فصلنامه علمی - پژوهشی فرماندهی و کنترل، سال پنجم، شماره یک، بهار 1400

شناسایی و کلاس‌بندی سیگنال رادارهای LPI با استفاده از آنالیز زمان فرکانس و یادگیری عمیق

قادر قدیمی [1]

تاریخ دریافت: ۱۳۹۹/۱۱/۱۵ **تاریخ پذیرش:** ۱۴۰۰/۰۷/۲۶

چکیده

رادارهای LPI (Low Probability of Intercept) و یا با احتمال رهگیری پائین، رادارهایی هستند که به‌دلیل توان کم، پهنای باند گسترده و فرکانس متغیر، احتمال رهگیری آنها توسط سیستم‌های شناسایی بسیار پائین است. بنابراین با ظهور این نوع تکنولوژی از رادارها، همواره روش‌های جدیدی در حوزه پردازش سیگنال و تصویر مورد نیاز است تا با استفاده از این روش‌ها، بتوان سیگنال‌های مذکور را در مرحله اول تشخیص داده و در مرحله دوم کلاس‌بندی کرده و در مرحله آخر بتوان مشخصات آنها را استخراج کرد. برای حل مسئله، امروزه یادگیری عمیق به‌عنوان یکی از روش‌های جدید در حوزه پردازش سیگنال و تصویر مطرح است. در این مقاله با استفاده از روش یادگیری عمیق امکان آشکارسازی و کلاس‌بندی انواع مدولاسیون رادارهای LPI، بررسی خواهد شد. در این راستا ابتدا سیگنال دریافتی با استفاده از تحلیل فوریه زمان-کوتاه، در حوزه زمان-فرکانس مورد تجزیه‌وتحلیل قرار گرفته و خروجی این بخش به‌صورت یک تصویر، به دو بهبود یافته دو شبکه الکس‌نت و گوگل‌نت که از شبکه‌های یادگیری عمیق هستند و بعنوان‌های method1,method2 در این مقاله شناخته شده‌اند، برای آشکارسازی و کلاس‌بندی انواع مدولاسیون‌های مورد استفاده در رادارهای LPI، مانند LFM، فازهای چند گانه (P1, P2, P3, P4)و زمان‌های چندگانه (T1, T2, T3, T4) داده خواهد شد.داده خواهد شد. نتایج به‌دست‌آمده از این شبیه‌سازی‌ها نشان می‌دهد که در SNR (نسبت سیگنال به نویز) ،15dB- دقت عملکرد روش method2, 80% و دقت عملکرد روش method1 100% است که نشان از عملکرد بهتر روش method1 است.

واژگان کلیدی: یادگیری عمیق، شبکه عصبی کانولوشن، تحلیل فوریه زمان-کوتاه ، رادارهای LPI

[1] نویسنده مسئول: استاد یار دانشگاه امام علی (ع)، g_ghadimi@yahoo.com

[Downloaded from ic4i-journal.ir on 2026-11-24]

1. کلیات

در گذشته بسیاری از طراحان رادار با استفاده از پالس‌هایی با دوره تناوب کم و توان بالا، سعی در کم کردن تلفات سیگنال ارسالی از رادارها را داشتند. این روش به‌دلیل امکان رهگیری آسان این سیگنال‌ها، بیشتر در مواردی که امنیت اطلاعات زیاد مهم نباشد استفاده می‌شود. ولی وقتی از این رادارها برای مقاصد نظامی استفاده می‌شود ارسال این سیگنال‌ها به‌گونه‌ای که تجهیزات رهگیر جنگ الکترونیک، متوجه این سیگنال‌ها نشوند، از اهمیت زیادی برخوردار است. امروزه برای برآورد کردن این خواسته، با استفاده از رادارهایی که امکان رهگیری پائینی (LPI[1]) دارند سعی در مخفی نگه‌داشتن سیگنال رادارها از دید گیرنده‌های جنگ الکترونیک دشمن را دارند.

به‌دلیل تکنولوژی خاص رادارهای LPI، این رادارها دارای توان ارسالی پائین، پهنای باند زیاد و فرکانس متغیر می‌باشند. لذا به‌دست آوردن مشخصات این نوع از سیگنال‌ها، برای گیرندگان جنگ الکترونیک از جمله رادارهای هشدار، گیرنده‌های هوشمند الکتریکی و ... مشکل‌ساز است. به‌عبارتی دیگر شناسایی سیگنال رادارهای LPI نیازمند استفاده از روش‌های جدید در حوزه پردازش سیگنال و تصویر، برای آشکارسازی، کلاس‌بندی و استخراج مشخصات این نوع از سیگنال‌ها است[1]. قبل از پرداختن به مسئله آشکارسازی سیگنال رادارهای LPI، لازم است بدانیم این نوع از سیگنال‌ها با توجه به نوع مدولاسیون به‌کاررفته دارای انواع مختلفی می‌باشند که عبارت‌اند از:

مدولاسیون FM خطی و غیرخطی (LFM,NLFM)، مدولاسیون PSK که شامل فرانک و کدهای فازی P1,P2, P3, P4 و کدهای زمانی T1,T2,T3,T4 همچنین مدولاسیون FSK که شامل کدهای کاستاس است و در نهایت مدولاسیون FSK/PSK که حاصل از ترکیب دو مدولاسیون PSK و FSK می باشد. بدلیل وجود انواع مختلف از مدولاسیون‌ها بایستی تجهیزات شنود مجهز به تشخیص نوع سیگنال این رادارها بصورت اتوماتیک در دو مرحله آشکارسازی و کلاس‌بندی باشد[2].

1-1مقدمه

هدف اصلی این مقاله ارائه روشی برای آشکارسازی و کلاس‌بندی سیگنال رادار های LPI است. در زمینه آشکارسازی و کلاس‌بندی سیگنال این نوع از رادارها در گذشته براساس خواص توابع خود همبستگی [3]و تحلیل زمان-فرکانس، انرژی سیگنال را در حوزه زمان- فرکانس جمع آوری کرده [4-6] و به صورت یک تابعی از زمان و فرکانس مورد بررسی قرار می‌گرفتند، ارائه شده است. خروجی آنالیز زمان-فرکانس به‌صورت یک تصویر است که می‌توان از آن برای شناسایی نوع سیگنال و استخراج پارامترهای آن استفاده کرد[8,9]. تا به حال روش‌هایی برای آنالیز زمان-فرکانس این نوع از سیگنال رادارها، ارائه شده است که عبارت‌اند از: توزیع چوئی ویلیامز[2][1,10]، روش سری فوریه زمان-کوتاه[3][1,11] و روش سوم توزیع واینر ویل[4][1,12].به تازگی روشی مشابه تصویربرداری SAR [13] برای تشخیص این نوع از سیگنالها ارئه شده است که با تولید یک تصویر از اختلاف فاز سیگنال‌های دریافت شده از دو آنتن که بر روی سکوی متحرک بکار برده شده‌اند سعی در شناسائی سیگنال رادارهای LPI را دارد.

مشکل اصلی روش‌های موجود در آشکارسازی و استخراج مشخصات سیگنال‌های رادارهای LPI،در SNRهای پائین این نوع از سیگنال‌ها است. برای حل این

[2]Low Probability of Interception(LPI)

[2]Choi-William Distribution (CWD)

[3]Short-Time Fourier Transform (STFT)

[4]Wigner Ville Distribution (WVD)

[Downloaded from ic4i-journal.ir on 2026-11-24]

مشـــکل روش‌های متعددی ارائه شـــده اســـت. یکی از این روش‌ها، ا ستفاده از روش یادگیری عمیق ا ست. در این روش با اســتفاده از یک شــبکه عصــبی کانولوشــنال(CNN)[1] انوع مدولاســـیون این نوع از رادارها را می‌توان آشـــکارســـازی وکلاس‌بندی کرد. در این مقاله سعی شده ا ست با ا ستفاده از شـــبکه‌های CNN، نوع مدولاســـیون رادارهای LPI را در SNRهای پائین تشخیص داده و کلاس‌بندی کرد.

هدف یادگیری عمیق ایجاد شبکه‌های عصبی بزرگ ا ست که می‌توانند یاد بگیرند و بدون دخالت انسان در مورد مسائل فکر کنند. شـــبکه‌های عصـــبی کانولوشـــنال که CNNs یا ConvNets نیز نامیده می‌شوند یکی از مهم‌ترین روش‌های یادگیری عمیق هســـتند که در آنها چندین لایه آموزش داده می شود تا از این آموزش بهره‌برداری‌های لازم بردا شته شود. این روش بســـیار کارآمد بوده و یکی از رایج‌ترین روش‌ها در کاربردهای مختلف بینایی کامپیوتر اســـت. این شـــبکه‌ها در زمینه‌های زیادی از جمله تشخیص الگو، تشخیص سخنان یک نفر، پردازش ز بان طبیعی و پردازش تصـــویر کاربرد دارد. شـــبکه‌های عصـــبی کانولوشـــنال تا حد بســـیار زیادی شـــبیه شبکه‌های عصبی مصنوعی هستند.

در [10] آقای ژانگ و همکارانش با ا ستفاده از یک شبکه CNN روشـــی را برای کلاس‌بندی 12 نوع از مدولاســـیون رادارهای LPI، ارائه کرده‌اند. در [14] آقای ژانگ و همکارانش مشخصات سیگنال رادارهای LPI را از فرکانس و فاز لحظه‌ای جدا شده از سیگنال به‌د ست می‌آورند. در [10] آقای ژانگ و همکارانش با اســتفاده از توزیع CWD و یک شـــبکه CNN یک روش اتوماتیک، برای تشـــخیص ســـیگنال‌های رادیوئی را ارائه داده‌اند. در [15] جی یو و همکارانش با ا ستفاده از شبکه CNN الکس‌نت بهبود یافته و توزیع WVD در حوزه زمان-فرکانس برای آنالیز و کلاس‌بندی ســـیگنال رادارهای LPI را ارئه داده‌اند. در [16] آقای وانگ و همکارانش با اســـتفاده از یک شبکه CNN که خود شان طراحی کرده بودند، رو شی را برای کلاس‌بندی سیگنال رادارهای LPI با ا ستفاده از ت صویر خروجی از آ نالیز ز مان - فر کانس را ارا ئه داده‌ا ند همچنین ویژگی‌های آماری نویز در این تصـــاویر مورد تجزیه‌وتحلیل قرار گرفتـه و نهـایتـاً رویکردی را برای کـاهش نویز ارائـه می‌دهند.

در این مقاله از شـــبکه‌های CNN الکس نت[2] و گوگل نت[3] برای کلاس‌بندی و تشـخیص انواع مدولاسـیون رادارهای LPI اســـتفاده شـــده و نتایج آنها با روش‌های ارائه‌شـــده در مراجع [10]و[14] مورد مقایسه قرار خواهند گرفت.

این مقاله از قسمت‌های زیر تشکیل شده است. در قسمت دوم سیگنال رادارهای LPI مورد بحث و برر سی قرار خواهد گرفت. در قســمت ســوم روش شــبکه CNN مورد بحث و برر سی قرار می‌گیرد. در قسمت چهارم روش پیشنهادی برای آشکارسازی و کلاس‌بندی سیگنال رادارهای LPI ارائه خواهد شد. در قسمت پنجم نتایج شبیه‌سازی‌ها ارائه شده و نهایتاً در بخش ششم جمع‌بندی مقاله ارائه خواهد شد.

2. سیگنال رادارهای LPI

در این بخش، مدل ســیگنال‌های اســتفاده‌شــده در این مقاله به همراه فرمول‌های مربوطه مورد بحث و بررســـی قرار خواهد گرفت.

2-1. مشخصات سیگنال رادارهای LPI

امروزه وجود تجهیزات پشـــتیبـانی جنـگ الکترونیـک و موشـــک‌های ARM اســـتفاده از رادارها رابه خطر انداخته و نمی توان از رادارهای MTI که برای د ستیابی به برد بیشتر از توان بالائی اسـتفاده می‌کنند، اسـتفاده کرد. بنابراین اسـتفاده از راداهائی که دارای احتمال شنود کمتری می‌باشند حائز اهمیت ا ست. در این را ستا تکنولوژی جدید در مورد سیگنال رادارها رونمائی شـد که امکان تشـخیص سـیگنال رادارها را بسـیار سخت می‌کرد. اصطلاحاً به این نوع از رادارها، رادارهای LPI اطلاق شـد[17]. یکی از مؤلفه‌های مهم که در رادارهای LPI دارای اهمیت اســت تکنیک فشــرده‌ســازی پالس می‌باشــد.

[1] Convolutional Neural Networks (CNN)
[2] AlexNet
[3] Google.Net

[Downloaded from ic4i-journal.ir on 2026-11-24]

روش‌های فشرده‌سازی پالس در رادارها به دو دسته فشرده سازی پالس با مدولاسیون فرکانس(خطی و غیرخطی) که در این مقاله به نوع خطی آن اشاره شده است و روش مدولاسیون فازی که به دو روش باینری و چندفازی تقسیم می‌شود، که در این مقاله از روش چندفازی آن استفاده شده است که توضیحات مختصر آن به‌صورت زیر است.

2-1-1 مدولاسیون FM

مدولاسیون FM و یا مدولاسیون فرکانس، می‌تواند یک سیگنال LPI پهن باند تولید کند. به چندین علت مدولاسیون FM یک تکنیک مؤثر در زمینه LPI است. مدولاسیون فرکانس انرژی سیگنال ارسالی را در پهنای باند وسیع ΔF توزیع می‌کند که باعث ایجاد رزولوشن خوب در برد می شود که برای تشخیص کلاتر از هدف بسیار خوب است. رابطه ذکرشده در جدول 1 برای مدولاسیون FM، B نشانگر پهنای باند سیگنال و τ_P، نشانگر فاصله بین پالس‌ها است[1].

2-1-2 مدولاسیون چند فازی

مدولاسیون چند فازی و یا به‌عبارتی کدهای چند فازی دنباله‌هایی با طول محدود، دامنه ثابت و فاز متغیر φ_k هستند که در آنها φ_k می‌تواند هر مقداری را بین 0و 2π را بگیرد. افزایش تعداد عناصر یا مقادیر فاز در دنباله، امکان تولید دنباله هایی با طول بلندتر و سطح لوپ فرعی پایین‌تر را امکان‌پذیر کرده که منجر به بهره پردازشی بیشتر در گیرنده می‌شود. از کدهای چند فازی می‌توان به کدهای بارکر، کدهای فرانک، کدهای P1,P2,P3,P4 و همچنین کدهای چند زمانه T1,T2,T3,T4 اشاره کرد. کدهای مورد استفاده در این مقاله کدهای چند فازی P1,P2,P3,P4 و همچنین کدهای چند زمانه T1,T2,T3,T4 می‌باشند که روابط حاکم بر این کدها در جدول شماره 1 آمده است.

در روابط ذکرشده برای کدهای P1,P2,P3,P4، که به‌صورت $\varphi_{i.j}$ بیان شده‌اند نشانگر فاز در iامین نمونه از jامین فرکانس است. همچنین برای کدهای چند زمانه T1,T2,T3,T4 که به‌صورت $\varphi_{i.j}(t)$ بیان شده، نشانگر فاز در iامین نمونه از jامین فرکانس در لحظه t می‌باشد[1].

2-2 سیگنال ارسالی از رادارهای LPI

در این قسمت نگاه اجمالی به فرمول این نوع از سیگنال‌ها می‌پردازیم.

سیگنال ارسالی از یک رادار را به‌صورت زیر می‌توان نشان داد:

$$s(t) = R\{Ae^{(j2\pi f_c t+\emptyset_k)}\} \qquad (1)$$

که در آن f_c فرکانس حامل و $\emptyset_k$ فاز مدولاسیون که به‌صورت زیر تعریف می‌گردد:

$$\emptyset_k = 2\pi f_k(kT_s) + \varphi_k \qquad (2)$$

که در آن φ_k فاز آفست و f_k فرکانس لحظه‌ای است. دو روش برای فشرده‌سازی پالس وجود دارد که 9 شکل موج رادار LPI ذکر شده در این مقاله را، در دو نوع مدولاسیون فرکانس[1]و مدولاسیون فاز[2]می‌توان جمع‌بندی کرد [18]. در مدولاسیون FM فرکانس لحظه‌ای f_k متغیر و فاز φ_k ثابت، و در مدولاسیون PM فرکانس لحظه‌ای f_k ثابت و فاز φ_k متغیر است [19]. فاز φ_k برای تمامی مدولاسیون‌ها به‌غیر از مدولاسیون FM ، به صورت $\varphi_{i.j}$ نشان داده شده است که نشانگر iامین نمونه از jامین فرکانس است. جدول (1) مشخصات 9 مدولاسیون رادار LPI را که در این مقاله استفاده شده است را نشان می‌دهد.

2-3. آنالیز زمان- فرکانس

طراحی سیگنال رادارهای LPI به‌گونه‌ای است که امکان آشکارسازی را برای گیرنده‌های غیرمجاز پیچیده می‌کند و گیرنده‌های EW غیرمجاز برای شناسایی و استخراج پارامترهای این نوع از سیگنال‌ها نیازمند گین پرداز شی بسیار بالائی هستند. این عملیات را می‌توان در دسته کلاس‌بندی قرار داد. کلاس‌بندی نیاز به قرار دادن سیگنال‌ها با مشخصات مشابه در یک گروه است. مشخصاتی از قبیل فرکانس حامل،

[1]Frequency Modulation(FM)

[2]Phase Modulation(PM)

[Downloaded from ic4i-journal.ir on 2026-11-24]

پهنای باند، پهنای باند مدولا سیون، دوره تناوب مدولا سیون و برخی پارامترهای دیگر این نوع از سیگنال ها می‌تواند این سیگنال‌ها را از هم جدا کند. همبستگی سیگنال‌های موجود در یک پایگاه داده می‌تواند در ردیابی سیگنال و مدیریت پاسخ کمک کند.

جدول (1): مشخصات انواع مدولاسیون رادارهای LPI

نوع مدولاسیون	φ_k	f_k
FM	ثابت	$f_c + \frac{B}{\tau_p}(kT_s)$
P1	$\varphi_{i.j} = \frac{-\pi}{N}[N-(2j-1)][(j-1)N + (i-1)]$	ثابت
P2	$\varphi_{i.j} = \frac{-\pi}{2N}[2j-1-N][2i-1-N]$	ثابت
P3	$\varphi_i = \frac{\pi(i-1)^2}{N_c}$	ثابت
P4	$\varphi_i = \frac{\pi(i-1)^2}{N_c} - \pi(i-1)$	ثابت
T1	$\varphi_{i.j}(t) = mod\left\{\frac{2\pi}{n} INT\left[(kt - jT)\frac{jn}{T}\right].2\pi\right\}$	ثابت
T2	$\varphi_{i.j}(t) = mod\left\{\frac{2\pi}{n} INT\left[(kt - jT)\left(\frac{2j-k+1}{T}\right)\frac{n}{2}\right].2\pi\right\}$	ثابت
T3	$\varphi_{i.j}(t) = mod\left\{\frac{2\pi}{n} INT\left[\frac{n\Delta F t^2}{2t_m}\right].2\pi\right\}$	ثابت
T4	$\varphi_{i.j}(t) = mod\left\{\frac{2\pi}{n} INT\left[\frac{n\Delta F t^2}{2t_m} - \frac{n\Delta F t}{2}\right].2\pi\right\}$	ثابت

در پردازش سیگنال، آنالیز زمان-فرکانس تکنیکی است که سیگنال را در دو حوزه زمان و فرکانس به‌طور هم‌زمان مورد بررسی قرار می‌دهد. علاوه بر این، تجزیه‌وتحلیل زمان-فرکانس مجموعه‌ای از تکنیک ها و روش ها، برای تعیین مشخصات سیگنال‌هایی است که مشخصات آنها در زمان تغییر می‌کند[20]. این نوع از تجزیه تحلیل همان گسترش یافته تبدیل فوریه است که مشخصات فرکانسی سیگنال در حوزه زمان تغییر می‌کند. برای شناسایی پارامترهای فرستنده، آنالیز فوریه سریع[1] به‌عنوان یکی از روش‌ها مورد استفاده قرار می‌گیرد. از این روش، خیلی از روش های پیچیده، از جمله روش STFT به‌منظور دست یافتن به پارامترهای سیگنال در طول زمان مشتق شده است[1]. طیف سیگنال ساده‌ترین و بصری‌ترین روش نمایش زمان-فرکانس یک سیگنال است که شامل توان دوم STFTی یک سیگنال محدودشده در یک پنجره است. طیف $S(\tau;f)$ را به‌صورت زیر می‌توان تعریف کرد[10]:

$$S(\tau.f) = \left| \int_{-\infty}^{+\infty} x(t)h^*(t - \tau)e^{-j2\pi ft}dt \right|^2 \quad (3)$$

در رابطه 3، $x(t)$ به‌عنوان سیگنال ورودی و $h(t)$ به‌عنوان پنجره است. طول $h(t)$ طول پنجره سیگنال $x(t)$ را نشان می‌دهد. یکی از روش‌های دیگر برای مشخص و استخراج پارامترهای سیگنال رادارهای LPI، توزیع واینر-ویل و یا WVD است که توسط آقای واینر ویل در سال 1932 به‌صورت رابطه 4 ارائه شد.

$$W_x(t,w) = \int_{-\infty}^{+\infty} x\left(t+\frac{\tau}{2}\right)x^*\left(t-\frac{\tau}{2}\right)e^{-jw\tau}d\tau \quad (4)$$

در رابطه 4، (*) نشان‌دهنده مزدوج سیگنال و w فرکانس زاویه‌ای و t به‌عنوان متغیر زمان است. یکی دیگر از روش‌هایی که برای آنالیز زمان-فرکانس سیگنال‌ها مورد استفاده قرار می‌گیرد توزیع چوئی-ویلیامز و یا CWD است. CWD پیوسته برای سیگنال ورودی $x(t)$ به‌صورت زیر تعریف می‌گردد:

[1]Fast Fourier Analysis(FFT)

[Downloaded from ic4i-journal.ir on 2026-11-24]

$$CWD_x(t,w) = \frac{1}{2\pi}\int_{\xi=-\infty}^{\infty} e^{-jw\tau} \left[\int_{\mu=-\infty}^{\infty} \sqrt{\frac{\sigma}{4\pi\tau^2}}\, e^{\frac{\sigma(\mu-t)^2}{4\tau^2}}\, x\left(\mu+\frac{\tau}{2}\right) x^*\left(\mu-\frac{\tau}{2}\right) d\mu\right] d\tau \quad (5)$$

که در آن w به‌عنوان فرکانس زاویه‌ای، σ فاکتور شیفت، که مقدار مثبتی می‌باشد و t به‌عنوان متغیر زمان است.

در این مقاله برای آنالیز سیگنال در حوزه زمان-فرکانس از روش STFT استفاده خواهیم کرد. بعد از اعمال روش STFT ، خروجی این مرحله به صورت یک تصویر رنگی به مرحله پیش پردازش داده خواهد شد که در بخش زیر توضیحات آن داده شده است.

4-2 پیش پردازش

پیش پردازش داده‌ها برای حل مشکل داده‌های دنیای واقعی که اغلب ناقص و احتمالاً خطاهای زیادی در آن وجود دارد استفاده می شود، مرحله پیش پردازش، داده‌ها را با تبدیل به یک قالب قابل درک، برای پردازش بیشتر آماده می‌کند. پیش پردازش داده ها در برنامه های مبتنی بر پایگاه داده مانند مدیریت ارتباط با مشتری و برنامه‌های مبتنی بر قاعده (مانند شبکه های عصبی) مورد استفاده قرار می‌گیرد و یک گام جدایی ناپذیر در یادگیری ماشین است زیرا کیفیت داده‌ها و اطلاعات مفیدی که می‌توان مستقیماً از آنها دریافت کرد بر توانایی مدل ما در یادگیری تأثیر می‌گذارد. به طور خلاصه، بسیار مهم است که داده‌های خود را قبل از تغذیه آنها در شبکه، پیش پردازش کنیم.

در این مقاله خروجی مرحله زمان-فرکانس به عنوان ورودی برای مرحله پیش پردازش است که هدف آن برای تغییر اندازه تصاویر است که اصطلاحا به این مرحله، مرحله نرمالیزه کردن هم اطلاق می‌گردد. نرمال سازی تکنیکی است که اغلب به عنوان بخشی از آماده سازی داده‌ها برای یادگیری ماشین استفاده می شود و هدف آن تغییر مقادیر ستون های عددی در مجموعه داده به یک مقیاس مشترک (به عنوان مثال بین 0 تا 1) است، بدون اینکه تفاوت در دامنه مقادیر تحریف شود. روش‌های متعددی برای نرمالیزه کردن داده‌ها وجود دارد که عبارتند از :

1-نرمالیزه کردن داده ها 2- بسط داده ها 3- استانداردسازی داده‌ها

استاندارد سازی داده ها بعنوان یکی از متداول‌ترین تکنیک‌های نرمال‌سازی مورد استفاده در یادگیری ماشین است، جایی که میانگین نمونه‌ها از تصویر کم و سپس نتیجه بر انحراف معیار نمونه تقسیم می‌شود. لذا اگر از تصویر به عنوان ورودی برخی الگوریتم‌های یادگیری ماشین استفاده شود بدلیل توزیع گاوسی با میانگین صفر و انحراف معیار واحد، بسیار مفید است. می توان استاندارد سازی داده‌ها را با استفاده از فرمول زیر انجام داد:

$$I_{new} = \frac{I - m_I}{\sigma_I} \quad (6)$$

که در آن I بعنوان تصویر ورودی و m_I ،σ_I به ترتیب بعنوان میانگین و انحراف معیار می باشد. خروجی این مرحله بعنوان ورودی شبکه های CNN (گوگل نت و الکس نت) است.

3. ساختار شناسائی و کلاس‌بندی سیگنال رادارهای LPI

در این قسمت نحوه آشکارسازی و کلاس بندی سیگنال رادارهای LPI تشریح می‌گردد.

3-1 بلوگ دیاگرام

در این قسمت بلوک دیاگرام روش پیشنهادی را تشریح می کنیم. روش پیشنهادی در این مقاله برای آشکارسازی و کلاس بندی سیگنال رادارهای LPI از 4 مرحله زیر تشکیل شده است:

1-آنالیز زمان-فرکانس

2-مرحله پیش پردازش

3-استخراج ویژگی‌ها

[Downloaded from ic4i-journal.ir on 2026-11-24]

4-تشخیص و آشکارسازی سیگنال رادارهای LPI

همانطور که در بلوک دیاگرام شکل 1 نشان داده شده است ، برای شـناسـایی پارامترهای سـیگنال، ابتدا سـیگنالRF1 از سیستم دریافت شده و سپس در حوزه زمان-فرکانس تجزیه و تحلیل می شود. خروجی این مرحله با صورت یک تصویر دو بعدی در حوزه زمان-فرکانس از سـیگنال اسـت. خروجی این مرحله وارد بلوک پیش پردازش شـــده و نرمالیزه می‌شـــود تا آماده ورود به مرحله آموزش توســط شـــبکه یادگیری عمیق شـــود. خروجی مرحله پیش پردازش به شـــبکه‌های یادگیری عمیق منتقل می‌شـــود تا به خوبی آموزش ببینند و به عملکرد مطلوب برسند. پس از آموزش شبکه در قسمت تشخیص، از تصـاویر آزمون برای تعیین عملکرد آشـکارسـازی سـیگنال و تشخیص نوع واقعی مدولاسیون استفاده می شود.

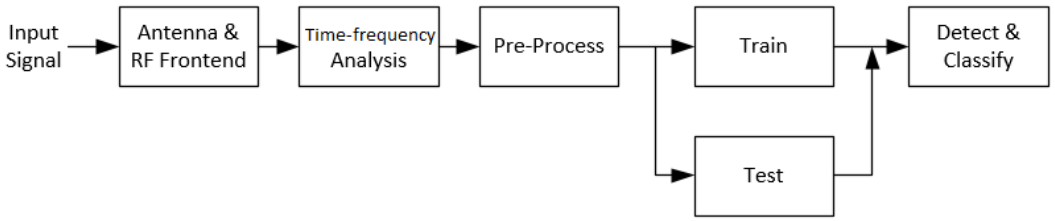

شکل1- بلوک دیاگرام روش پیشنهادی مقاله برای تشخیص و کلاس‌بندی سیگنال راداهای LPI

3-2. شبکه‌های عصبی کانولوشن

یکی از کاربردهای روش یادگیری عمیق به‌کارگیری داده‌ها جهت آموزش الگوریتم‌های شبکه‌های عصبی برای کلاس‌بندی انواع مختلفی از اشیاء است. شبکه‌های CNN به‌عنوان الگوریتم‌های یادگیری عمیق یک ابزار قدرتمند برای آنالیز و کلاس‌بندی تصاویر است. دو شبکه یادگیری عمیق مورد استفاده در این مقاله در حوزه کلاس‌بندی تصاویر، روش‌های گوگل‌نت و الکس‌نت است برای بکار گیری این دو روش در آشکارسازی و کلاس‌بندی سیگنال رادارهای LPI بایستی تغییراتی را در این شبکه ها اعمال کرد تا بتوان برای هدف این مقاله استفاده کرد. لذا از این به بعد تغییرات اعمال شده را برای شبکه گوگل نت را با عنوان method1 و تغییزات اعمال شده برای شبکه الکس نت را با عنوان method2 نام گذاری می کنیم. توضیحات این دو روش شبکه و بهبود یافته آنها به صورت زیر بیان می شوند.

3-2-1. معماری شبکه الکس‌نت

همان‌طور که در شکل (2) نشان داده شده است این شبکه دارای 8 لایه می‌باشد که شامل 5 لایه کانولوشن و 3 لایه اتصال کامل است. همچنین ورودی این شبکه به‌صورت یک تصویر224×224 است. در این معماری ابتدا از تصویر ورودی با استفاده از 96 ضریب مجزا عمل کانولوشن گرفته می‌شود که خروجی به‌صورت یک تصویر 55×55 در می‌آید در مرحله بعد با استفاده از یک لایه مکس پولینق با اندازه 5×5 خروجی به‌صورت یک تصویر 27×27 در می‌آید. این عملیات را در 5 مرحله انجام می‌دهیم تا به لایه‌های اتصال کامل برسیم. در این قسمت ابتدا داده‌ها از حالت ماتریسی به حالت برداری در آمده و بعد از 3 لایه اتصال کامل می‌توان به تعداد کلاس‌ها، خروجی را مشاهده کرد.

[Downloaded from ic4i-journal.ir on 2026-11-24]

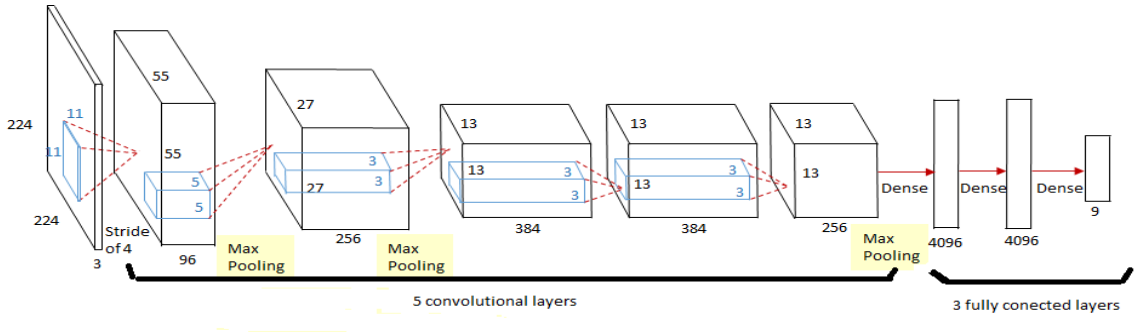

شکل (2): معماری شبکه الکس‌نت [21]:

2-2-3. معماری شبکه گوگل‌نت

معماری مدل شبکه یادگیری عمیق گوگل‌نت توسط شرکت گوگل ارائه شده است. این شبکه، یک شبکه بسیار پیچیده با عمق 27 لایه است که کیفیت آن در زمینه شناسایی و طبقه بندی ارزیابی می‌شود [22]. طراحان این شبکه برای ایجاد یک شبکه عمیق با افزودن لایه‌ای به نام inception باعث پیشرفت بزرگی در شناسائی و طبقه‌بندی شبکه‌های CNN شدند. معمولا در یک لایه شبکه CNN، یک دسته فیلتر 3×3 و یا 5×5 و یا لایه مکس پولینق[1]وجود دارد که وجود همگی این لایه‌ها باعث بالا رفتن قدرت مدل‌سازی یک شبکه مفید می‌شود. همانطور که در شکل (3) مشاهده می‌گردد در ماژول inception از یک دسته فیلتر 3×3 و 5×5 و لایه مکس پولینق استفاده کرده است. این بدان معنی است که آنها به جای افزودن یک لایه اندازه فیلتر خاص، همه فیلترهای1×1 ، 3×3 و 5×5 را اضافه کرده و بر روی خروجی لایه‌های قبلی ترکیب می‌کنند. این امر منجر به شناسایی و دسته بندی تصاویری می‌شود که اطلاعات کمتری در آن وجود دارد. از آنجا که لایه پولینق برای بهبود عملکرد شبکه CNN بسیار ضروری است، لذا ماژول inception نیز دارای لایه پولینق مجزائی است.

همچنین در ماژول inception خروجی همه فیلترها بهم پیوسته و به عنوان ورودی به لایه بعدی منتقل می‌شود [19]. معماری گوگل‌نت دارای 9 ماژول آغازین است که بصورت خطی در کنار هم قرار گرفته‌اند.

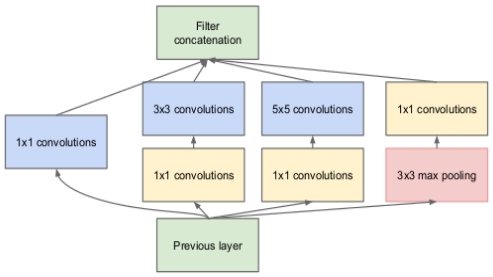

شکل3: ماژول inception

3-2-3. تشریح method1,2

لازم به ذکر اســـت که معماریهای گوگل‌نت و الکس‌نت برای مقدار زیادی از داده‌ها در حدود 1,2 میلیون داده برای آموزش، 50 هزار داده برای اعتبار سنجی[2] و 150 هزار داده برای تست گو گل نت و 100 هزار داده برای تســـت الکس نت طراحی شـــده‌اند. در حالی که تعداد داده‌ها در این مقاله 200 هزار داده برای آموزش، 20 هزار داده برای اعتبار سنجی و 20 هزار داده برای تست استفاده شده است. تعداد کم داده‌ها باعث می شود که شـبکه‌های انتخاب شـده در زمان آموزش به حالت اشـباع[3] وارد شـود همچنین نویز آغشـته به ورودی نیز امکان اشـباع شـدن شـبکه را دارد. در این مقاله برای جلوگیری از اشـباع شـبکه بعد از لایه کانولوشـن از لایه رگولاریزه[4]اسـتفاده شـده است. یعنی روش رگولاریزه با پارامتر تنظیم λ ، بدون افزایش قابل توجهی دربایاس مدل، واریانس مدل را به طور قابل توجهی کاهش می دهد. بصورت عمومی رگولاریزیشن به سه روش L1, L2, و (L1+L2)-regularization بیـان

[1]Max pooling
[2]vallidation
[3]saturate
[4]regularization

[Downloaded from ic4i-journal.ir on 2026-11-24]

می‌گردد. روش رگولاریزیشن مورد استفاده در این مقاله روش L2 است که بصورت فرمول 7 بیان می‌گردد.

$$\text{L2-regularization}=\lambda \sum_{i=0}^{n} \theta_i^2 \qquad (7)$$

برای روش‌های گوگل‌نت و الکس‌نت L2-regularization به ترتیب با ضـــرایب $\lambda = 10^{-6}$ و $\lambda = 10^{-4}$ انتخاب شـــده اســـت. این روش‌ها بعنوان روش‌های method1 برای معماری گوگل نت و method2 برای معماری الکس نت نامیده شده‌اند.همچنین برای جلوگیری از اشباع توابع غیرخطی فعالیت، همانند ســـیگموید[1]از لایه پس انتشـــار خطا[2]اســـتفاده کرده‌ایم. شـــکل 4 معماری گوگل‌نت را قبل و بعد از اضـــافه کردن لایه L2-regularization را نشـــان می‌دهد. همانطور که در شکل 4 مشاهده می گردد حالت اشباع که در معماری گوگل نت اتفاق افتاده با اضـــافه کردن لایه مورد نظر از بین رفته و داده های اعتبار ســـنجی امکان دنبال کردن داده های آموزش را داشته و در این حال امکان پیشگوئی داده‌های جدید وجود خواهد داشت.

همچنین شـــکل 5 معماری الکس‌نت را قبل و بعد از اضـــافه کردن لایه L2-regularization، نشـــان می‌دهد. همانند توضـــیحاتی که برای روش گوگل نت داده شـــد معماری الکس‌نت نیز امکان پیشگوئی داده‌های جدید را پس از اضافه کردن لایه مورد نظر، خواهد داشـــت. بنابراین در مقاله این روش‌ها با عنوان روش‌های method1 و method2 شناخته خواهند شد.

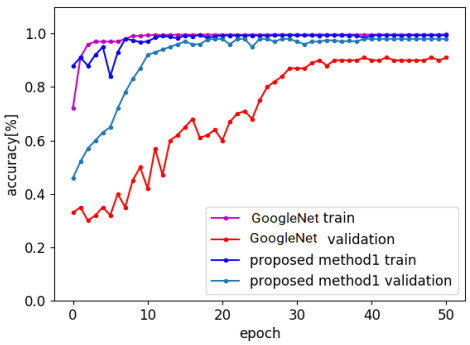

شکل(4) روش گوگل نت و روش method1

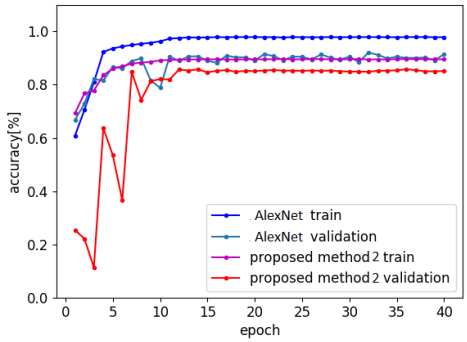

شکل(5) روش الکس نت و method2

4. ارائه روش پیشنهادی برای آشکار سازی و کلاس‌بندی سیگنال رادارهای LPI

هدف از این مقاله آشکارسازی و کلاس‌بندی سیگنال رادارهای LPI، با اســـتفاده از یادگیری عمیق اســـت. دانشـــمندانی که در زمینه یادگیری عمیق فعالیت می‌کنند معماری‌های متفاوتی را برای این روش پیشـــنهاد داده‌اند که هر کدام از این روش‌ها تکمیل‌کننده روش قبلی می‌باشد. اولین روش که در این حوزه معرفی شده است شبکه لی‌نت است که در سال 1998 توسط آقای لی نت و همکارانش معرفی شـــد ولی به‌دلیل نبود ســـخت‌افزار لازم که بتواند این شـــبکه راه‌اندازی کند، در آن زمان توجه زیادی به این روش نشـــد. نهایتاً در ســـال 2012 با پیشرفت سخت‌افزارهای رایانه‌ای امکان راه‌اندازی این شبکه

[1]sighmoid

[2]batch normalization

[Downloaded from ic4i-journal.ir on 2026-11-24]

بوجود آمد. اولین کاربرد این شـــبکه برای تشـــخیص اعداد دست‌نوشته 0 تا 9 انگلیسی که به مجموعه MNIST معروف هســـتند، بود. دانشـــمندانی که در این حوزه فعالیت می‌کردند دریافتند که با گســـترش این شـــبکه‌ها از نظر تعداد و ســـاختار لایه‌ها می‌توانند نتایج بهتری را برای کارهای متفاوتی از جمله برای ا ستفاده در خودروهای بدون سرنشین و... بگیرند. برای رســـیدن به این منظور آقای الکس‌نت و همکارانش توانســـتند دومین معماری در این حوزه را در ســـال 2012 که به نام الکس‌نت معروف اســـت، به ثبت برســـانند. این روند همچنان ادامه داشت و در سالهای بعدی معماری‌های متفاوت‌تر بادقت عملکرد بالائی ارئه شـــد. یکی از این معماری ها معماری گوگل‌نت بود که توسط محققان شرکت گوگل ارائه شد.

هدف از ارائه این مقاله اسـتفاده از دو معماری الکس‌نت و گوگل‌نت در یادگیری عمیق برای آ شکار سازی و کلاس‌بندی سیگنال رادارهای LPI ا ست. برای این منظور 9 نوع متفاوت از سیگنال این رادارها برای آشکارسازی و کلاس‌بندی انتخاب شـــده‌اند که عبارت‌اند از: LFM,P1, P2, P3, P4 ,T1, T2,T3, T4

قبل از ارائه نتایج شـــبیه‌ســـازی‌های انجام‌شـــده، ابتدا نحوه پیاده‌سازی این معماری‌ها در محیط نرم‌افزاری و سخت‌افزاری، مشـــخصـــات سـیگنال‌های اسـتفاده‌شـده و روند شـبیه‌سـازی، توضیحاتی ارائه داده می‌شود.

4-1. مشخصات محیط نرم‌افزاری و سخت‌افزاری

ت‌مامی پیاده‌ســـازی‌ها در لینوکس و در محیط ابونتو نســـخه 16,04(Ubuntu 16.04) انجـام گرفتـه اســـت. از زبـان برنامه‌نویسی پایتون با نصب کتابخانه‌های تنسور فلو و کراس که مخصوص استفاده در یادگیری عمیق می‌باشند استفاده شده است. سخت‌افزار مورد استفاده برای این مقاله، در جدول (2) اشاره شده است.

جدول (2): مشخصات سخت‌افزاری استفاده شده

RAM	16G DDR4 2400
CPU	CORE I7-7700
M.B	ASUS Z270 GAMING
GHRAPHIC	VGA ASUS 8G GTX1070
POWER	GREEN 600W

4-2. مشخصات سیگنال‌های استفاده شده

مشخصات سیگنال‌های مورد استفاده در این مقاله در جدول (3) نشان داده شده است. که در آن F_s نرخ نمونه‌برداری، f_c فرکانس سـیگنال کریر، BW پهنای باند مدولاسـیون، SNR نسـبت سـیگنال به نویز سـیگنال‌ها اسـت و همچنین m در سیگنال‌های چند فازی به عنوان گام فرکانسی و در سیگنال‌های چند زمانه، تعداد فازهای مورد اسـتفاده در زمان‌های مورد نظر است.

جدول (3): مشخصات سیگنال‌های استفاده شده

Modulation type	SNR	F_s	f_c	BW	m
LFM	-10dB~0dB	200MHz	1MHz_50MHz	1MHz_20MHz	-
P1-4	-10dB~0dB	200MHz	constant	1MHz_20MHz	16,25,36
T1-4	-10dB~0dB	200MHz	constant	1MHz_20MHz	2:10

4-3. روند شبیه‌سازی‌های انجام گرفته

زمانی که یک ســـیگنال از کانال هوائی توســـط یک گیرنده دریافت می‌گردد مراحل زیر طی می شود تا سیستم بتواند یک ســـیگنال را از نویز تشـــخیص داده و همچنین در صـــورت تشخیص سیگنال بتواند کلاس سیگنال را برای ما مشخص کند.

4-3-1. آنالیز زمان-فرکانس

دلیل استفاده از آنالیز زمان-فرکانس به‌عنوان یک پیش پردازش این اســـت که طیف ســـیگنال را در دو حوزه زمان و فرکانس

[Downloaded from ic4i-journal.ir on 2026-11-24]

مشخص می‌کند در این صورت به راحتی می‌توان مشخصات سیگنال را از آن استخراج کرد. ولی محدودیتی که این روش دارد با استفاده از این روش در SNRهای پائین مشخصات سیگنال دریافتی را نمی‌توان استخراج کرد البته قابل ذکر است که در روش‌های متفاوت این مقدار SNR متفاوت است. روش آنالیز زمان-فرکانسی که در این مقاله استفاده شده است روش تبدیل فوریه زمان کوتاه و یا همان STFT است. بعد از انجام این پیش‌پردازش خروجی این مرحله به‌صورت یک تصویر با فرمت JPG به شبکه CNN داده می‌شود.

4-3-2. شبکه کانولوشنال (CNN)

خروجی آنالیز زمان-فرکانس بعد از طی فرایندی به عنوان ورودی برای شبکه CNN محسوب می‌شود. برای اینکه بتوان تصاویر خروجی از روش STFT را به‌عنوان ورودی شبکه CNN قرار دارد بایستی با توجه به شرایط حاکم بر شبکه‌های CNN پیش پرداز شی دومی را نیز بر روی تصاویر انجام داد. این پیش‌پردازش یک گام اساسی در یادگیری ماشینی است زیرا کیفیت داده‌ها و اطلاعات مفیدی که می‌توان از آنها به دست آورد، مستقیماً بر توانایی مدل ما برای یادگیری تأثیر می‌گذارد. این پیش‌پردازش شامل تغییر اندازه تصویر با توجه به نوع شبکه CNN و نرمالیزه کردن تصویر است. خروجی این پیش پردازش به‌عنوان ورودی برای شبکه CNN محسوب می شود. نهایتاً از خروجی شبکه CNN می‌توان به‌عنوان یک روش برای تشخیص اتوماتیک نوع سیگنال رادارهای LPI استفاده کرد. شبکه‌های CNN مورد استفاده در این مقاله، معماری‌های لی‌نت و الکس‌نت است.

4-3-3. نحوه آموزش شبکه CNN

قبل از اینکه بتوانیم از روش ارائه شده در این مقاله برای آشکارسازی و کلاس‌بندی انواع سیگنال‌های LPI استفاده کرد باید شبکه CNN آموزش ببیند. آموزش به این معنا که بایستی، تعداد زیادی از تصاویر در کلاس انواع مدولاسیون‌ها(در این‌جا هر نوع مدولاسیون را به‌عنوان یک کلاس کاری برای شبکه CNN در نظر می‌گیریم) به شبکه CNN داد تا شبکه بتواند انواع کلاس‌ها را به خوبی یاد گرفته و در مرحله بعد به ازاء هر ورودی که گیرنده دریافت می‌کند نوع مدولاسیون را تشخیص دهد. نحوه آموزش شبکه CNN به‌صورت زیر است.

در این مقاله از 9 مدولاسیون متفاوت (LFM,P1,P2,P3,P4,T1,T2,T3,T4) رادارهای LPI به همراه نویز، با مشخصاتی که در جدول 3 نشان داده شده برای تولید سیگنال‌ها جهت آموزش در دو شبکه کانولوشنال الکس‌نت و گوگل‌نت استفاده شده است. به همین منظور برای هر نوع از این مدولاسیون‌ها به تعداد 20 هزار تصویر سیگنال با SNRهائی در بازه 10dB- تا 0dB در نرم افزار متلب با استفاده از روش STFT تولید شده که خروجی آن به‌صورت یک تصویر ذخیره می‌گردد و جمعا 200,000 تصویر برای آموزش شبکه‌های پیشنهادی، استفاده شده است. همچنین برای هر نوع مدولاسیون تعداد 2000 تصویر سیگنال در بازه 20dB- تا 0dB که جمعا 20000 هزار تصویر می‌گردد، برای انجام تست بر روی انواع مدولاسیون‌ها و بررسی دقت عملکرد[1]این روش‌ها در زمان آموزش شبکه استفاده می‌شود.

5. نتایج شبیه‌سازی

قبل از انجام مقایسه روش ارائه شده در این مقاله با روش‌های دیگر ابتدا امکان آشکارسازی سیگنال‌های راداری اشاره شده در این مقاله را بررسی می‌کنیم. برای این منظور ابتدا بهبود یافته شبکه‌های الکس‌نت با نام method1 و بهبود یافته گوگل‌نت با نام method2 را با دو کلاس نویز و سیگنال(شامل 9 نوع متفاوت سیگنال راداری اشاره شده در این مقاله) هر کدام با 90,000 سیگنال با SNR در محدوده 10dB- تا 0dB که به‌صورت تصویر ذخیره شده، جهت آموزش به شبکه‌های مورد نظر می‌دهیم. نتایج حاصل از این شبیه سازی که در شکل 6 نشان داده شده است نشان می‌دهد روش method1 تا SNR، 15dB- دقت عملکرد آشکارسازی

[1] accuracy

[Downloaded from ic4i-journal.ir on 2026-11-24]

سیگنال از نویز 100درصد بوده و در SNR، 20dB- به 93 درصد می‌رسد یعنی امکان تشخیص سیگنال از نویز که مسئله آشکارسازی را بیان می‌کند در SNRهای پائین برای این روش بسیار مناسب است. همچنین در روش method2 تا SNR، 11dB- دقت عملکرد آشکارسازی سیگنال از نویز 100درصد بوده و در SNR، 20dB- به 88 درصد می‌رسد با مقایسه دو روش می‌توان نتیجه گرفت که عملکرد روش method1 در مقایسه با روش method1 بهتر است ولی هر دو نتایج قابل قبولی را دارند.

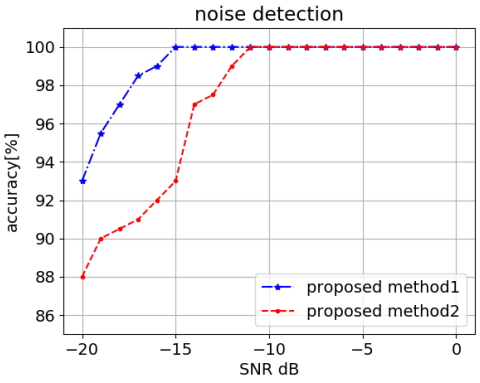

شکل(6): نتایج آموزش شبکه‌های method1 و method2 برای دو کلاس کاری در محدوده SNR، 20dB- تا 0dB

5-1. مقایسه عملکرد روش‌های پیشنهادی با روش‌های [10و14]

در این مقاله روش‌های پیشنهادی را با روش‌های مطرح شده در مراجع [10و14] را در محدوده SNR، 20dB- تا 0dB مقایسه خواهیم کرد. برای این کار ابتدا 2000 سیگنال با SNR یکسان در هر کلاس تولید می‌کنیم در هر SNR برای هر کلاس کاری پارامتر های پهنای باند(BW)، فرکانس کریر(f_c) و فرکانس نمونه برداری(F_s) متفاوت خواهد بود. سپس STFT هر یک از سیگنال‌ها محاسبه و خروجی این مرحله به صورت یک تصویر ذخیره و به مرحله پیش پردازش داده می‌شود در مرحله پیش پردازش طبق توضیحات داده شده در بخش‌های قبلی سایز تصویر متناسب با نوع شبکه تغییر داده شده و نهایتا نرمالیزه می‌شود بعد از مرحله نرمالیزه، داده‌ها به شبکه CNN مورد نظر که بعنوان method1,2 در این مقاله نام‌گذاری شده است تزریق می‌شوند. داده‌های تزریق شده به شبکه به دو قسمت تقسیم می شوند قسمت اول 90 درصد داده‌ها است که بعنوان داده‌های آموزش بوده و 10 درصد بقیه بعنوان داده‌های اعتبار سنجی می‌باشند. ابتدا شبکه‌های CNN توسط 90 درصد داده‌ها آموزش داده شده و از 10 درصد باقی مانده بعنوان اعتبار سنجی داده‌ها استفاده می‌شوند بطوریکه این داده‌ها، آموزش مناسب شبکه توسط 90 درصد داده ها را نشان می‌دهد. نتیجه مقایسه بین دو روش method1,2 توسط مولفه نرخ عملکرد[1]در SNR های متفاوت سنجیده خواهد شد.

شکل7، 9 نوع مدولاسیون استفاده شده در این مقاله را که در حوزه زمان-فرکانس تولید شده‌اند را نشان می دهد.

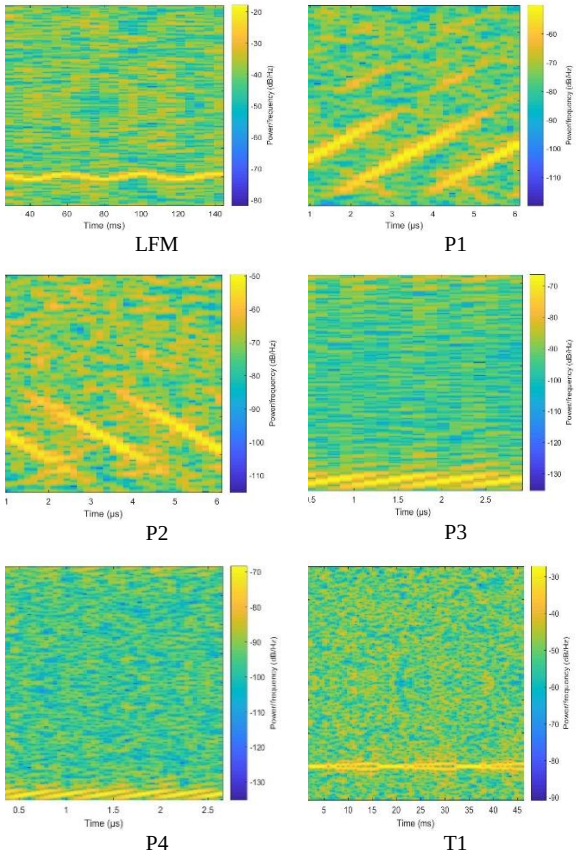

[1]accuracy rate

[Downloaded from ic4i-journal.ir on 2026-11-24]

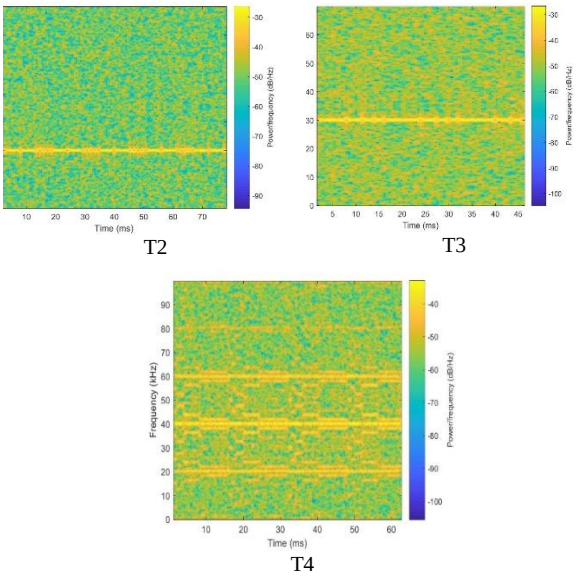

شکل(7): نمایش 9 نوع مدولاسیون استفاده شده در این مقاله

شکل 8 مقایسه بین روشهای method1,2 و روش‌های ارائه شده در مراجع 10 و 14 که اخیرا منتشر شده است را برای حالت کلی(حالتی که دقت عملکرد تمامی مدولاسیون ها به‌صورت هم‌زمان محاسبه می‌شود) و مدولاسیون LFM نشان می‌دهد. کارائی روش‌های ارائه شده در مراجع [10و14] به ترتیب تا SNRهای 4db- و 8db- مورد بررسی قرار گرفته‌اند. همانطور که در شکل(8-الف) نشان داده شده است روش‌های method1,2 در SNR=-4db دارای دقت عملکرد 100 درصدی بوده که در مقایسه با روش [10] به اندازه 8db در حالت کلی بهتر است. بخصوص در همین SNR روش‌های method1,2 دارای دقت عملکرد 100 درصدی می باشند در حالی که روش‌های [10,14] در همین SNR حدودا دارای دقت عملکرد 87 درصدی در حالت کلی می‌باشند که این حالت نشان از کارائی بهتر روش های method1 و method2 در مقایسه با روش‌های [10,14] است. همچنین همانطور که در شکل(8-الف) نشان داده شده است در SNR=-8db دقت عملکرد روش method1 برابر با 99,99 در صد برای حالت کلی است در حالی که در همین SNR برای روش‌های method2 و [14] به ترتیب برابر با 90 و 72 درصد است. بطور مشابه همانطور که در شکل(8-ب) برای مدولاسیون LFM نشان داده شده است روش‌های پیشنهادی method1 و method2 به طور چشمگیری دارای عملکرد بهتری نسبت به روش‌های [10,14] می باشند.

شکل 9 مقایسه بین روشهای پیشنهادی method1,2 و روش ارائه شده در [10] را نشان می دهد. مدولاسیون‌هائی که در [10] برای کلاس‌بندی استفاده شده، مدولاسیون‌های LFM, BPSK, Costas, Frank, T1, T2, T3, T4 است که 5 نوع مدولاسیون LFM, T1, T2, T3 , T4 را به‌دلیل اشتراک با مدولاسیون‌های مورد استفاده در این مقاله، برای مقایسه انتخاب شده‌اند.

همانطور که در شکل های 8و9 نشان داده شده است عملکرد روشهای method1 و method2 برای مدولاسیون‌های LFM و T4 (برای SNR های بالاتر از 4db-) در میان تمامی مدولاسیون‌های مورد بحث در این مقاله دارای عملکرد بسیار خوبی نسبت به روش ارائه شده در [10] را دارد.

شکل 10 مقایسه بین روش‌های پیشنهادی method1 و method2 را با روش ارائه شده در [14] نشان می‌دهد. مدولاسیون‌هائی که در [14] برای کلاس‌بندی استفاده شده، مدولاسیون‌های LFM, BPSK, Costas, Frank, P1, P2, P3, P4 است که 5 نوع مدولاسیون LFM, P1, P2, P3 , P4 به‌دلیل اشتراک با مدولاسیون‌های مورد استفاده در این مقاله، برای مقایسه انتخاب شده‌اند.همانطور که در شکل 10 نشان داده شده است دقت عملکرد روش‌های پیشنهادی یعنی method1 و method2 در مقایسه با روش [14] در مدولاسیون‌های LFM, P1, P2, P3, P4 بسیار بهتر است. بهترین دقت عملکرد برای روش [14] در مدولاسیون P2 اتفاق افتاده که در SNR های بالاتر از 2db- دارای دقت عملکرد 100 درصدی است. اما برای SNRهای پائین‌تر از 2db- روش‌های method1 و method2 دارای وضعیت مناسبتری نسبت به روش [14] می‌باشند.

[Downloaded from ic4i-journal.ir on 2026-11-24]

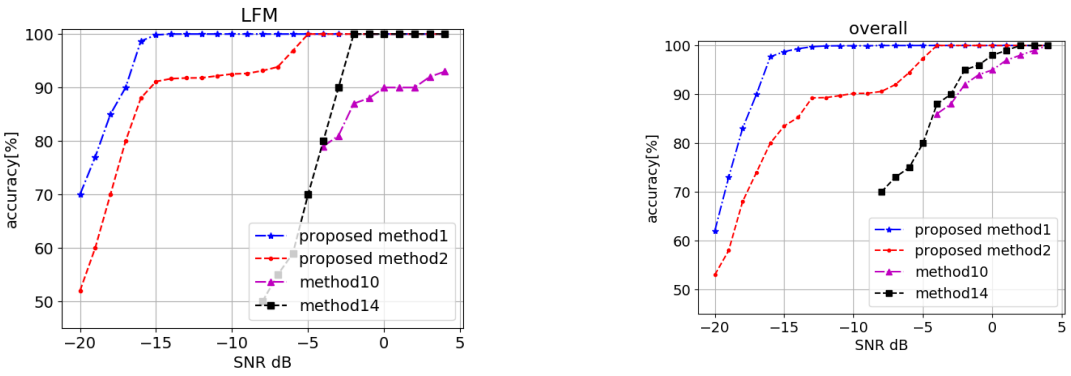

ب الف

شکل(8): مقایسه روشهای پیشنهادی این مقاله method1 و method2 با روش‌های ارائه شده در [10,14] الف- حالت کلی ب-مدولاسیون LFM

با توجه به شکل های 8،9،10 می توان نتیجه گرفت که روش پیشنهادی method1 در تمامی مدولاسیون‌ها دارای دقت عملکرد بسیار بهتری نسبت به روشهای method2 و [10,14] است. در شکل (8-الف) مشاهده می‌گردد که در SNR=-15db دقت عملکرد روش‌های method1 و method2 به ترتیب برابر با 98,7 و 80 درصد است. این نتایج نشانگر این موضوع است که روش method1 دارای دقت عملکرد بهتری نسبت به روش method2 بوده و می‌تواند گزینه مناسبی برای تشخیص و کلاس بندی سیگنال رادارهای LPI باشد.

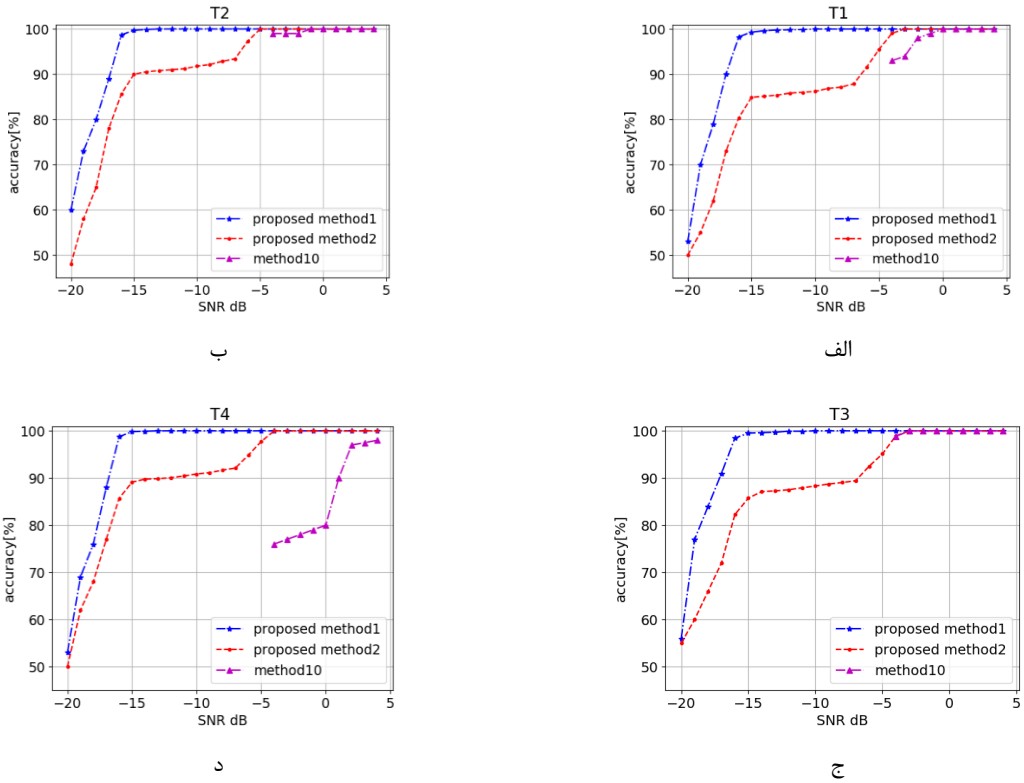

ب الف

د ج

شکل(9): مقایسه روش‌های method1 و method2 با روش ارائه شده در [10] الف- مدولاسیون T1 ب-مدولاسیون T2 ج-مدولاسیون T3 د-مدولاسیون T4

[Downloaded from ic4i-journal.ir on 2026-11-24]

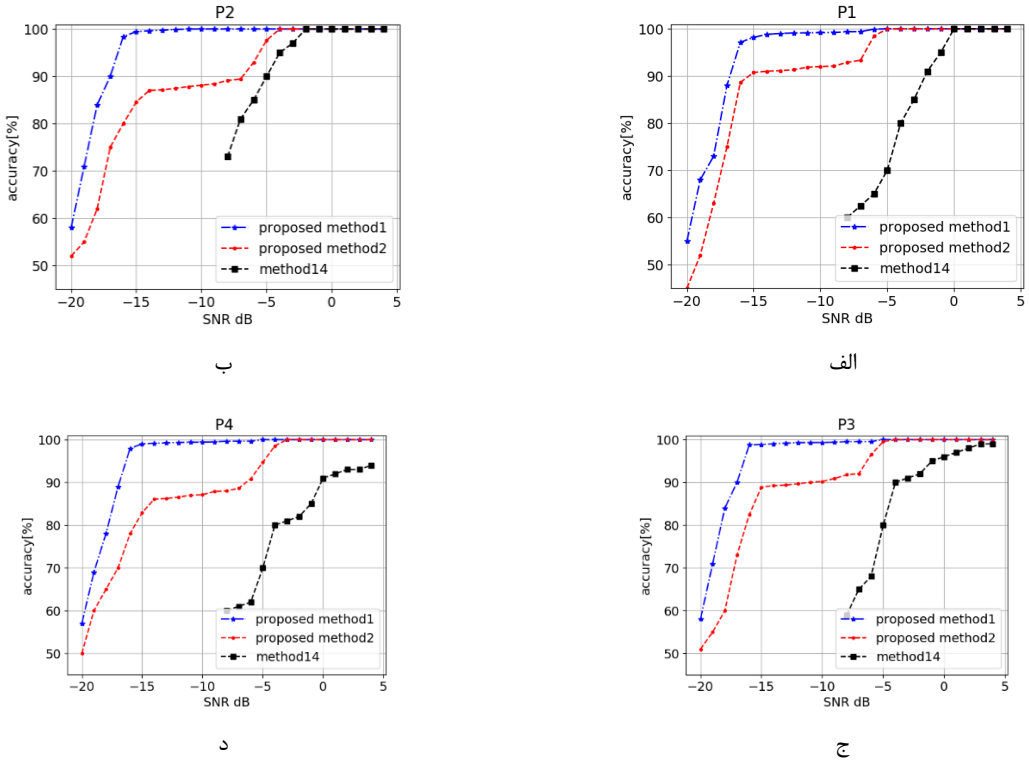

شکل(10): مقایسه روش‌های method1 و method2 با روش ارائه شده در [14] الف- مدولاسیون P1 ب-مدولاسیونP2 ج-مدولاسیونP3 د-مدولاسیون P4

2-5. ماتریس درهم ریختگی (کانفیوژن)

در علم یادگیری ماشـــین، بخصـــوص در زمینه کلاس‌بندی ورودی‌ها، ماتریس کانفیوژن به‌عنوان یک ماتریس خطا شناخته می‌شـــود. در حقیقت ماتریس کانفیوژن یک جدول اســـت که برای تعیین عملکرد کلاس‌بندی یک مدل، بر روی ورودی‌هائی که به‌عنوان تســـت شـــبکه مورد اســـتفاده قرار گرفته‌اند، بکار می‌رود. جـدول (4) مـا تریس کـا نفیوژن را برای روش method1 در SNR، 15dB- نشـــان می‌دهد. این جدول برای 9 نوع مدولا سیون به همراه نویز تهیه شده ا ست. تعداد تصاویر تست که برای هر کدام از 10 نوع متفاوت از سیگنال‌ها در نظر گرفته شده است هر کدام 2000 تصویر است. با دقت در جدول مشـــخص اســـت بهترین عملکرد برای تـمامی سیگنال‌ها رخ داده است.

شایان ذکر است که، همچنین جدول شامل کلاس null است که فقط مربوط به نویز اســت. همانطور که در جدول مشـاهده شـــد ، روش پیشـــنهادی method1 به عنوان یک روش کلاس‌بندی و هم یک الگوریتم تـشخیص، عملکرد قابل قبولی دارد.

جدول4- ماتریس درهم ریختگی برای روش method1 در SNR= -15dB

mod	LFM	P1	P2	P3	P4	T1	T2	T3	T4	None
LFM	1990	1	0	2	1	3	1	0	1	1

[Downloaded from ic4i-journal.ir on 2026-11-24]

P1	3	1982	2	3	3	1	2	0	1	3
P2	3	2	1986	2	3	1	1	0	0	2
P3	3	2	3	1974	4	2	3	1	2	6
P4	5	2	3	3	1978	1	3	1	2	2
T1	3	2	1	0	1	1982	4	2	3	2
T2	4	2	1	2	2	4	1976	3	3	3
T3	2	1	1	2	1	2	4	1982	3	2
T4	2	0	1	0	1	2	5	6	1979	4
None	1	0	1	0	1	1	1	0	1	1994

3-5. زمان پردازش

مدت زمان پردازش برای آموزش روش method1 ، با توجه به بیشتر بودن تعداد لایه‌های این روش نسبت به روش method2، 128 ساعت و 50 دقیقه و برای روش method2، 100 ساعت و 28 دقیقه طول کشیده است. همچنین با عنایت به اینکه در مرحله تست از 2000 تصویر برای دو روش method1,2 استفاده شده است، برای روش method1 این مرحله 12 دقیقه و42 ثانیه، و برای روش method2، 8 دقیقه و 28 ثانیه طوی کشیده است.

6. نتیجه گیری

معماری گوگل‌نت بعنوان یکی از مهمترین شبکه‌های علوم یادگیری عمیق است که امکان آشکارسازی و کلاس‌بندی تصاویر را دارد. در راستای جلوگیری از اشباع این شبکه با افزودن لایه رگولاریزیشن L2 ، نتایج بسیار خوبی در راستای تشخیص و کلاس‌بندی سیگنال رادارهای LPI بدست آمد که این روش بعنوان روش method1 نام گذاری شد. همچنین با اعمال همین تغییر در معماری الکس‌نت، تغییر یافته این معماری، با عنوان روش method2 نام گذاری شد که در این روش نیز نتایج خوبی را در راستای اهداف این مقاله بدست آمد. روش های پیشنهادی method1,2 و همچنین روش STFT برای آنالیز سیگنال در حوزه زمان-فرکانس برای آشکار سازی و کلاس بندی 9 نوع از سیگنال رادارهای LPI (P4,T1,T2,T3,T4 P3, P2, P1, LFM,) با SNRهائی در محدوده 20dB- تا 0dB انجام شد. نتایج بدست آمده نشان می‌دهد که روش method1 در SNR=-15db دارای دقت عملکرد 98,70 درصدی می‌باشد در مقابل روش method2در همین SNR دارای دقت عملکرد 80 درصدی است. همچنین کارائی روش method1 در مقایسه با روش‌های ارائه شده در مراجع [10,14] دارای دقت عملکرد بسیار بالائی است. همانطور که در شکل‌های 8,9,10 قابل مشاهده است SNR لازم برای رسیدن به دقت عملکرد 100 درصدی در روش [10]، 2db، برای روش [14]، 2db- ، برای روش method2 این عدد برابر با 4db- و برای روش method1 برابر با 13db- است. بنابراین، می‌توان نتیجه گرفت که روش پیشنهادی method1 از روشهای تشخیص و طبقه‌بندی سیگنال رادارهای LPI موجود، بهتر عمل می‌کند و می‌تواند در عمل به کار گرفته شود.

به‌عنوان کارهای آتی می‌توان برای استخراج مشخصات این نوع از سیگنال‌ها در SNRهای پائین از پردازش سیگنال در حوزه یادگیری عمیق استفاده کرد.

[Downloaded from ic4i-journal.ir on 2026-11-24]

7. مراجع

[1] P. E. Pace, ‘‘Detecting and Classifying Low Probability of Intercept Radar’’. Norwood, MA, USA: Artech House, 2009.

[2] Seung-Hyun Kong, Minjun Kim, LinhManh Hoang, And Eunhui Kim, ‘‘Automatic LPI Radar Waveform Recognition Using CNN,’’ IEEE Access, Vol 6, 2018, pp. 4207-4219

[3] Chao Wang, Hao Gao and Xu-Dong Zhang, “Radar Signal Classification Based on Auto-correlation Function and Directed Graphical Model,” 6th International Conference on Signal Processing, Communications and Computing (ICSPCC), Hong Kong, August 2016.

[4] . K. Konopko, Y. P. Grishin and D. Jańczak, "Radar signal recognition based on time-frequency representations and multidimensional probability density function estimator," Signal Processing Symposium, 2015, pp. 1-6.

[5] D. Li, R. Yang, X. Li and S. Zhu, “Radar signal modulation recognition based on deep joint learning,” IEEE Access, vol. 8,pp.48515-48528,2020. Doi:10.1109/ACCESS.2020.2978875.

[6] S. Wei, Q. Qu, M. Wang, et al., “Automatic modulation recognition for radar signals via multi-branch ACSE networks,” IEEEAccess,vol.8,pp.94923-94935,2020. Doi: 10.1109/ACCESS.2020.2995203..

[7] L. Cohen, ``Time-frequency distributions A review," Proc. IEEE, vol. 77, no. 7, pp. 941-981, 1989.

[8] H. Zhang, G. Bi, W. Yang, S.G. Razul, C.M.S. See, "IF estimation of FM signals based on time-frequency image," Aerospace and Electronic Systems, IEEE Transactions on, pp. 326-343, 2015.

[9] G. J. Upperman, T. L. Upperman, D. J. Fouts, P. E. Pace, "Efficient time-frequency and bi-frequency signal processing on a reconfigurable computer," in 42nd Asilomar Conference on Signals, Systems and Computers, IEEE. Pacific Grove, CA, USA, 2008.

[10] M. Zhang, M. Diao, and L. Guo, "Convolutional neural networks for automatic cognitive radio waveform recognition," IEEE Access, vol. 5, 2017, pp. 11074-11082

[11] G. López-Risueño, J. Grajal, and A. Sanz-Osorio, "Digital channelized receiver based on time-frequency analysis for signal interception," IEEE Trans. Aerosp. Electron. Syst., vol. 41, no. 3, 2005, pp. 879-898.

[12] C. Wang, J. Wang, and X. Zhang, ``Automatic radar waveform recognition based on time-frequency analysis and convolutional neural network, ‘in Proc. IEEE Int. Conf. Acoust., Speech Signal Process. (ICASSP), Mar. 2017, pp. 2437-2441.

[13] Hejazikookamari, F., Nayebi, M.M., Norouzi, Y. and Kashani, E.S., 2018. "A Novel Method to Detect and Localize LPI Radars". IEEE Transactions on Aerospace and Electronic Systems. Volume: 55, 2019,pp. 2327 – 2336

[14] M. Zhang, L. Liu, and M. Diao, "LPI radar waveform recognition based on time-frequency distribution", Sensors, vol. 16, no. 10, 2016, pp. 1682.

[15] GUO Limin,Chen Xin, ‘‘Low Probability of Intercept Radar Signal Recognition Based on the Improved AlexNet Model,’’ , ICDSP Conference paper, 2018.

[16] C. Wang, J. Wang, and X. Zhang, ‘‘Automatic radar waveform recognition based on time-frequency analysis and convolutional neural network,’’. ICASSP IEEE. Conference paper. 2017.

[17] T. L. Odom Upperman, “Elint Signal Processing Using Choi-Williams Distribution On Reconfigurable Computers For Detection And Classification Of Lpi Emitters,” M.S. thesis, Naval Postgraduate School, Monterey, CA, United States, 2008.

[18] N. Levanon and E. Mozeson, “Radar Signals”. New York, NY, USA: Wiley, 2004

[19] Fielding, J. E., “Polytime coding as a means of pulse compression,” IEEE Trans. on Aerospace and Electronic Systems, vol. 35, pp. 716-721, 1999.

[20] E. Sejdić, I. Djurović, J. Jiang, “Time-frequency feature representation using energy concentration: An overview of recent advances,” Digital Signal Processing, vol. 19, pp. 153-183, 2009.

[21] Alex Krizhevsky, Ilya Sutskever,Geoffrey E. Hinton, “ImageNet Classification with Deep Convolutional Neural Networks,” IEEE Computer Society Conference paper, 2009

[22] Yann LeCun and et.all., “Gradient-Based Learning Applied to Document Recognition.,” Proceedings of the IEEE,vol: 86, pp: 2278 – 2324, 1998.

[Downloaded from ic4i-journal.ir on 2026-11-24]