به پیشرفت زیادی در آینده کمک خواهد کرد. این پژوهش گامی در جهت کاربردی‌تر کردن یادگیری عمیق در زمینه‌های مرتبط پردازش سیگنال رادار است. به‌منظور عملیاتی‌تر دادن روش پیشنهادی این سامانه در برد اسپارتن ۶ پیاده‌سازی شده است. اکثر پژوهش‌های موجود تنها بر روی یکی از چالش‌ها (مثلاً فقط کمبود داده) متمرکز هستند. یک مدل جامع که به‌طور هم‌زمان بر وابستگی زاویه‌ای، کمبود داده و اغتشاش غلبه کند، یک خلأ محسوس است. یکی از مشکلات در عملیاتی نمودن، عدم امکان آموزش مناسب شبکه یادگیری عمیق است. زیرا برای عملکرد بالای ۹۵ درصد شناخت کامل تمام اهداف مورد نیاز است که با توجه به ابعاد مختلف، دستیابی کامل اطلاعات چالش‌برانگیز خواهد بود که به‌عنوان کارهای آتی می‌توان برای استخراج مشخصات استفاده نمود.

مزایای طرح پیشنهادی

- ♦ عملی بودن: استفاده از معماری‌های استاندارد و قابل پیاده‌سازی.
 - ♦ کارایی: ترکیب تکنیک‌های اثبات‌شده برای حل چالش‌های واقعی.
 - ♦ قابلیت توسعه: امکان افزودن ماژول‌های جدید برای سناریوهای خاص.
 - ♦ توجیه‌پذیری: هر کامپوننت برای حل یک چالش مشخص طراحی شده است.
- این طرح پیاده‌سازی مسیر مشخص و عملی را برای رسیدن به اهداف تحقیق فراهم می‌کند و می‌تواند به‌عنوان نقشه راه برای توسعه یک سامانه تشخیص هدف راداری بهبودیافته مورد استفاده قرار گیرد.

References

- Elbir, A.M.; Mishra, K.V.; Eldar, Y.C. Cognitive radar antenna selection via deep learning. *IET Radar Sonar Navig.* 2019, 13, 871–880.
- Akhtar, J.; Olsen, K.E. GO-CFAR Trained Neural Network Target Detectors. In *Proceedings of the 2019 IEEE Radar Conference*, Boston, MA, USA, 22–26 April 2019.
- Bengio, Y.; Courville, A.; Vincent, P. Representation Learning: A Review and New Perspectives. *IEEE Trans. Pattern Anal. Mach. Intell.* 2013, 35, 1798–1828.
- C. Wang, J.; Zhang, X. Automatic Radar Waveform Recognition based on Time-frequency Analysis and Convolutional Neural Network. In *Proceedings of the 2017 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, New Orleans, LA, USA, 5–9 March 2017; pp. 2437–2441.
- Ding, J.; Chen, B.; Liu, H.; Huang, M. Convolutional Neural Network with Data Augmentation for SAR Target Recognition. *IEEE Geosci. Remote Sens. Lett.* 2016, 13, 364–368.
- Gao, J.; Lu, Y.; Qi, J.; Shen, L. A Radar Signal Recognition System Based on Non-Negative Matrix Factorization Network and Improved Artificial Bee Colony Algorithm. *IEEE Access* 2019, 7, 117612–117626.
- Geng, J.; Fan, J.; Wang, H.; Ma, X.; Li, B.; Chen, F. High-resolution SAR Image Classification via Deep Convolutional Autoencoders. *IEEE Geosci. Remote Sens. Lett.* 2015, 12, 2351–2355.
- Goodfellow, I.; Bengio, Y.; Courville, A. *Deep Learning*; The MIT Press: Cambridge, MA, USA, 2016.
- Guo, C., He, Y., Wang, H., Jian, T., & Sun, S. Radar HRRP target recognition based on deep one dimensional residual-inception network. *IEEE Access*, 7, 2019, 9191–9204.
- Haykin, S. Cognitive radar: A way of the future. *IEEE Signal Process. Mag.* 2006, 23, 30–40.
- Kay, S.M. *Fundamentals of Statistical Signal Processing: Detection Theory*; Prentice Hall PTR: Hoboken, NJ, USA, 1998; Volume 2. Melvin, W.L.; Scheer, J.A. (Eds.) *Principles of Modern Radar*; SciTech Publishing: Raleigh, NC, USA, 2013.
- Kim, Y.; Keely, S.; Ghosh, J.; Ling, H. Application of Artificial Neural Networks to Broadband Antenna Design Based on a Parametric Frequency Model. *IEEE Trans. Antennas Propag.* 2007, 55, 669–674.
- LeCun, Y.; Bengio, Y.; Hinton, G. Deep Learning. *Nature* 2015, 521, 436–444.
- Liao, K.; Si, J.; Zhu, F.; He, X. Radar HRRP Target Recognition Based on Concatenated Deep Neural Networks. *IEEE Access* 2018, 6, 29211–29218.
- Liu, H.; Feng, B.; Chen, B.; Du, L. Radar high-resolution range profiles target recognition based on stable dictionary learning. *IET Radar Sonar Navig.* 2016, 10, 228–237.
- Long, T.; Liang, Z.; Liu, Q. Advanced technology of high-resolution radar: Target detection, tracking, imaging, and recognition. *Sci. China Inf. Sci.* 2019, 62, 1–26.
- Mason, E.; Yonel, B.; Yazici, B. Deep Learning for Radar. In *Proceedings of the 2017 IEEE Radar Conference*, Seattle, WA, USA, 8–12 May 2017.



- Pakravan, Payam, Pakravan, Pedram, Adaptive Spike Detector Architectures with Wavelet for Online Neural Spike Sorting on FPGA, 20th Iranian Student Conference on Electrical Engineering, Kermanshah, 2020.
- Pedram Pakravan, S.H.H. Sadeghi, Hossein Askarian Abyaneh, "Improvement of An Artificial Neural Network for Maximum Power Point Tracking of Photovoltaic Panels with Boost DC-DC Converter ", 33PSC – International Power System Conference, October 2018.
- Rawat, A.; Yadav, R.; Shrivastava, S. Neural network applications in smart antenna arrays: A review. *Int. J. Electron. Commun.* 2012, 66, 903–912
- Richards, M.A. *Fundamentals of Radar Signal Processing*, 1st ed.; McGraw-Hill: New York, NY, USA, 2005.
- Singhal, M.; Saini, G. Optimization of Antenna Parameters Using Artificial Neural Network: A Review. *Int. J. Comput. Trends Technol.* 2017, 44, 64–73.
- Xisto, L.T.; Sergio, L.A.; Nathan, I. Artificial Neural Networks and Machine Learning techniques applied to Ground Penetrating Radar: A review. *Appl. Comput. Inf.* 2018, 17, 296–308.