

ارائه یک روش برای شناسایی سیگنال رادار با احتمال شنود پایین مبتنی بر یادگیری عمیق

اسماعیل کوغانی^{۱*}، محمدحسین صداقی^۲

۱. دانشجوی دکتری، گروه مخابرات، دانشکده مهندسی برق، دانشگاه صنعتی تبریز، تبریز، ایران.

۲. استاد، گروه مخابرات، دانشکده برق دانشگاه صنعتی تبریز، تبریز، ایران.

تاریخ دریافت:

۲۱ آذر ماه ۱۴۰۴

تاریخ پذیرش:

۲۴ بهمن ماه ۱۴۰۴

چکیده

در این مقاله یک شبکه عصبی مناسب به منظور افزایش میزان شناسایی و طبقه‌بندی سیگنال‌های ساطع شده از اهداف نظامی طراحی شده است. در الگوریتم پیشنهادی روشی برای شناسایی سیگنال هدف مبتنی بر هوش مصنوعی ارائه شده است. پس از تولید دو مجموعه داده از سیگنال‌های رادار، پیش پردازش لازم به روش تبدیل زمان-فرکانس روی این داده‌ها انجام می‌گردد و تصاویر طیف نگار مربوط به این داده‌ها تولید می‌گردد. سپس با اعمال تصاویر مجموعه داده به مدل، فرآیند آموزش، اعتبارسنجی و آزمایش انجام می‌گردد. نتایج به‌دست آمده نشان می‌دهد، مدل طراحی شده به صورت خودکار و بهینه قادر به استخراج ویژگی‌های سیگنال رادار در سطوح مختلف می‌باشد، و با انتخاب بهترین و موثرترین ویژگی‌ها، موجب افزایش دقت و کاهش خطا در شناسایی و طبقه‌بندی سیگنال می‌گردد. دقت تشخیص اهداف بیش از ۹۷ درصد، خطای تشخیص در داده‌های آموزش ۲ درصد و در داده‌های اعتبارسنجی ۱ درصد است. با بهینه کردن دقت شناسایی، سرعت تشخیص اهداف به صورت قابل قبول افزایش یافته است.

واژه‌های کلیدی: هوش مصنوعی، یادگیری عمیق، شبکه های عصبی کانولوشن، فناوریهای نوظهور و بدیع.

Introducing a method for recognition of Low Probability of Interception Radar signals based on deep learning

Esmaeil Kogani¹, Mohammad Hosein Sedaagh²


1. Ph.D. Student, Department of Electrical Engineering, Sahand University of Technology, Tabriz, Iran.

2. Prof. Department of Electrical Engineering, Sahand University of Technology, Tabriz, Iran.

Abstract


In this paper, a suitable neural network is designed to increase the detection and classification of signals emitted from military targets. The proposed algorithm presents a novel method for target signal detection based on artificial intelligence. After generating two datasets of radar signals, the necessary preprocessing is performed on these data using the time-frequency transformation method and spectrograph images related to these data are generated. Then, by applying the dataset images to the model, the training, validation, and testing processes are performed. The results obtained show that the designed model is able to automatically and optimally extract radar signal features at different levels, and by selecting the best and most effective features, it increases the accuracy and reduces the error in signal detection and classification. The target detection accuracy is more than 97 percent, the detection error in the training data is 2 percent and in the validation data is 1 percent. By optimizing the detection accuracy, the target detection speed has increased acceptably.

Key words: Artificial Intelligence, Deep Learning, Convolutional Neural Networks, Emerging and Novel Technologies.



شکل (۱) گیرنده سیستم شنود الکترونیکی مبتنی بر یادگیری عمیق [۲۴]

یادگیری عمیق در زمینه پردازش تصویر موفقیت زیادی داشته و چون نمایش زمان-فرکانس ماهیت تصویر دارد، لذا ما امیدوار هستیم که بتوانیم به وسیله آن به توانمندی بالایی در زمینه تشخیص مدولاسیون سیگنال‌های رادار برسیم. الگوریتم‌های یادگیری عمیق زیرمجموعه‌ای از الگوریتم‌های یادگیری ماشین هستند که هدف آن‌ها استخراج خودکار ویژگی‌ها و کشف چندین سطح مختلف از ویژگی‌های توزیع شده در داده ورودی است، در حالی که در یادگیری ماشین استخراج ویژگی به صورت دستی انجام می‌گیرد [۳].



شکل (۲) تفاوت یادگیری ماشین و یادگیری عمیق در استخراج ویژگی [۳].

هدف نهایی این مقاله یافتن راه‌حل مناسب برای تشخیص مدولاسیون سیگنال‌های رادار در حوزه نظامی است. لذا قبل از بحث در مورد تشخیص مدولاسیون سیگنال‌های رادار، ابتدا اصطلاحات و تعاریف موردنیاز در مورد این سیگنال‌ها نظیر سیگنال رادارهای LPI را مورد بررسی قرار داده و سپس انواع این سیگنال‌ها را معرفی و در مرحله بعد بر روی مقالات انجام شده در خصوص تشخیص این نوع از سیگنال‌ها بحث و بررسی انجام می‌گردد. نهایتاً روش پیشنهادی این مقاله، در خصوص تشخیص مدولاسیون سیگنال‌های رادار با استفاده از مفهوم یادگیری عمیق^۴ ارائه خواهد شد. قبل از تشخیص سیگنال‌های رادار، لازم است بدانیم این سیگنال‌ها با توجه به نوع مدولاسیون به کاررفته دارای انواع مختلفی می‌باشند که این انواع شامل سیگنال

پیشرفت روزافزون و لحظه‌ای شاخه‌های فنی در علوم مهندسی منجر به گام نهادن به فناوری‌های بدیع و نوظهور و حرکت در این راستا گردیده است. بنابراین با ظهور رادارهای دارای فناوری‌های مدرن، همواره روش‌های جدیدی در حوزه پردازش سیگنال و تصویر موردنیاز است تا با استفاده از این روش‌ها، بتوان سیگنال‌های ساطع شده از این رادارها را تشخیص داده و در مراحل بعدی به کلاس‌بندی و استخراج مشخصات آن‌ها پرداخت. با پیدایش رادار در جنگ جهانی دوم، تحقیقاتی در زمینه ناکارآمد کردن آن انجام گرفت. بنابراین گیرنده‌های شنود مختلفی برای آشکارسازی و استخراج پارامترهای سیگنال رادار، مورد استفاده قرار گرفت. در طول دهه‌های گذشته برای غلبه بر آشکارسازی و استخراج پارامترهای سیگنال رادار، فناوری جدیدی به نام رادارهای LPI^۱ به وجود آمد. طبیعت پهنای باند زیاد سیگنال‌های LPI، چالشی آشکار در برابر طراحی گیرنده‌های رهگیر ایجاد می‌کند. لذا گیرنده‌های رهگیر جنگ الکترونیک به منظور تحلیل تهدیدات در میدان جنگ‌های امروزی باید پهنای باند وسیعی در حدود ۳۰۰ مگاهرتز تا ۱۰۰ گیگاهرتز و بالاتر را پوشش دهند. جداسازی و شناسایی پالس‌های رادار یکی از وظایف مهم در سامانه‌های پشتیبانی الکترونیک می‌باشد. در این حوزه، سرعت عملکرد در جداسازی و همچنین قابلیت کشف انواع اهداف موجود در محیط از اهمیت زیادی برخوردار است. در سامانه‌های سنتی، رادارها یا به روش خطی عمل نموده که با استفاده از فیلترهای تطبیقی و به کارگیری دو سطح آستانه تصمیم‌گیری برای شناسایی اهداف عمل می‌نمایند و در نتیجه آشکارسازی هدف با دقت کمتری انجام می‌گردد و یا به صورت نیمه خطی عمل نموده و تعداد اهداف محدود با دقت متوسط رو به پایین را آشکارسازی می‌نمایند. به دلیل فناوری خاص رادارهای LPI، این رادارها دارای توان ارسالی پائین، پهنای باند و فرکانس متغیر می‌باشند. لذا به دست آوردن مشخصات این نوع از سیگنال‌ها، برای گیرندگان جنگ الکترونیک از جمله رادارهای هشدار و گیرنده‌های هوشمند الکترونیکی مشکل ساز است. به عبارتی دیگر شناسایی سیگنال رادارهای LPI نیازمند استفاده از روش‌های جدید نظیر شبکه‌های عصبی عمیق^۲ در حوزه پردازش سیگنال و پردازش تصویر برای آشکارسازی، شناسایی و استخراج مشخصات این نوع از سیگنال‌ها است [۳۵].

هدف یادگیری عمیق استخراج ویژگی‌ها^۳ به صورت هوشمند طی یک مرحله یادگیری است. تلاش‌ها در این زمینه (خصوصاً ساخت یک ماشین آموزش‌پذیر با استفاده از شبکه‌های عصبی) تا قبل از سال ۲۰۰۶ موفقیت‌آمیز نبود. از این سال به بعد تلاش‌ها امیدوارکننده‌تر بود؛ به عنوان مثال یک گروه گوگل در سال ۲۰۱۲ شبکه عصبی‌ای را طراحی کردند که یاد می‌گیرد مفاهیم سطح بالاتر را نیز تشخیص دهد.

³ Feature Extraction

⁴ Deep Learning


¹ Low Probability of Interception Radar

² Deep Neural Network

ماشین دارند. شبکه‌های عصبی سنتی فقط شامل ۲ یا ۳ لایه پنهان هستند، در صورتی که شبکه‌های عمیق می‌توانند بیش از ۱۵۲ لایه داشته باشند [۱۴]. یادگیری عمیق بر مبنای مجموعه‌ای از الگوریتم‌ها است که ویژگی‌های سطح بالا در داده‌ها را با استفاده از یک شبکه عمیق که شامل چندین لایه پردازشی است، مدل‌سازی می‌کند. بدین صورت که داده‌های سطح پایین را در هر لایه دریافت می‌کند، آنها را پردازش کرده و در نتیجه داده‌های سطح بالاتر را به دست می‌آورد. بدین ترتیب، برای به دست آوردن اطلاعات مورد نیاز ماشین، لزومی به نظارت کامل انسان در هر لحظه نیست. در این حوزه، شبکه‌ها و معماری‌های مختلفی وجود دارد که از جمله این شبکه‌ها می‌توان به شبکه عصبی عمیق^{۱۳}، شبکه باور عمیق^{۱۴}، شبکه عصبی بازگشتی^{۱۵}، شبکه عصبی کانولوشنی^{۱۶} CNN شبکه باقیمانده^{۱۷} GAN،^{۱۸} ResNet و غیره اشاره کرد.

۲-۲- انواع لایه‌های شبکه CNN

در حالت کلی شبکه عصبی کانولوشنی یک شبکه عصبی سلسله مراتبی است که لایه‌های کانولوشن آن به صورت یک‌درمیان با لایه‌های ادغام^{۱۹} قرار دارند. پس از لایه ادغام لایه‌های تماماً متصل^{۲۰} وجود دارد (شکل ۳) [۱۴].



شکل (۳) نمونه معماری شبکه عصبی کانولوشنی

۱-۲-۲- لایه کانولوشن

شبکه عصبی کانولوشن از فیلترهای مختلف برای کانالو کردن تصویر ورودی و ایجاد نقشه ویژگی^{۲۱} استفاده می‌کند و بدین ترتیب نقشه‌های ویژگی مختلفی همانند آنچه در شکل ۴ مشاهده می‌کنید، ایجاد می‌شود.

FM^۱ خطی و غیرخطی (LFM^۲, NLFM^۳)، سیگنال PSK^۴: فرانک^۵، کدهای فازی (P1, P2, P3, P4)، کدهای زمانی (T1, T2, T3, T4)، سیگنال FSK^۶ شامل کدهای کاستاس^۷ و در نهایت سیگنال حاصل ترکیب دو مدولاسیون PSK و FSK می‌باشند [۱]. در این مقاله ابتدا پیش‌پردازشی بر روی داده‌های ورودی به عمل می‌آید. در این پیش‌پردازش سیگنال‌های ورودی با استفاده از تبدیل زمان-فرکانس مورد تجزیه و تحلیل قرار گرفته و خروجی این بخش به صورت یک تصویر به منظور شناسایی نوع هدف به شبکه عصبی کانولوشنی (CNN) که یکی از انواع شبکه عصبی عمیق است، داده می‌شود. سپس با تحلیل‌های مبتنی بر یادگیری عمیق پارامترهای بهینه سیستم استخراج و در ادامه کلاس‌بندی سیگنال‌ها به منظور شناسایی اهداف توسط شبکه انجام می‌شود. هدف اصلی از انجام این پژوهش، تشخیص صحیح سیگنال رادار است که خود می‌تواند به افزایش قابلیت کشف و شناسایی تهدیدات و متعاقب آن، حفظ و بقای تجهیزات و نیروی انسانی کمک کند.

۲- مبانی نظری

۱-۲- یادگیری عمیق

یادگیری عمیق، زیرمجموعه‌ای از یادگیری ماشین^۸، مبتنی بر شبکه‌های عصبی مصنوعی^۹ بوده که از عملکرد سلول‌های مغز انسان به نام ساختار عصبی الهام می‌گیرد. در یادگیری عمیق، ضروری نیست همه چیز آموزش داده شود. الگوریتم‌های یادگیری عمیق را می‌توان به روش‌های یادگیری نظارت‌شده^{۱۰}، نیمه نظارت‌شده^{۱۱} و بدون نظارت^{۱۲} تقسیم‌بندی نمود. روش یادگیری نظارت‌شده بر مبنای آموزش یک مدل با استفاده از داده‌های دارای برچسب‌های صحیح که از قبل طبقه‌بندی شده‌اند، به منظور دستیابی به یک مدل، ایجاد شده است، به گونه‌ای که وقتی داده‌های جدید به این ساختار وارد می‌شوند، این مدل می‌تواند نوع خروجی‌ها را به راحتی تخمین بزند. توابع یادگیری بدون نظارت برای یک مجموعه داده بدون برچسب، می‌تواند مدلی را آموزش دهد که بدون اطلاع از سیگنال‌های در نظر گرفته شده برای ارزیابی مدل، اطلاعات موجود در داده را بررسی و طبقه‌بندی صحیحی را انجام دهد. استفاده از الگوریتم‌های یادگیری عمیق این روزها به طور گسترده افزایش یافته است. این روش، با تحلیل حجم زیادی از داده‌ها، بسیار عالی کار می‌کند. تکنیک‌های یادگیری عمیق عملکرد بهتر و دقت بیشتری نسبت به سایر تکنیک‌های یادگیری

¹² Unsupervised

¹³ Deep Neural Network (DNN)

¹⁴ Deep Belief Network

¹⁵ Recurrent Neural Network

¹⁶ Convolution Neural Network

¹⁷ Residual Network

¹⁸ Generative Adversarial Network

¹⁹ Pooling

²⁰ Fully Connected Layers

²¹ Feature Map

¹ Frequency modulation

² Linear Frequency modulation

³ Non Linear Frequency modulation

⁴ Phase-shift keying

⁵ Frank

⁶ Frequency shift keying


⁷ Costas

⁸ Machine Learning


⁹ Artificial Neural Networks (ANN)

¹⁰ Supervised

¹¹ Semi-Supervised



شکل (۵) عملیات لایه ادغام پیشینه




شکل (۴) تولید نقشه ویژگی در لایه کانولوشن

۲-۲-۳- لایه تماماً متصل

بعد از آخرین لایه ادغام همان طور که در شکل ۶ مشاهده می شود، لایه های تماماً متصل وجود دارند که نقشه ویژگی های دوبعدی را به بردارهای ویژگی یک بعدی جهت ادامه فرآیند بازنمایی ویژگی ها^۶ تبدیل می کنند. لایه های تماماً متصل همانند هم تانایان خود در شبکه های عصبی مصنوعی سنتی عمل می کنند و بیشتر پارامترهای شبکه CNN را شامل می شوند.

لایه تماماً متصل به ما اجازه می دهد تا نتیجه شبکه را در قالب یک بردار با اندازه مشخص ارائه کنیم.



شکل (۶) عملیات لایه های تماماً متصل که بعد از آخرین لایه ادغام قرار گرفته اند

ما می توانیم از این بردار برای دسته بندی داده ها استفاده کنیم و یا اینکه از آن، جهت ادامه پردازش های بعدی بهره ببریم.

۳- پیشینه پژوهش

در سالهای اخیر، هوش مصنوعی به عنوان روشی مبتنی بر یادگیری ذهنی به کانون تحقیقات دفاعی و نظامی تبدیل شده است. در [۲] روشی برای شناسایی و رتبه بندی فناوری های اطلاعاتی نوظهور در عرصه دفاعی نظامی ارائه شده است. یادگیری عمیق نه تنها می تواند به طور خودکار ویژگی هایی را از سیگنال خام بیاموزد، بلکه می تواند استخراج ویژگی های عمیق تر و حتی ترکیب ویژگی ها را بر اساس برخی از پارامترهای ویژگی سطح بالا انجام دهد. در [۵] تحقیقی باهدف بررسی تأثیر تبدیل ویگنر-ویل هاف بر روی آشکارسازی سیگنال های LPI از نوع FMCW انجام شده است. هدف از به کارگیری تبدیل

انجام عملیات کانولوشن سه مزیت عمده دارد:

- ۱- مکانیزم اشتراک وزن در هر نقشه ویژگی باعث کاهش شدید تعداد پارامترها می شود.
- ۲- اتصال محلی، ارتباط بین پیکسل های همسایه را یاد می گیرد.
- ۳- باعث تغییرناپذیری و ثبات نسبت به تغییر مکان شی می شود.

به واسطه فواید معرفی شده توسط عملیات کانولوشن، بعضی از مقالات روش هایی جهت جایگزینی لایه های تماماً متصل استفاده کردند تا با این کار سرعت فرآیند یادگیری را افزایش دهند. یکی از روش های جالب مدیریت لایه های کانولوشن روش NIN^۱ است که در آن ایده اصلی جایگزینی لایه کانولوشن با یک شبکه عصبی پرسپترون کوچک است که شامل چندین لایه تماماً متصل با توابع فعال سازی غیرخطی است. به این ترتیب فیلترهای خطی با شبکه های عصبی غیرخطی جایگزین می شوند. این روش باعث به دست آوردن نتایج خوبی در دسته بندی تصاویر می شود.

۲-۲-۲- لایه ادغام

لایه ادغام معمولاً بعد از لایه های کانولوشن قرار می گیرد و از آن برای کاهش اندازه نقشه های ویژگی و پارامترهای شبکه می توان استفاده کرد. همانند لایه های کانولوشن، لایه های ادغام به خاطر در نظر گرفتن پیکسل های همسایه در محاسبات خود نسبت به تغییر مکان^۲ پایدار هستند. پیاده سازی لایه ادغام با استفاده از توابع ادغام پیشینه^۳ و ادغام میانگین^۴ رایج ترین پیاده سازی ها هستند. در شکل ۵ می توان نمونه ای از فیلتر ادغام پیشینه را مشاهده کرد. با استفاده از این فیلتر با اندازه 2×2 و اندازه گام^۵ دو، نقشه ویژگی با اندازه 8×8 خروجی با اندازه 4×4 را ایجاد می کند.

⁴ Average Pooling

⁵ Stride

⁶ Feature Representation

¹ Network in Network

² Translation

³ Max Pooling

ویگنر-ویل هاف در این تحقیق به حداقل رساندن اثرات منفی توزیع ویگنر-ویل در زمان تبدیل و بهبود بخشیدن در پیاده‌سازی سخت‌افزاری برای تبدیل ویگنر-ویل می‌باشد، و اجرای این برنامه باعث پائین آمدن میزان محاسبات می‌شود. در [۱۰] با آموزش یک شبکه عصبی کانولوشنی و عمیق تا $1/2$ میلیون تصویر با وضوح بالا را در مسابقه ImageNet LSVRC-2010^۱ شرکت داده و در ۱۰۰۰ کلاس مختلف طبقه‌بندی کرده‌اند. نویسندگان در تست‌های مرتبه اول و پنجم به نرخ‌های خطای $37/5$ درصد و 17 درصد رسیده‌اند که به‌طور قابل توجهی بهتر از آخرین وضعیت تا آن زمان بوده است. در [۲۰] تأثیر عمق شبکه کانولوشنی بر دقت آن در تنظیمات تشخیص تصویر را بررسی نموده‌اند. ایده اصلی این تحقیق، ارزیابی کامل شبکه‌های افزایش عمق با استفاده از معماری با فیلترهای کانولوشن بسیار کوچک 3×3 است که نشان می‌دهد با افزایش عمق به 16 الی 19 لایه می‌توان به بهبود قابل توجهی در پیکربندی‌های قبلی دست یافت. در [۲۱] یک معماری شبکه عصبی کانولوشنی عمیق با اسم رمز Inception ارائه و پیشنهاد شده است که مشخصه اصلی این معماری استفاده بهتر از منابع محاسباتی داخل شبکه است. در این مقاله ایده خاصی که در ارسال برای ILSVRC14 استفاده می‌شود، GoogLeNet نام دارد. یک شبکه عمیق 22 لایه که کیفیت آن در زمینه طبقه‌بندی و شناسایی ارزیابی می‌شود. در [۳] یک بررسی جامع و ساختار یافته در مورد کاربرد الگوریتم‌های مبتنی بر یادگیری عمیق (DL)، مانند شبکه‌های عصبی کانولوشنی (CNN) و حافظه طولانی کوتاه‌مدت (LSTM^۲)، در پردازش سیگنال رادار ارائه شده است. در [۲۸] عملکرد طبقه‌بندی سیگنال در طبقه‌بندکننده‌های مختلف برای سیگنال‌های قطعی تحت نویز گاوسی سفید افزودنی (WGN^۳) در طیف وسیعی از سطوح نسبت سیگنال به نویز تجزیه و تحلیل شده است. در [۱] یک مجموعه داده بزرگ با 58 منبع انتشار مجزا برای آموزش و آزمایش استفاده شده است. ثابت شده است که نمایش تصویر مؤثر است و به‌طور مداوم دقت طبقه‌بندی را نزدیک به 98 درصد ایجاد می‌کند.

در [۱۲] به‌منظور غلبه بر مشکل نرخ تشخیص کم به علت نوع سیگنال ضعیف رادار LPI در نسبت سیگنال به نویز -6db ، روشی مبتنی بر توزیع شبه ویگنر-ویل صاف ($SPWVD^4$) برای تجزیه و تحلیل زمان-فرکانس سیگنال و یک مدل شبکه عصبی پیچیده عمیق AlexNet برای طبقه‌بندی سیگنال رادار LPI ارائه شده است. نتایج شبیه‌سازی نشان می‌دهد که نرخ تشخیص صحیح کلی (CRR^5) سیگنال‌های رادار $92/5$ درصد در -6 دسی‌بل است که بالاتر از روش‌های مشابه تا آن زمان است. در [۱۵] یک روش تلفیق ویژگی عمیق با وضوح چندگانه برای تشخیص شکل موج رادار LPI پیشنهاد شده است. آزمایش‌های شبیه‌سازی روی دوازده نوع شکل موج رادار LPI نشان می‌دهد که دقت تشخیص روش می‌تواند در سیگنال به

نویز -8 دسی‌بل به $95/2$ درصد برسد. این رویکرد در واقع دقت تشخیص را به‌طور مؤثر در SNR های پایین بهبود می‌بخشد. در [۱۳] یک روش تشخیص خودکار برای مدولاسیون‌های مختلف سیگنال رادار LPI پیشنهاد می‌شود. شبیه‌سازی نشان می‌دهد که نرخ تشخیص صحیح می‌تواند به 94% در -10 دسی‌بل برسد و روش پیشنهادی دارای قابلیت تشخیص مدولاسیون‌های مختلف سیگنال رادار LPI، حتی تحت SNR کم است. در [۱۹] الگوریتمی ارائه شده است که با استفاده مجدد از ویژگی و استخراج ویژگی‌های دقیق، موجب بهبود عملکرد تشخیص شکل موج رادار در SNR پائین می‌گردد.

در [۲۹] رابطه مصالحه بین دقت طبقه‌بندی و زمان تشخیص سیگنال‌های رادار را با استفاده از طیف‌نگار، توزیع ویگنر-ویل (WVD) و چوی-ویلیامز (CWD) نشان داده‌اند. در نتیجه، مدل CWD دقت بالاتری نسبت به مدل WVD دارد، اما زمان پیش‌بینی بیش از 200 برابر بیشتر است. تفاوت دقت برای SNR بیش از -2 دسی‌بل تنها 1% است، اما برای SNR حدود -10 دسی‌بل به $7/5$ درصد رسیده است. بنابراین، SNR کمتر، بسته به نوع TFA، یک مصالحه بین زمان پیش‌بینی و دقت را نشان می‌دهد. در [۲۷] از یک روش تشخیص تداخل از تفاوت در نتایج تبدیل فوریه سریع یک بعدی (1D-FFT) بین اهداف و تداخل استفاده کرده‌اند. بنابراین سیگنال تداخل بدون تأثیر بر سیگنال هدف از حوزه زمان حذف می‌گردد و نتایج تجربی نشان می‌دهد که دامنه تداخل $20-25$ دسی‌بل کاهش می‌یابد. در [۲۲] یک الگوریتم تشخیص سیگنال رادار LPI را بر اساس همبستگی خودکار و لحظات مبتنی بر تصویر فرکانس زمانی ارائه شده است. نویسنده نشان داده است، تشخیص درست، نیازی به اطلاعات قبلی در مورد سیگنال‌های رادار ندارد. عملکرد تشخیص برای انواع مختلف شکل موج سیگنال رادار LPI مورد مطالعه قرار گرفته است. نتایج نشان داد که تشخیص تحت SNR پایین امکان‌پذیر است. در [۱۸] یک روش تشخیص سیگنال رادار LPI مبتنی بر بهبود ویژگی با یادگیری متریک عمیق را پیشنهاد داده‌اند. نتایج این مقاله نشان می‌دهد که در مقایسه با سایر روش‌های پایه، دقت تشخیص قابل توجهی را تحت نسبت سیگنال به نویز کم به دست می‌آورد. هنگامی که نسبت سیگنال به نویز -10 دسی‌بل است، نرخ تشخیص موفقیت آمیز برای دوازده سیگنال LPI معمولی به $94/38\%$ می‌رسد.

در [۹] با بهره‌گیری از توزیع چوی ویلیامز تصاویر زمان-فرکانس سیگنال را استخراج و سپس با استفاده از شبکه عصبی سه طبقه به شناسایی ویژگی سیگنال‌های اهداف پرداخته می‌شود. نتایج شبیه‌سازی نشان می‌دهد که به دقت تشخیص بیش از 98 درصد در سیگنال به نویز صفر دسی‌بل و عملکرد بهتری نسبت به سایر مدل‌های عمیق رسیده‌اند.

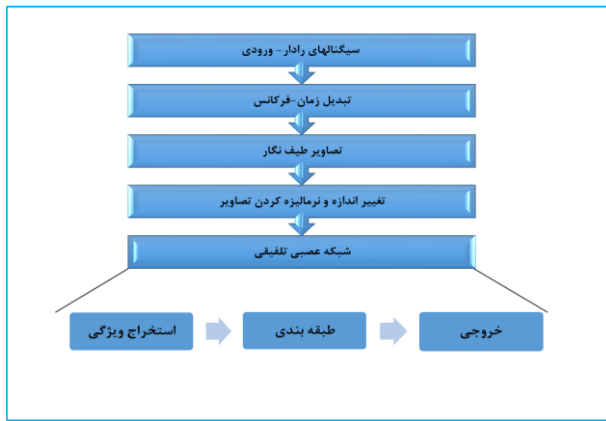
⁴ Smooth Pseudo Wigner-Ville Distribution

⁵ Cognitive Radar Radio

¹ ImageNet Large Scale Visual Recognition Challenge

² Long Short-Term Memory

³ White Gaussian Noise



شکل (۷) مدل پیشنهادی برای شناسایی سیگنال‌های دریافتی از اهداف

دقت شبکه عصبی در طبقه‌بندی به انتخاب ابر پارامترهای مناسب نظیر اندازه و تعداد فیلترها در لایه‌های کانولوشن، تابع فعال‌سازی و تابع زیان و همچنین کیفیت تصحیح وزن‌ها در طول فرآیند یادگیری شبکه بستگی دارد. در ادامه نتایج به‌دست‌آمده از شبیه‌سازی ارائه خواهد شد و میزان کارایی و عملکرد شبکه بررسی گردیده و با سایر تحقیقات مشابه، مقایسه می‌گردد. نتایج به‌دست‌آمده از دقت شبکه در قالب ماتریس پیچیدگی^۲ مورد بررسی قرار می‌گیرد. تهیه مجموعه داده و انجام پیش‌پردازش روی داده لازمه پیشبرد و تکمیل این پژوهش می‌باشد. یکی از چالش‌های بکارگیری هوش مصنوعی در انجام طرح‌های تحقیقاتی، کمبود مجموعه داده، مخصوصاً در حوزه نظامی می‌باشد. همانگونه که می‌دانیم در این مقاله تحقیق در حوزه پردازش سیگنال رادار می‌باشد و بعلاوه ماهیت دفاعی پروژه، سیگنال رادار برای آموزش شبکه عصبی عمیق در دسترس نبوده، لذا به همین منظور برای انجام پژوهش پیش‌رو ناچار به تولید سیگنال رادار هستیم. با توضیحات بعمل آمده، اقدام به تولید دو سیگنال رادار با تکیه بر رادارهای با احتمال شوند پایین (LPI) مطابق پارامترهای این سیگنال شده است. پرواضح است که شبکه عصبی طراحی شده در مقاله می‌تواند در آینده در راستای بکارگیری و بهره‌وری در کاربردهای مدنظر، سفارشی شده و سیگنال‌های مدنظر را شناسایی نماید. پس از تولید سیگنال‌های FMCW و BPSK لازم است پیش‌پردازشی مبتنی بر تحلیل زمان-فرکانس روی این سیگنال‌ها صورت پذیرد تا قابلیت اعمال به شبکه عصبی عمیق را داشته باشند، و شبکه عصبی طراحی شده مورد تست و ارزیابی قرار بگیرد. در ادامه به شرح اقدامات انجام شده به صورت تفصیلی پرداخته می‌شود.

جدول (۱) مدل‌های مطرح CNN به همراه بیکربندی و دستاوردهای

هریک در مسابقات ILSVRC


دستاورد	بیکربندی	مقام	سال	روش
معماری مهمی که باعث علاقه بسیاری از محققان در زمینه بینایی کامپیوتر شد	۵ لایه کانولوشن + ۳ لایه تماماً متصل	اول	۲۰۱۲	AlexNet
باعث شد تا اتفاقاتی که در داخل شبکه رخ می‌دهد قابل دیدن باشند	۵ لایه کانولوشن + ۳ لایه تماماً متصل	اول	۲۰۱۳	Clarifai
با ارائه spatial pyramid pooling محدودیت اندازه تصاویر را از میان برداشت	۵ لایه کانولوشن + ۳ لایه تماماً متصل	سوم	۲۰۱۴	SPP
ارزیابی کاملی از شبکه با عمق افزایشی	۱۳-۱۵ لایه کانولوشن + ۳ لایه تماماً متصل	دوم	۲۰۱۴	VGG
افزایش عمق و عرض شبکه را بدون افزایش نیازمندی‌های محاسباتی	۲۱ لایه کانولوشن + ۱ لایه تماماً متصل	اول	۲۰۱۴	GoogLeNet
افزایش عمق شبکه و ارائه روشی جهت جلوگیری از اشباع‌شدگی گرادینت	۱۵۲ لایه کانولوشن + ۱ لایه تماماً متصل	اول	۲۰۱۵	ResNet

۴- طرح پیشنهادی


در طرح پیشنهادی با استفاده از الگوریتم‌های یادگیری عمیق که یکی از روش‌های جدید و کارا در حوزه پردازش سیگنال و تصویر می‌باشد، چگونگی آشکارسازی و تشخیص انواع اهداف راداری بررسی خواهد شد. به همین منظور ابتدا پیش‌پردازشی بر روی داده‌های ورودی به عمل می‌آید. در این پیش‌پردازش ابتدا پنجره‌گذاری روی سیگنال‌های ورودی به‌عمل آمده، سپس با استفاده از تبدیل فوریه زمان-کوتاه (STFT^۱) مورد تجزیه و تحلیل قرار گرفته و خروجی این بخش (خروجی زمان-فرکانس از سیگنال) به‌صورت یک تصویر به‌منظور شناسایی نوع هدف به شبکه عصبی کانولوشنی داده می‌شود. سپس با تحلیل‌های مبتنی بر یادگیری عمیق پارامترهای بهینه سیستم استخراج و در ادامه کلاس‌بندی سیگنال‌ها به‌منظور تشخیص سیگنال اهداف توسط شبکه انجام می‌شود.

¹ Short-Time Fourier Transform


داده‌های طیف‌نگار و نرخ یادگیری اولیه 0.001 آموزش داده شده است. دقت و تابع هزینه مدل برای داده‌های آموزشی و داده‌های اعتبارسنجی به‌دست آمده است. مدل‌های مبتنی بر شبکه‌های کانولوشنی در دو مرحله حرکت روبه‌جلو^۷ و پس‌انتشار^۸ آموزش داده می‌شوند. ویژگی‌های سطح پایین و سطح بالا که در داده‌های تزریق شده به مدل وجود دارد، توسط فیلترهای بهینه‌شده در مرحله پس انتشار استخراج می‌گردند. برای هر کلاس، فیلترها مهم‌ترین نواحی را برای تشخیص تصاویر طیف‌نگار مربوط به آن کلاس نشان می‌دهد. در نتیجه، دقت نهایی مدل اصلاح‌شده پیشنهادی توسط فیلترها یا ویژگی‌های استخراج‌شده از لایه‌های مختلف مدل تعیین می‌گردد و تصویرسازی فیلترها به‌منظور ارزیابی عملکرد مورد استفاده قرار می‌گیرد. معمولاً فیلترهای لایه اول ویژگی‌های رنگی و لبه‌های جهت‌دار موجود در تصاویر طیفی را جداسازی و تفکیک می‌کنند. فیلترهای میانی بافت‌های به‌وجود آمده از همپوشانی رنگ‌های مختلف و لبه‌ها را شناسایی و نشان‌گذاری می‌کنند. بدین ترتیب الگوهای خاصی از جهت‌گیری و رنگ‌بندی مربوط به طیف‌نگارهای کلاس‌های مختلف توسط فیلترهای لایه‌های پایانی کانولوشنی مدل پیشنهادی استخراج می‌شوند. نتایج به‌دست‌آمده نشان می‌دهد که استفاده از روش‌های یادگیری عمیق منتج به نتایج مطلوبی در شناسایی صحیح اهداف و کاهش تشخیص اشتباه می‌گردد. نتایج ارزیابی مدل نشان می‌دهد که مدل ارائه‌شده کارایی لازم جهت تشخیص و طبقه‌بندی کلاس‌های اهداف را دارد. در طراحی مدل CNN، معماری ساخت مدل بدین شکل صورت می‌پذیرد که اولین لایه از کانولوشن را برای استخراج ویژگی از تصویر ورودی اضافه کرده و تابع ReLU (3×3) را برای تولید ویژگی‌های کانوالو شده به کار می‌بریم. لایه بعدی یک لایه ادغام با فیلتر 2×2 پیکسل برای بدست آوردن بزرگ‌ترین عنصر از نگاشت ویژگی‌ها خواهد بود. مانند لایه قبلی، یک لایه دیگر کانولوشن و ادغام ایجاد می‌کنیم. سپس در تکمیل معماری مدل لایه‌های صاف‌کننده، حذف تصادفی و خروجی را به آن اضافه می‌نماییم. با استفاده از تابع هزینه^۹ و بهینه‌ساز آدام^{۱۰}، دقت مدل محاسبه می‌گردد.



شکل (۱۰) دیاگرام شبکه عصبی کانولوشن در طرح پیشنهادی



شکل (۸) تبدیل زمان-فرکانس سیگنال FMCW



شکل (۹) تبدیل زمان-فرکانس سیگنال BPSK

پس از تولید دو نوع از سیگنال‌های پر کاربرد رادار به شرح گفته شده و انجام پیش پردازش روی این نمونه‌ها، سیگنال‌های مذکور را به عنوان مجموعه دیتا ذخیره می‌نماییم. در مراحل بعد پس از وارد کردن نمونه‌های آموزشی این سیگنال‌ها به شبکه عصبی و اصطلاحاً آموزش شبکه، نمونه‌های آزمایشی را به شبکه اعمال نموده و کارایی شبکه را با نمونه‌های اعتبارسنجی مورد سنجش قرار می‌دهیم. پس از تصحیح وزنهای لایه‌های مختلف شبکه، به شناسایی و تفکیک اهداف راداری می‌پردازیم.

۴-۱- یافته‌ها و تجزیه و تحلیل داده‌ها

طراحی شبکه عصبی، با استفاده از برنامه پایتون و کتابخانه کراس با پس‌زمینه تانسورفلو انجام می‌گیرد. از شبکه عصبی کانولوشن در طبقه‌بندی دو کلاس از تصاویر در اندازه‌های 128×128 استفاده می‌شود. تعداد 10000 تصویر شامل تصاویری از دو کلاس هدف یا همان BPSK و غیرهدف یا همان FMCW تولید که 70% از این داده‌ها برای آموزش^۱، 20% برای اعتبارسنجی^۲ و 10% برای آزمایش^۳ استفاده شده است. در مرحله بعد پس از وارد نمودن کتابخانه‌های موردنیاز اندازه تصویر، تعداد تکرار^۴، دسته‌بندی^۵ و مسیر داده‌های آموزشی و اعتبارسنجی را تعیین و هر کدام را به محیط برنامه معرفی می‌کنیم. مدل مورد استفاده در این پژوهش در 52 تکرار با استفاده از بهینه‌ساز نزولی گرادیان تصادفی^۶ با اندازه دسته‌های 62 تایی از

⁶Stochastic Gradient Descent Optimizer

⁷ Feed-Forward

⁸ Back-Propagation

⁹ Categorical Crossentropy

¹⁰ adam optimizer

¹Training

² Validation

³ Test

⁴ epochs

⁵ batch_size

جدول (۲) نمایش مقادیر دقت، صحت، بازیابی و امتیاز F1 در مدل طراحی شده

	دقت	صحت	امتیاز F1	بازیابی
هدف	۰/۹۵	۰/۹۴	۰/۹۷	۰/۹۸
غیر هدف	۰/۹۸	۰/۹۶	۰/۹۵	۰/۹۲

معادلات ارزیابی از طریق روابط زیر قابل محاسبه می‌باشند:

$$(۱) \text{ دقت} = \frac{\text{تعداد منفی صحیح} + \text{تعداد مثبت صحیح}}{\text{مجموع داده ها}}$$

$$(۲) \text{ صحت} = \frac{\text{تعداد مثبت صحیح}}{\text{تعداد مثبت کاذب} + \text{تعداد مثبت صحیح}}$$

$$(۳) \text{ بازیابی} = \frac{\text{تعداد مثبت صحیح}}{\text{تعداد منفی کاذب} + \text{تعداد مثبت صحیح}}$$

$$(۴) \text{ امتیاز F1} = 2 \times \frac{\text{بازیابی} \times \text{دقت}}{\text{بازیابی} + \text{دقت}}$$

$$(۵) \text{ نرخ مثبت صحیح} = \frac{\text{تعداد مثبت صحیح}}{\text{تعداد منفی کاذب} + \text{تعداد مثبت صحیح}}$$


$$(۶) \text{ نرخ مثبت کاذب} = \frac{\text{تعداد مثبت کاذب}}{\text{تعداد مثبت کاذب} + \text{تعداد منفی صحیح}}$$

ارزیابی بدین صورت انجام می‌گیرد که پس از اعمال داده‌های آزمایشی به مدل پیشنهادی، تعداد داده‌هایی که به درستی تشخیص داده شده‌اند، به عنوان معیار مثبت صحیح، داده‌هایی که به اشتباه شناسایی شده‌اند، مثبت کاذب، داده‌هایی که به درستی رد شده‌اند، منفی صحیح و داده‌هایی که به اشتباه رد شده‌اند، منفی کاذب در نظر گرفته شده و شمارش می‌شوند. با استفاده از این دسته‌بندی، معیارهای معرفی شده برای ارزیابی مدل‌های پیشنهادی مورد استفاده قرار می‌گیرند. هدف یافتن بالاترین نرخ مثبت واقعی^۷ (TPR) و کمترین نرخ مثبت کاذب^۸ (FPR) می‌باشد. با استفاده از ماتریس پریشانی^۹ (پیچیدگی) میزان اطمینان و صحت طبقه‌بندی در کلاس‌های مختلف را مشخص می‌نماییم. در پایان با استفاده از منحنی ROC^{۱۰} به ارزیابی عملکرد مدل طبقه‌بندی خواهیم پرداخت.


جدول (۳) نمایش کلی ماتریس پیچیدگی

کلاس واقعی	کلاس پیش بینی شده	
	هدف	غیر هدف
هدف	مثبت صحیح	منفی کاذب
	غیر هدف	مثبت کاذب

در ادامه به منظور بارگذاری داده، داده‌های آموزش و اعتبارسنجی را در گروه‌بندی چند دسته‌ای و با سایز بسته‌های مشخص (۱۰۰ تصویر انتخاب شده به صورت تصادفی از سرتاسر کلاس‌ها در مجموعه داده) به شبکه اعمال می‌نماییم. سپس، از یک تابع تکرار برای بارگذاری تدریجی داده‌ها در مجموعه داده استفاده می‌کنیم. دقت^۱ و هزینه^۲ مدل را هم برای داده‌های آموزشی و هم برای داده‌های اعتبارسنجی بدست می‌آوریم. نمودار تابع هزینه و دقت مدل در تکرارهای مختلف در شکل ۱۰ نشان داده شده است. مشاهده می‌شود با افزایش تکرارها، دقت مدل افزایش پیدا کرده و هزینه مدل کاهش می‌یابد.



شکل (۱۱) نمودار نمایش دقت در ارزیابی طرح پیشنهادی



شکل (۱۲) نمودار نمایش زیان در ارزیابی طرح پیشنهادی

با استفاده از داده‌های آزمایشی، مدل ذخیره شده را مورد آزمایش قرار می‌دهیم. عملکرد الگوریتم با پارامترهایی مانند صحت^۳، دقت^۴، بازیابی^۵ و امتیاز F1^۶ ارزیابی می‌شود.

^۶ F1-Score

^۷ True Positive Rate

^۸ False Positive Rate

^۹ Confusion Matrix

^{۱۰} Receiver Operating Characteristics

^۱ accuracy

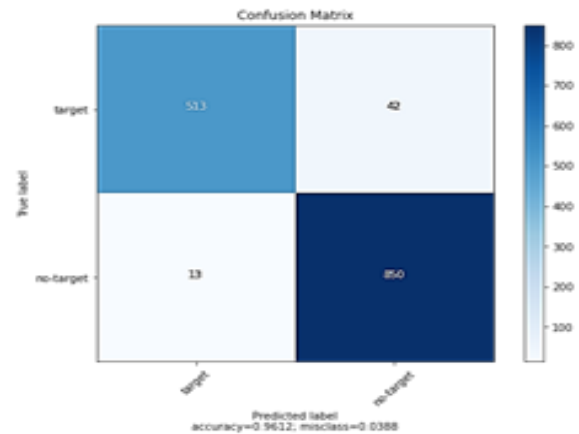
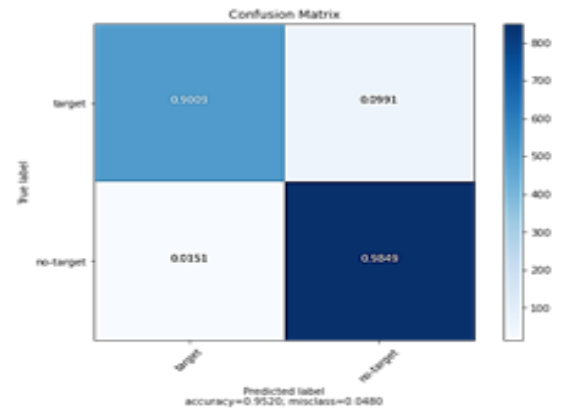


^۲ Loss

^۳ Accuracy

^۴ Precision



^۵ Recall

نمودار ROC مشخص می‌شود تشخیص درست اهداف به خوبی صورت نمی‌گیرد و ارزیابی مدل به درستی انجام نمی‌شود.



شکل (۱۵) نمودار زیان و دقت مدل در شناسایی هدف پس از کاهش مجموعه داده به نصف

شکل (۱۳) نمایش مقادیر ماتریس پیچیدگی مربوط به داده‌های آزمایش در مدل پیشنهادی



شکل (۱۶) افت دقت شناسایی در نمودار ROC مربوط به داده‌های آزمایش پس از کاهش مجموعه دیتا

شکل (۱۴) دقت شناسایی مطلوب حدود ۰/۹۷+ در نمودار ROC مربوط به داده‌های آزمایش

همان‌گونه که از ماتریس پیچیدگی و نمودارهای ROC مشاهده می‌گردد، پس از کاهش تعداد تصاویر زمان-فرکانس مربوط به سیگنال‌های هدف، دقت شناسایی به شدت کاهش می‌یابد که این مهم در شکل‌های (۱۵) و (۱۶) به وضوح دیده می‌شود. بنابراین می‌توان نتیجه گرفت در استفاده از مدل‌های یادگیری عمیق، شبکه عصبی نیاز به آموزش با حجم دیتای مناسب دارد، تا در مواجهه با اهداف جدید قادر به شناسایی صحیح باشد. به همین منظور در بکارگیری شبکه‌های

حال نشان می‌دهیم که با کاهش ۵۰ درصد از اندازه دیتاست، و آموزش مجدد مدل طراحی شده دقت شناسایی به صورت محسوس پایین می‌آید. نتایج را با نتایج قبلی مقایسه کرده تا تأثیر اندازه دیتاست بر روی طبقه بندی مشخص گردد. مشاهده می‌شود مقادیر خطای اعتبارسنجی^۱ افزایش یافته و میزان دقت اعتبارسنجی^۲ در ارزیابی مدل نسبت به حالت قبل به شدت کاهش یافته است (شکل ۱۳). در این حالت و با کاهش اندازه دیتاست، با مشاهده ماتریس پیچیدگی و

² Validation Accuracy

¹ Validation Loss

عصبی عمیق چنانچه مجموعه داده کافی در اختیار نباشد، شبکه عصبی قادر به آموزش درست و متعاقب آن تشخیص درست اهداف نمی‌گردد.

۵- تجزیه و تحلیل نتایج

۵-۱- مقایسه کمی و تحلیل آماری عملکرد مدل‌ها

جدول مقایسه عملکرد شبکه پیشنهادی با مدل‌های مرجع، شامل معیارهای Accuracy، Precision، Recall و F1-Score، در جدول (۴) ارائه شده است. تحلیل این جدول نشان می‌دهد که مدل پیشنهادی، با وجود سبک بودن و عمق کم، عملکردی کاملاً رقابتی با شبکه‌های بسیار عمیق‌تر مانند ResNet-50، ResNet-152 و VGG ارائه می‌دهد. در ادامه نکات کلیدی تحلیل آماری آورده شده است:

۵-۱-۱- تحلیل میانگین عملکرد

اگر میانگین چهار شاخص اصلی را برای هر مدل محاسبه کنیم، شبکه پیشنهادی در دسته مدل‌های «عملکرد بالا/پیچیدگی کم»^۱ قرار می‌گیرد؛ یعنی توانسته با کمترین تعداد پارامتر، به سطحی از عملکرد برسد که معمولاً مختص شبکه‌های سنگین و چند ده لایه‌ای است.

۵-۱-۲- تحلیل واریانس^۲ عملکرد

در شبکه‌های سنگینی مثل VGG و ResNet-152 معمولاً اختلاف بین Precision و Recall زیاد است که نشان‌دهنده عدم تعادل در حساسیت مدل به کلاس‌هاست. اما در شبکه پیشنهادی، واریانس بین چهار شاخص بسیار کم است. این یعنی مدل پیشنهادی رفتار باثبات‌تر و اصطلاحاً تعمیم‌پذیری^۳ بهتری دارد.

۵-۱-۳- تحلیل دقت

اگرچه ResNet‌ها در برخی تست‌ها دقت بالایی دارند، اما با توجه به هزینه محاسباتی بسیار زیادشان، نسبت کارایی^۴ پایین‌تری نسبت به طرح پیشنهادی دارند.

۵-۱-۴- تحلیل نسبت «دقت به هزینه محاسباتی»^۵

در شبکه‌های بسیار عمیق، هر واحد افزایش دقت (مثلاً ۰.۱٪) ممکن است هزینه محاسبات را ۵ تا ۲۰ برابر افزایش دهد. اما در شبکه پیشنهادی، افزایش دقت با افزایش بسیار کم هزینه محاسبات به دست آمده است، که این موضوع در کاربردهای بلادرنگ اهمیت حیاتی دارد.

جدول مقایسه عملکرد مدل پیشنهادی با شبکه‌های متداول و پرکاربرد در حوزه طبقه‌بندی سیگنال‌های LPI نشان می‌دهد که با وجود سادگی و کم‌پارامتری بودن معماری پیشنهادی، این مدل قادر است عملکردی بسیار رقابتی و در برخی شاخص‌ها حتی برتر از شبکه‌های عمیق و سنگینی مانند ResNet و VGG ارائه دهد. در مقایسه با شبکه‌های

کلاسیک‌تر نظیر LeNet و AlexNet، مدل پیشنهادی بهبود قابل توجهی در معیارهای دقت، یادآوری، و F1-Score نشان می‌دهد. این موضوع بیانگر توانایی مدل در استخراج الگوهای زمانی-فرکانسی ظریف موجود در سیگنال‌های LPI است، در حالی که شبکه‌های قدیمی‌تر به دلیل عمق کم و ظرفیت محدود، توانایی کافی برای یادگیری این ویژگی‌های پیچیده را ندارند.

از سوی دیگر، شبکه‌های بسیار عمیق مانند VGG، GoogleNet و ResNet-50/152 به دلیل تعداد بالای پارامترها و پیچیدگی معماری، در برخی شاخص‌ها عملکرد بالایی ارائه می‌دهند؛ اما این عملکرد با هزینه سنگین محاسباتی و نیاز به حافظه و توان پردازشی بالا به دست آمده است. مقایسه مقادیر موجود در جدول نشان می‌دهد که مدل پیشنهادی با وجود عمق کمتر در معیارهایی مانند Precision، Recall و به‌خصوص Accuracy، بسیار نزدیک یا حتی برتر از این شبکه‌ها عمل می‌کند. برای مثال، مدل پیشنهادی در مقایسه با ResNet-50 و ResNet-152 دقت قابل رقابت و در برخی موارد بهتر ارائه کرده است، در حالی که زمان آموزش و استنتاج آن چندین برابر کمتر است. بنابراین، مزیت اصلی مدل پیشنهادی در نسبت «عملکرد به هزینه محاسباتی» است. این مدل با بهره‌گیری از معماری سبک و بهینه‌سازی شده، توانسته است تعادلی مناسب میان دقت بالا و سرعت محاسبات ایجاد کند. چنین ویژگی‌ای برای کاربردهای عملی مانند پردازش بلادرنگ سیگنال رادار و پیاده‌سازی روی سخت‌افزارهای با توان پردازشی محدود (نظیر SDRها یا پردازنده‌های لبه‌ای) بسیار حیاتی است.

به‌طور خلاصه، نتایج نشان می‌دهد که طرح پیشنهادی نه تنها قادر به رقابت با شبکه‌های عمیق پرهزینه است، بلکه با توجه به سادگی، سرعت استنتاج بالا و نیاز محاسباتی کم، انتخابی مناسب برای کاربردهای عملی و مقیاس‌پذیر در حوزه شناسایی سیگنال رادارهای LPI محسوب می‌شود. با لحاظ نمودن میزان دقت و پیچیدگی شبکه عصبی به عنوان دو پارامتر مهم و مصالحه بین این دو پارامتر در مدل‌های مختلف، اگرچه تعدادی از الگوریتم‌های شبکه عصبی، با افزایش لایه‌های پنهان و عمق دادن به شبکه که منجر به افزایش پیچیدگی‌های محاسباتی می‌گردد، نسبت به روش پیشنهادی، اندک دقت شناسایی بیشتری دارند (در حدود حداکثر ۳ درصد)، اما روش پیشنهادی در این پژوهش علاوه بر سادگی طراحی (سرعت پردازش بالا)، دارای دقت طبقه‌بندی و شناسایی مناسبی می‌باشد، که حتی توسط رایانه‌های معمولی قابل اجرا بوده و عملکرد قابل قبولی را ارائه می‌دهد.

⁴ Efficiency Ratio

⁵ Performance-to-Complexity Ratio

¹ High-Performance / Low-Complexity

² Variance

³ Generalization


جدول (۴) مقادیر صحت طبقه‌بندی، دقت شناسایی، فراخوانی، و امتیاز F1 روش‌های مختلف یادگیری عمیق در شناسایی خودکار اهداف. بهترین معیار در هر ستون به صورت پررنگ‌تر نشان داده شده است.

Method	Accuracy	Precision	Recall	F1-Score
LeNet	٪ ۷۰/۰۰	٪ ۷۸/۰۰	٪ ۸۵/۰۰	٪ ۷۷/۰۰
AlexNet	٪ ۸۱/۰۰	٪ ۸۳/۰۰	٪ ۸۷/۰۰	٪ ۸۴/۰۰
Proposed Method	٪ ۹۵/۰۰	٪ ۹۶/۰۷	٪ ۹۷/۳۲	٪ ۹۷/۱۱
VGG	٪ ۹۷/۳۴	٪ ۹۸/۴۷	٪ ۹۹/۲۸	٪ ۹۹/۱۴
GoogleNet	٪ ۹۶/۸۶	٪ ۹۸/۳۳	٪ ۹۹/۰۴	٪ ۹۸/۸۴
ResNet 50	٪ ۹۶/۹۷	٪ ۹۷/۶۱	٪ ۹۸/۲۲	٪ ۹۷/۸۵
ResNet 152	٪ ۹۷/۶۷	٪ ۹۸/۵۴	٪ ۹۹/۳۷	٪ ۹۹/۱۸

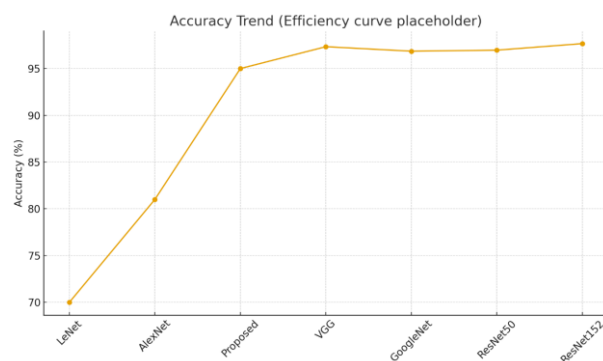
و نیاز محاسباتی کم، طرح پیشنهادی انتخابی مناسب برای کاربردهای عملی و مقیاس‌پذیر است. لذا مدل اشاره شده در طرح پیشنهادی این مقاله می‌تواند گزینه مناسبی برای پیاده‌سازی در سیستم‌های بالادرنگ یا سخت‌افزارهای کم‌مصرف باشد. به نسبت سایر شبکه‌های عصبی مرجع، شبکه عصبی عمیق طراحی شده در این مقاله با ایجاد دقت شناسایی مطلوب و کاهش پیچیدگی محاسباتی (سرعت بالا)، در شناسایی سیگنال رادار دشمن، می‌تواند موجب افزایش قابلیت حفظ و بقای تجهیزات و نیروی انسانی در نبردهای مدرن گردد. با توجه به بدیع بودن روش‌های یادگیری عمیق در شناسایی اهداف به ویژه در روی نظامی، پیشنهاد می‌گردد در تحقیقات آینده، توسعه‌دهندگان بر روی بهبود معماری‌های شبکه‌های عصبی و یکپارچگی با فناوری‌های پیشرفته تمرکز کنند و برنامه‌هایی برای تطبیق با تهدیدات جدید ارائه نمایند. همچنین محققان می‌توانند تمرکز ویژه‌ای بر روی ارتقاء پارامترهای حیاتی شبکه‌های عصبی نظیر افزایش دقت و کاهش پیچیدگی به منظور استفاده در سامانه‌های هوشمند شنود و تشخیص الکترونیکی در حوزه نظامی داشته باشند.

۷- منابع

- [۱] قدیمی، قادر؛ نوروزی، یاسر، بایدرخانی، رضا، نائی، محمد مهدی. (۱۳۹۸). شناسایی و کلاس‌بندی سیگنال رادارهای LPI با استفاده از شبکه‌های لی‌نت و الکس‌نت در یادگیری عمیق.
- [۲] محمدی فاتح، اصغر و ابراهیمی، سیدعباس. (۱۳۹۹). شناسایی و رتبه‌بندی فناوری‌های اطلاعاتی نوظهور در بخش دفاعی-نظامی، فصلنامه آینده‌پژوهی دفاعی. ۱۷(۵): ۱۷۱-۱۴۳
- [۳] وزان، میلاد. (۱۳۹۹). یادگیری عمیق، اصول، مفاهیم و رویکردها، چاپ اول، تهران: انتشارات میعاد اندیشه.
- [4] Cain, L., Clark, J., Pauls, E., Ausdenmoore, B., Clouse, R., & Josue, T. (2018). Convolutional neural networks for radar emitter classification. In 2018 IEEE 8th Annual Computing and Communication Workshop and Conference (CCWC) (pp. 79-83). IEEE. doi: 10.1109/CCWC.2018.8301627.
- [5] Gao, L., Qin, P., Li, H., Wang, S., Sun, H., & Lu, Y. (2019, July). Transfer learning in polytime codes signal recognition. In 2019 IEEE 4th International Conference on Signal and Image Processing (ICSIP) (pp. 91-95). IEEE. doi: 10.1109/SIPROCESS.2019.8868336.
- [6] Geng, Z., Yan, H., Zhang, J., & Zhu, D. (2021). Deep-learning for radar: A survey. IEEE Access, 9, 141800-141818., doi: 10.1109/ACCESS.2021.3119561.
- [7] Ghosal, P., Nandanwar, L., Kanchan, S., Bhadra, A., Chakraborty, J., & Nandi, D. (2019). Brain tumor classification using ResNet-101 based squeeze and excitation deep neural network. In 2019 Second International Conference on Advanced Computational and Communication Paradigms (ICACCP) (pp. 1-6). IEEE.
- [8] Guner, K. K., Erkmen, B., Gulum, T. O., Erdogan, A. Y., Yildirim, T., & Ata, L. D. (2016). Implementation aspects of Wigner-Hough Transform based detectors for LFM signals. In 2016 39th International Conference on Telecommunications and Signal Processing (TSP) (pp. 441-444). IEEE. doi: 10.1109/TSP.2016.7760916.
- [9] He, K., Zhang, X., Ren, S., & Sun, J. (2015). Spatial pyramid pooling in deep convolutional networks for visual recognition. IEEE transactions on pattern analysis and machine intelligence, 37(9), 1904-1916.



شکل (۱۷) نمودار مقایسه Precision / Recall / F1



شکل (۱۸) نمودار روند Accuracy (به عنوان جایگزین نمودار Efficiency)

۶- نتیجه گیری

در طرح پیشنهادی با ارائه و پیاده‌سازی یک روش نوین مبتنی بر یادگیری عمیق برای شناسایی سیگنال رادار LPI، به تاثیر مولفه‌های مهمی نظیر سادگی مدل، عمق کم و دقت بالا در شبکه عصبی عمیق پرداخته‌ایم. با توجه به تحلیل کمی نتایج، می‌توان نتیجه گرفت که طرح پیشنهادی در مقاله، ضمن دارا بودن معیارهای اصلی عملکردی نظیر: دقت، صحت و بازیابی، دارای هزینه محاسباتی چندین برابر پایین‌تر از مدل‌های مرجع شبکه‌های عمیق است و شرایط رقابتی قابل توجهی را با این شبکه‌ها رقم می‌زند. تعادل و پایداری شاخص‌های دقت، صحت و بازیابی در طرح پیشنهادی بهتر از مدل‌های مرجع سنگین شبکه‌های عمیق است. با توجه به سادگی، سرعت استنتاج بالا

- [25] Ünal, L., & Pakfiliz, A. G. (2022). LPI Radar Signal Detection Based on Autocorrelation Function and Wigner-Ville Distribution. *Review of Computer Engineering Studies*, 9(4).
- [26] Wan, T., Jiang, K. L., Ji, H., & Tang, B. (2023). Deep learning-based LPI radar signals analysis and identification using a Nyquist Folding Receiver architecture. *Defence Technology*, 19, 196-209.
- [27] Wang, Q., Du, P., Dou, T., Gao, L., & Li, C. (2019). Cognitive passive radar system: software defined radio and deep learning approach. *The Journal of Engineering*, 2019(21), 7326-7330.
- [28] Wang, X., Xu, G., Yan, H., Zhu, D., Wen, Y., & Luo, Z. (2023). Lpi radar signals modulation recognition based on acdca-resnext. *IEEE Access*, 11, 45168-45180.
- [29] Wu, Y., Mao, Y., & Chen, X. (2020, May). Research on radar signal recognition technology based on deep learning. In *2020 IEEE 3rd International Conference on Electronics Technology (ICET)* (pp. 630-633). IEEE.. doi: 10.1109/ICET49382.2020.9119713.
- [30] Xu, Z., & Wei, S. (2023). FMCW Radar System Interference Mitigation Based on Time-Domain Signal Reconstruction. *Sensors*, 23(16), 7113.
- [31] Yildirim, A., & Kiranyaz, S. (2020). 1D convolutional neural networks versus automatic classifiers for known LPI radar signals under white gaussian noise. *IEEE Access*, 8, 180534-180543. doi: 10.1109/ACCESS.2020.3027472.
- [32] Yoo, J., Cho, Y. S., Kim, C. J., Choi, H., & Kim, Y. (2023). Time and Accuracy Trade-Off of LPI Radar Classification Technology Based on Time-Frequency Analysis and Deep Learning. *The Journal of Korean Institute of Electromagnetic Engineering and Science*, 34(1), 25-32.
- [10] He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 770-778).
- [11] Hong, S., Kwak, S., & Han, B. (2017). Weakly supervised learning with deep convolutional neural networks for semantic segmentation: Understanding semantic layout of images with minimum human supervision. *IEEE Signal Processing Magazine*, 34(6), 39-49.
- [12] Huynh-The, T., Doan, V. S., Hua, C. H., Pham, Q. V., Nguyen, T. V., & Kim, D. S. (2021). Accurate LPI radar waveform recognition with CWD-TFA for deep convolutional network. *IEEE Wireless Communications Letters*, 10(8), 1638-1642.
- [13] Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 25.
- [14] Liang, F., Zhou, Y., Chen, X., Liu, F., Zhang, C., & Wu, X. (2021, January). Review of target detection technology based on deep learning. In *Proceedings of the 5th International Conference on Control Engineering and Artificial Intelligence* (pp. 132-135). <https://doi.org/10.1145/3448218.3448234>.
- [15] Limin, G. U. O., & Xin, C. (2018). Low probability of intercept radar signal recognition based on the improved AlexNet model. In *Proceedings of the 2nd International Conference on Digital Signal Processing* (pp. 119-124). doi:10.1145/3193025.3193037
- [16] Liu, L., & Li, X. (2021). Radar signal recognition based on triplet convolutional neural network. *EURASIP Journal on Advances in Signal Processing*, 2021(1), 112.. <https://doi.org/10.1186/s13634-021-00821-8>
- [17] Liu, Y., Xiao, P., Wu, H., & Xiao, W. (2015). LPI radar signal detection based on radial integration of Choi-Williams time-frequency image. *Journal of systems engineering and electronics*, 26(5), 973-981., doi: 10.1109/JSEE.2015.00106.
- [18] Ni, X., Wang, H., Meng, F., Hu, J., & Tong, C. (2021). LPI radar waveform recognition based on multi-resolution deep feature fusion. *IEEE Access*, 9, 26138-26146. doi: 10.1109/ACCESS.2021.3058305.
- [19] Nuhoglu, M. A. (2018, May). Classification of radar signal features in electronic warfare with convolutional long-short time memory. In *2018 26th Signal Processing and Communications Applications Conference (SIU)* (pp. 1-4). IEEE. doi: 10.1109/SIU.2018.8404452.
- [20] Ren, F., Quan, D., Shen, L., Wang, X., Zhang, D., & Liu, H. (2023). LPI Radar Signal Recognition Based on Feature Enhancement with Deep Metric Learning. *Electronics*, 12(24), 4934.
- [21] Ren, F., Quan, D., Shen, L., Wang, X., Zhang, D., & Liu, H. (2023). LPI Radar Signal Recognition Based on Feature Enhancement with Deep Metric Learning. *Electronics*, 12(24), 4934.
- [22] Si, W., Wan, C., & Zhang, C. (2021). Towards an accurate radar waveform recognition algorithm based on dense CNN. *Multimedia Tools and Applications*, 80(2), 1779-1792. doi:10.1007/s11042-020-09490-5
- [23] Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.
- [24] Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., ... & Rabinovich, A. (2015). Going deeper with convolutions. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 1-9)., doi: 10.1109/CVPR.2015.7298594.