

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

قادر قدیمی¹

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 به دلیل 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 تجزیه و تحلیل 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 به‌عنوان‌های 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. 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

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 از سالی از رادارها را داشتند. این روش به دلیل 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 از سال این سیگنال‌ها به گونه‌ای 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) دارند سعی در مخفی نگه داشتن سیگنال رادارها از دید گیرنده‌های جنگ الکترونیک دشمن را دارند.

به دلیل تکنولوژی خاص رادارهای LPI، این رادارها دارای توان از سالی پائین، پهنای باند زیاد و فرکانس متغیر می‌باشند. لذا به دست آوردن مشخصات این نوع از سیگنال‌ها، برای گیرندگان جنگ الکترونیک از جمله رادارهای هشدار، گیرنده‌های هوشمند الکترونیک و ... مشکل ساز است. به عبارتی دیگر شناسایی سیگنال رادارهای LPI نیازمند استفاده از روش‌های جدید در حوزه پردازش سیگنال و تصویر، برای آشکار سازی، کلاس‌بندی و استخراج مشخصات این نوع از سیگنال‌ها است [1]. قبل از پرداختن به مسئله آشکار سازی سیگنال رادارهای LPI، لازم است بدانیم این نوع از سیگنال‌ها با توجه به نوع مدولاسیون به کاررفته 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 می‌باشند. بدلیل وجود انواع مختلف از مدولاسیون‌ها بایستی تجهیزات شوند مجهز به تشخیص نوع سیگنال این رادارها بصورت اتوماتیک در دو مرحله آشکار سازی و کلاس‌بندی باشد [2].

1-1 مقدمه

هدف اصلی این مقاله ارائه روشی برای آشکار سازی و کلاس‌بندی سیگنال رادارهای LPI است. در زمینه آشکار سازی و کلاس‌بندی سیگنال این نوع از رادارها در گذشته بر اساس 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 به صورت 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 [1,10]، روش سری فوریه زمان-کوتاه [1,11] و روش سوم توزیع واینر ویل [1,12]، به تازگی روشی مشابه تصویربرداری SAR [13] برای تشخیص این نوع از سیگنال‌ها ارائه 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 شناسایی سیگنال رادارهای LPI را دارد.

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

¹Low Probability of Interception (LPI)

²Choi-William Distribution (CWD)

³Short-Time Fourier Transform (STFT)

⁴Wigner Ville Distribution (WVD)

خروجی از آنالیز زمان - فرکانس را ارائه داده اند همچنین ویژگی های آماری نويز در این تصاویر مورد تجزیه و تحلیل قرار گرفته و نهایتاً رویکردی را برای کاهش نويز ارائه می دهند.

در این مقاله از شبکه های CNN الکسنت² و گوگل نت³ برای کلاس بندی و تشخیص انواع مدولاسیون رادارهای LPI استفاده شده و نتایج آنها با روش های ارائه شده در مراجع [10] و [14] مورد مقایسه قرار خواهند گرفت.

این مقاله از قسمت های زیر تشکیل شده است. در قسمت دوم سیگنال رادارهای LPI مورد بحث و بررسی قرار خواهد گرفت. در قسمت سوم روش شبکه CNN مورد بحث و بررسی قرار می گیرد. در قسمت چهارم روش پیشنهادی برای آشکارسازی و کلاس بندی سیگنال رادارهای LPI ارائه خواهد شد. در قسمت پنجم نتایج شبیه سازی ها ارائه شده و نهایتاً در بخش ششم جمع بندی مقاله ارائه خواهد شد.

2. سیگنال رادارهای LPI

در این بخش، مدل سیگنال های استفاده شده در این مقاله به همراه فرمول های مربوطه مورد بحث و بررسی قرار خواهد گرفت.

2-1. مشخصات سیگنال رادارهای LPI

امروزه وجود تجهیزات پشتیبانی جنگ الکترونیک و موشک های ARM استفاده از رادارها رابه خطر انداخته و نمی توان از رادارهای MTI که برای دستیابی به برد بیشتر از توان بالائی استفاده می کنند، استفاده کرد. بنابراین استفاده از راداهائی که دارای احتمال شوند کمتری می باشند حائز اهمیت است. در این راستا تکنولوژی جدید در مورد سیگنال رادارها رونمایی شد که امکان تشخیص سیگنال رادارها را بسیار سخت می کرد. اصطلاحاً به این نوع از رادارها، رادارهای LPI اطلاق شد [17]. یکی از مؤلفه های مهم که در رادارهای LPI دارای اهمیت است تکنیک فشرده سازی پالس می باشد.

مشکل روش های متعددی ارائه شده است. یکی از این روش ها، استفاده از روش یادگیری عمیق است. در این روش با استفاده از یک شبکه عصبی کانولوشنال (CNN) انواع مدولاسیون این نوع از رادارها را می توان آشکارسازی و کلاس بندی کرد. در این مقاله سعی شده است با استفاده از شبکه های CNN، نوع مدولاسیون رادارهای LPI را در SNR های پائین تشخیص داده و کلاس بندی کرد.

هدف یادگیری عمیق ایجاد شبکه های عصبی بزرگ است که می توانند یاد بگیرند و بدون دخالت انسان در مورد مسائل فکر کنند. شبکه های عصبی کانولوشنال که CNNs یا ConvNets نیز نامیده می شوند یکی از مهم ترین روش های یادگیری عمیق هستند که در آنها چندین لایه آموزش داده می شود تا از این آموزش بهره برداری های لازم برداشته شود. این روش بسیار کارآمد بوده و یکی از رایج ترین روش ها در کاربردهای مختلف بینایی کامپیوتر است. این شبکه ها در زمینه های زیادی از جمله تشخیص الگو، تشخیص سخنان یک نفر، پردازش زبان طبیعی و پردازش تصویر کاربرد دارد. شبکه های عصبی کانولوشنال تا حد بسیار زیادی شبیه شبکه های عصبی مصنوعی هستند.

در [10] آقای ژانگ و همکارانش با استفاده از یک شبکه CNN روشی را برای کلاس بندی 12 نوع از مدولاسیون رادارهای LPI ارائه کرده اند. در [14] آقای ژانگ و همکارانش مشخصات سیگنال رادارهای LPI را از فرکانس و فاز لحظه ای جدا شده از سیگنال به دست می آورند. در [10] آقای ژانگ و همکارانش با استفاده از توزیع CWD و یک شبکه CNN یک روش اتوماتیک، برای تشخیص سیگنال های رادیویی را ارائه داده اند. در [15] جی یو و همکارانش با استفاده از شبکه CNN الکسنت بهبود یافته و توزیع WVD در حوزه زمان - فرکانس برای آنالیز و کلاس بندی سیگنال رادارهای LPI را ارائه داده اند. در [16] آقای وانگ و همکارانش با استفاده از یک شبکه CNN که خودشان طراحی کرده بودند، روشی را برای کلاس بندی سیگنال رادارهای LPI با استفاده از تصویر

¹Convolutional Neural Networks (CNN)

²AlexNet

روش‌های فشرده‌سازی پالس در رادارها به دو دسته فشرده‌سازی 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 به صورت زیر است.

2-1-1-1 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 می‌شود که برای تشخیص کلاتر از هدف بسیار خوب است. رابطه ذکر شده در جدول 1 برای مدولاسیون FM، B نشانگر پهنای باند سیگنال و T_p نشانگر فاصله بین پالس‌ها است [1].

2-1-1-2 مدولاسیون چند فازی

مدولاسیون چند فازی و یا به عبارتی 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 0 و 2π را بگیرد. افزایش تعداد عناصر یا مقادیر فاز در دنباله، امکان تولید دنباله‌هایی 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 فازی $T1, T2, T3, T4$ 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 ذکر شده برای کدهای $P1, P2, P3, P4$ ، که به صورت $\varphi_{i,j}$ بیان شده‌اند نشانگر فاز در Δ امین نمونه از Δ امین فرکانس است. همچنین برای کدهای چند زمانه

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 به صورت زیر می‌توان نشان داد:

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

که در آن f_c فرکانس حامل و ϕ_k فاز مدولاسیون که به صورت زیر تعریف می‌گردد:

$$\phi_k = 2\pi f_k (kT_s) + \varphi_k \quad (2)$$

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 فرکانس¹ و مدولاسیون فاز² 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 به غیر از مدولاسیون FM، به صورت $\varphi_{i,j}$ نشان داده شده است که نشانگر Δ امین نمونه از Δ امین 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 به گونه‌ای 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 پردازشی بسیار بالایی 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،

²Phase Modulation (PM)

¹Frequency Modulation (FM)

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

فرکانس مجموعه‌ای از تکنیک‌ها و روش‌ها، 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 سریع¹ به‌عنوان یکی از روش‌ها مورد استفاده قرار می‌گیرد. از این روش، خیلی از روش‌های 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 STFT یک سیگنال محدودشده در یک پنجره است. طیف $S(\tau; f)$ را به‌صورت زیر می‌توان تعریف کرد [10]:

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

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:

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	$\varphi_{i,j}(t) = \text{mod} \left\{ \frac{2\pi}{n} \text{INT} \left[(kt - jT) \frac{jn}{T} \right], 2\pi \right\}$	ثابت
T2	$\varphi_{i,j}(t) = \text{mod} \left\{ \frac{2\pi}{n} \text{INT} \left[(kt - jT) \left(\frac{2j - k + 1}{T} \right) \frac{n}{2} \right], 2\pi \right\}$	ثابت
T3	$\varphi_{i,j}(t) = \text{mod} \left\{ \frac{2\pi}{n} \text{INT} \left[\frac{n\Delta F t^2}{2t_m} \right], 2\pi \right\}$	ثابت
T4	$\varphi_{i,j}(t) = \text{mod} \left\{ \frac{2\pi}{n} \text{INT} \left[\frac{n\Delta F t^2}{2t_m} - \frac{n\Delta F t}{2} \right], 2\pi \right\}$	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، تجزیه و تحلیل زمان-

¹Fast Fourier Analysis(FFT)

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 داده‌ها
- 2- بسط داده‌ها
- 3- استانداردسازی داده‌ها

استانداردسازی داده‌ها 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، دلیل توزیع گاوسی با میانگین صفر و انحراف معیار واحد، بسیار مفید است. می‌توان 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 می‌باشد. خروجی این مرحله بعنوان ورودی شبکه‌های CNN (گوگل نت و الکس نت) است.

3. ساختار شناسایی و کلاس‌بندی سیگنال رادارهای

LPI

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

3-1 بلوک دیاگرام

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

- 1- آنالیز زمان-فرکانس
- 2- مرحله پیش پردازش
- 3- استخراج ویژگی‌ها

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

که در آن w به عنوان فرکانس زاویه‌ای، σ فاکتور شیفیت، که مقدار مثبتی می‌باشد و t به عنوان 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

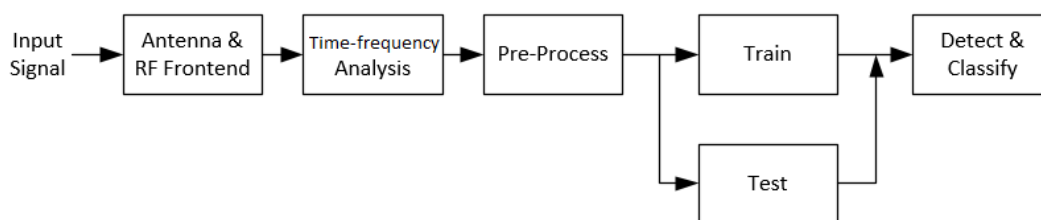
پیش پردازش داده‌ها برای حل مشکل داده‌های دنیای واقعی که اغلب ناقص و احتمالاً خطاهای زیادی در آن وجود دارد استفاده می‌شود، مرحله پیش پردازش، داده‌ها را با تبدیل به یک قالب قابل درک، برای پردازش بیشتر آماده می‌کند. پیش پردازش داده‌ها در برنامه‌های مبتنی بر پایگاه داده مانند مدیریت ارتباط با مشتری و برنامه‌های مبتنی بر قاعده (مانند شبکه‌های 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 اصطلاحاً 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 می‌شود و هدف آن تغییر مقادیر ستون‌های عددی در مجموعه داده به یک مقیاس مشترک (به عنوان مثال

4- تشخیص و آشکارسازی سیگنال رادارهای LPI

همانطور که در بلوک دیاگرام شکل 1 نشان داده شده است، برای شناسایی پارامترهای سیگنال، ابتدا سیگنال RF از سیستم دریافت شده و سپس در حوزه زمان-فرکانس تجزیه و تحلیل می شود. خروجی این مرحله بصورت یک تصویر دو بعدی در حوزه زمان-فرکانس از سیگنال است. خروجی این

مرحله وارد بلوک پیش پردازش شده و نرمالیزه می شود تا آماده ورود به مرحله آموزش توسط شبکه یادگیری عمیق شود. خروجی مرحله پیش پردازش به شبکه های یادگیری عمیق منتقل می شود تا به خوبی آموزش ببینند و به عملکرد مطلوب برسند. پس از آموزش شبکه در قسمت تشخیص، از تصاویر آزمون برای تعیین عملکرد آشکارسازی سیگنال و تشخیص نوع واقعی مدولاسیون استفاده می شود.



شکل 1- بلوک دیاگرام روش پیشنهادی مقاله برای تشخیص و کلاس بندی سیگنال رادارهای LPI


کنیم. توضیحات این دو روش شبکه و بهبود یافته آنها به صورت زیر بیان می شوند.

3-2-1. معماری شبکه الکسنت

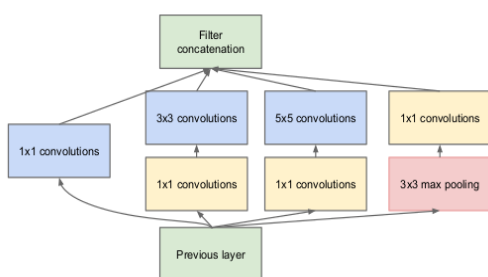
همان طور که در شکل (2) نشان داده شده است این شبکه دارای 8 لایه می باشد که شامل 5 لایه کانولوشن و 3 لایه اتصال کامل است. همچنین ورودی این شبکه به صورت یک تصویر 224×224 است. در این معماری ابتدا از تصویر ورودی با استفاده از 96 ضریب مجزا عمل کانولوشن گرفته می شود که خروجی به صورت یک تصویر 55×55 در می آید در مرحله بعد با استفاده از یک لایه مکس پولینق با اندازه 5×5 خروجی به صورت یک تصویر 27×27 در می آید. این عملیات را در 5 مرحله انجام می دهیم تا به لایه های اتصال کامل برسیم. در این قسمت ابتدا داده ها از حالت ماتریسی به حالت برداری در آمده و بعد از 3 لایه اتصال کامل می توان به تعداد کلاس ها، خروجی را مشاهده کرد.

3-2. شبکه های عصبی کانولوشن

یکی از کاربردهای روش یادگیری عمیق به کارگیری داده ها جهت آموزش الگوریتم های شبکه های عصبی برای کلاس بندی انواع مختلفی از اشیاء است. شبکه های CNN به عنوان الگوریتم های یادگیری عمیق یک ابزار قدرتمند برای آنالیز و کلاس بندی تصاویر است. دو شبکه یادگیری عمیق مورد استفاده در این مقاله در حوزه کلاس بندی تصاویر، روش های گوگل نت و الکسنت است برای بکار گیری این دو روش در آشکارسازی و کلاس بندی 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 تغییرات اعمال شده برای شبکه الکسنت را با عنوان method2 نام گذاری می



شکل (2): معماری شبکه الکسنت [21]:



شکل 3: ماژول inception

3-2-3. تشریح method1,2

لازم به ذکر است که معماریهای گوگل نت و الکسنت برای مقدار زیادی از داده‌ها در حدود 1,2 میلیون داده برای آموزش، 50 هزار داده برای اعتبار سنجی² و 150 هزار داده برای تست گوگل نت و 100 هزار داده برای تست الکسنت طراحی شده‌اند. 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 می‌شود که شبکه‌های انتخاب شده در زمان آموزش به حالت اشباع³ وارد شود همچنین نويز آغشته به ورودی نیز امکان اشباع شدن شبکه را دارد. در این مقاله برای جلوگیری از اشباع شبکه بعد از لایه کانولوشن از لایه رگولاریزه⁴ استفاده شده است. یعنی روش رگولاریزه با پارامتر تنظیم λ ، بدون افزایش قابل توجهی در بایاس مدل، واریانس مدل را به طور قابل توجهی کاهش می‌دهد. بصورت عمومی رگولاریزیشن به سه روش $L1$, $L2$ ، و $(L1+L2)$ -regularization بیان

3-2-2 معماری شبکه گوگل نت

معماری مدل شبکه یادگیری عمیق گوگل نت 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 شناسایی و طبقه بندی شبکه‌های CNN شدند. معمولاً در یک لایه شبکه CNN، یک دسته فیلتر 3×3 و یا 5×5 و یا لایه مکس پولینگ¹ 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 پولینگ استفاده کرده است. این بدان معنی است که آنها به جای افزودن یک لایه اندازه فیلتر خاص، همه فیلترهای 1×1 ، 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 پولینگ برای بهبود عملکرد شبکه CNN بسیار ضروری است، لذا ماژول inception نیز دارای لایه پولینگ مجزائی است.

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

³saturate

⁴regularization

¹Max pooling


²validation

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

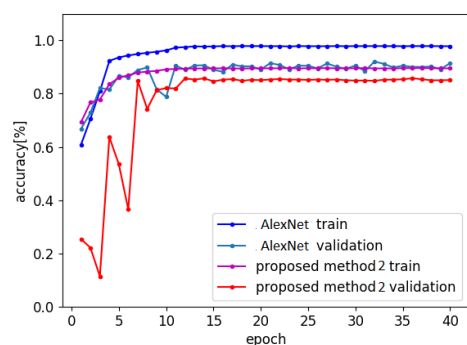
$$L2\text{-regularization} = \lambda \sum_{i=0}^n \theta_i^2 \quad (7)$$

برای روش‌های گوگل نت و الکس نت L2-regularization به ترتیب با ضرایب $\lambda = 10^{-4}$ و $\lambda = 10^{-6}$ انتخاب شده است. 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 سیگموئید¹ از لایه پس انتشار خطا² استفاده کرده‌ایم. شکل 4 معماری گوگل نت را قبل و بعد از اضافه کردن لایه L2-regularization را نشان می‌دهد. همانطور که در شکل 4 مشاهده می‌گردد حالت اشباع در معماری گوگل نت اتفاق افتاده با اضافه کردن لایه مورد نظر از بین رفته و داده‌های اعتبار سنجی امکان دنبال کردن داده‌های آموزش را داشته و در این حال امکان پیشگویی داده‌های جدید وجود خواهد داشت.

همچنین شکل 5 معماری الکس نت را قبل و بعد از اضافه کردن لایه L2-regularization نشان می‌دهد. همانند توضیحاتی که برای روش گوگل نت داده شد معماری الکس نت نیز امکان پیشگویی داده‌های جدید را پس از اضافه کردن لایه مورد نظر، خواهد داشت. 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 آشکار سازی و کلاس‌بندی سیگنال رادارهای LPI، با استفاده از یادگیری عمیق است. دانشمندانی که در زمینه یادگیری عمیق فعالیت می‌کنند معماری‌های متفاوتی را برای این روش پیشنهاد داده‌اند که هر کدام از این روش‌ها تکمیل‌کننده روش قبلی می‌باشند. اولین روش که در این حوزه معرفی شده است شبکه لی‌نت است که در سال 1998 توسط آقای لی نت و همکارانش معرفی شد ولی به دلیل نبود سخت‌افزار لازم که بتواند این شبکه راه‌اندازی کند، در آن زمان توجه زیادی به این روش نشد. نهایتاً در سال 2012 با پیشرفت سخت‌افزارهای رایانه‌ای امکان راه‌اندازی این شبکه

²batch normalization

¹sigmoid

4-1. مشخصات محیط نرم‌افزاری و سخت‌افزاری

تمامی پیاده‌سازی‌ها در لینوکس و در محیط ابونتو نسخه 16,04 (Ubuntu 16.04) انجام گرفته است. از زبان 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 سیگنال کریپر، BW پهنای باند مدولاسیون، SNR نسبت سیگنال به نویز سیگنال‌ها است و همچنین m در سیگنال‌های چند فازی به عنوان گام فرکانسی و در سیگنال‌های چند زمانه، تعداد فازهای مورد استفاده 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

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 است که طیف سیگنال را در دو حوزه زمان و فرکانس

بوجود آمد. اولین کاربرد این شبکه برای تشخیص اعداد دست‌نوشته 0 تا 9 انگلیسی که به مجموعه MNIST معروف هستند، بود. دانشمندانی که در این حوزه فعالیت می‌کردند دریافتند که با گسترش این شبکه‌ها از نظر تعداد و ساختار لایه‌ها می‌توانند نتایج بهتری را برای کارهای متفاوتی از جمله برای استفاده در خودروهای بدون سرنشین و... بگیرند. برای رسیدن به این منظور آقای الکسنت و همکارانش توانستند دومین معماری در این حوزه را در سال 2012 که به نام الکسنت معروف است، به ثبت برسانند. این روند همچنان ادامه داشت و در سالهای بعدی معماری‌های متفاوت‌تر با دقت عملکرد بالایی ارائه شد. یکی از این معماری‌ها معماری گوگل‌نت بود که توسط محققان شرکت گوگل ارائه شد.

هدف از ارائه این مقاله استفاده از دو معماری الکسنت و گوگل‌نت در یادگیری عمیق برای آشکار سازی و کلاس‌بندی سیگنال رادارهای LPI است. برای این منظور 9 نوع متفاوت از سیگنال این رادارها برای آشکار سازی و کلاس‌بندی انتخاب شده‌اند که عبارت‌اند از: LFM, P1, P2, P3, P4, T1, T2, T3, T4

قبل از ارائه نتایج شبیه‌سازی‌های انجام‌شده، ابتدا نحوه پیاده‌سازی این معماری‌ها در محیط نرم‌افزاری و سخت‌افزاری، مشخصات سیگنال‌های استفاده‌شده و روند شبیه‌سازی، توضیحاتی ارائه داده می‌شود.

4-3. روند شبیه‌سازی‌های انجام گرفته

زمانی که یک سیگنال از کانال هوایی توسط یک گیرنده دریافت می‌گردد مراحل زیر طی می‌شود تا سیستم بتواند یک سیگنال را از نویز تشخیص داده و همچنین در صورت

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 به صورت زیر است.

در این مقاله از 9 مدولاسیون متفاوت LPI (LFM, P1, P2, P3, P4, T1, T2, T3, T4) رادارهای به همراه نویز، با مشخصاتی که در جدول 3 نشان داده شده برای تولید سیگنال‌ها جهت آموزش در دو شبکه کانولو شنال الکسنت و گوگل نت استفاده شده است. به همین منظور برای هر نوع از این مدولاسیون‌ها به تعداد 20 هزار تصویر سیگنال با SNRهایی در بازه -10dB تا 0dB در نرم افزار متلب با استفاده از روش STFT تولید شده که خروجی آن به صورت 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 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 آشکار سازی سیگنال‌های راداری اشاره شده در این مقاله را بررسی می‌کنیم. برای این منظور ابتدا بهبود یافته شبکه‌های الکسنت با نام method1 و بهبود یافته گوگل نت 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 به صورت 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 آشکار سازی

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 پیش پردازش خروجی این مرحله به صورت یک تصویر با فرمت JPG به شبکه CNN داده می‌شود.

4-3-2. شبکه کانولو شنال (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 به عنوان ورودی شبکه CNN قرار دارد بایستی با توجه به شرایط حاکم بر شبکه‌های CNN پیش پردازشی دومی را نیز بر روی تصاویر انجام داد. این پیش پردازش 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 پیش پردازش شامل تغییر اندازه تصویر با توجه به نوع شبکه CNN و نرمالیزه کردن تصویر است. خروجی این پیش پردازش به عنوان ورودی برای شبکه CNN محسوب می‌شود. نهایتاً از خروجی شبکه CNN می‌توان به عنوان یک روش برای تشخیص اتوماتیک نوع سیگنال رادارهای LPI استفاده کرد. شبکه‌های CNN مورد استفاده در این مقاله، معماری‌های لی نت و الکسنت است.

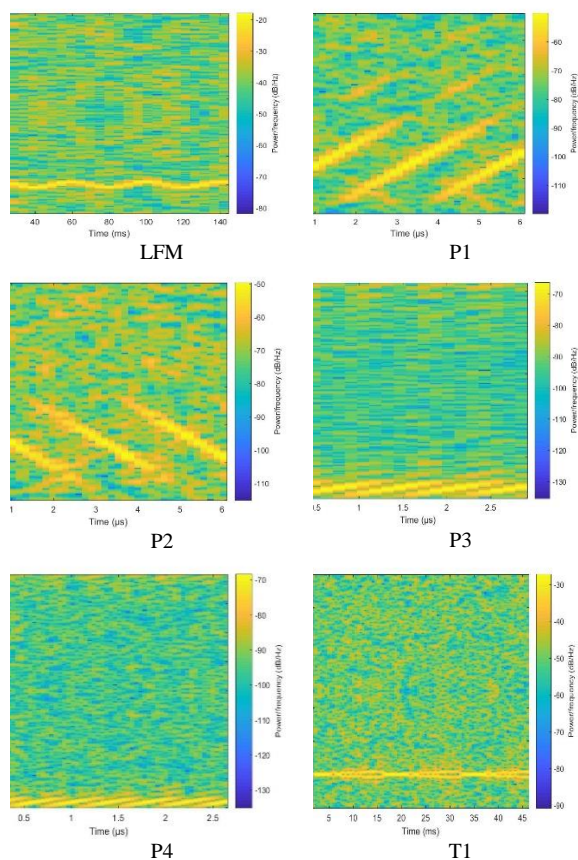
4-3-3. نحوه آموزش شبکه CNN

قبل از اینکه بتوانیم از روش ارائه شده در این مقاله برای آشکار سازی و کلاس بندی 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 این جا هر نوع مدولاسیون را به عنوان یک

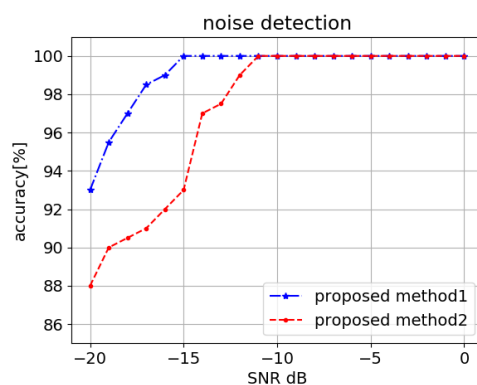
¹ accuracy

داده شده و نهایتاً 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 می‌شوند 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 داده‌ها را نشان می‌دهد. نتیجه مقایسه بین دو روش method1,2 توسط مولفه نرخ عملکرد¹ در SNR های متفاوت سنجیده خواهد شد.

شکل 7، 9 نوع مدولاسیون استفاده شده در این مقاله را که در حوزه زمان-فرکانس تولید شده‌اند را نشان می‌دهد.



سیگنال از نویز 100 درصد 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 100 درصد بوده و در SNR، -20dB به 88 درصد می‌رسد با مقایسه دو روش می‌توان نتیجه گرفت که عملکرد روش method1 در مقایسه با روش method2 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 [10 و 14]

در این مقاله روش‌های پیشنهادی را با روش‌های مطرح شده در مراجع [10 و 14] 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 پارامترهای پهنای باند (BW)، فرکانس کریپر (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 سائز تصویر متناسب با نوع شبکه تغییر

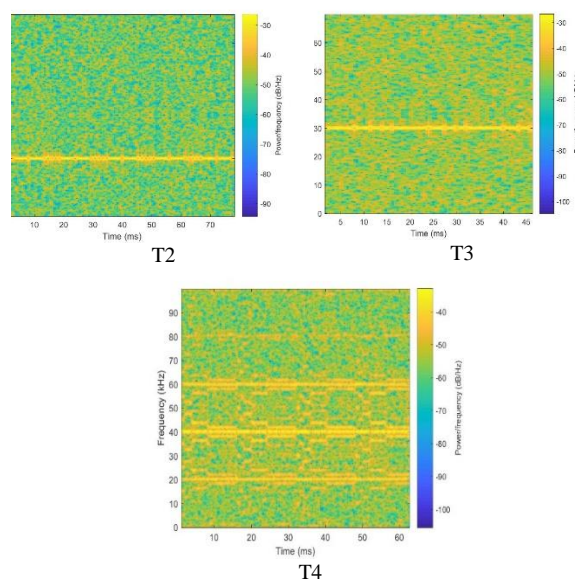
¹accuracy rate

90 و 72 درصد است. بطور مشابه همانطور که در شکل (8-8) (ب) برای مدولاسیون LFM نشان داده شده است روش‌های پیشنهادی method1 و method2 به طور چشمگیری دارای عملکرد بهتری نسبت به روش‌های [10,14] می‌باشند.

شکل 9 مقایسه بین روش‌های پیشنهادی method1,2 و روش ارائه شده در [10] را نشان می‌دهد. مدولاسیون‌هایی 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 به دلیل اشتراک با مدولاسیون‌های مورد استفاده در این مقاله، برای مقایسه انتخاب شده‌اند.

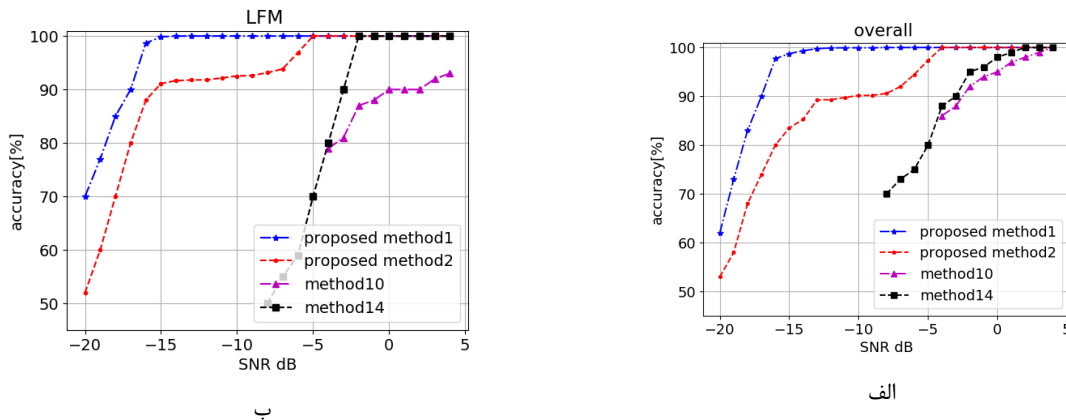
همانطور که در شکل‌های 8 و 9 نشان داده شده است عملکرد روش‌های method1 و method2 برای مدولاسیون‌های LFM و T4 (برای SNRهای بالاتر از -4db) در میان تمامی مدولاسیون‌های مورد بحث در این مقاله دارای عملکرد بسیار خوبی نسبت به روش ارائه شده در [10] را دارد.

شکل 10 مقایسه بین روش‌های پیشنهادی method1 و method2 را با روش ارائه شده در [14] نشان می‌دهد. مدولاسیون‌هایی 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 به دلیل 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 SNRهای بالاتر از -2db دارای دقت عملکرد 100 درصدی است. اما برای SNRهای پایین‌تر از -2db روش‌های method1 و method2 دارای وضعیت مناسبتری نسبت به روش [14] می‌باشند.



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

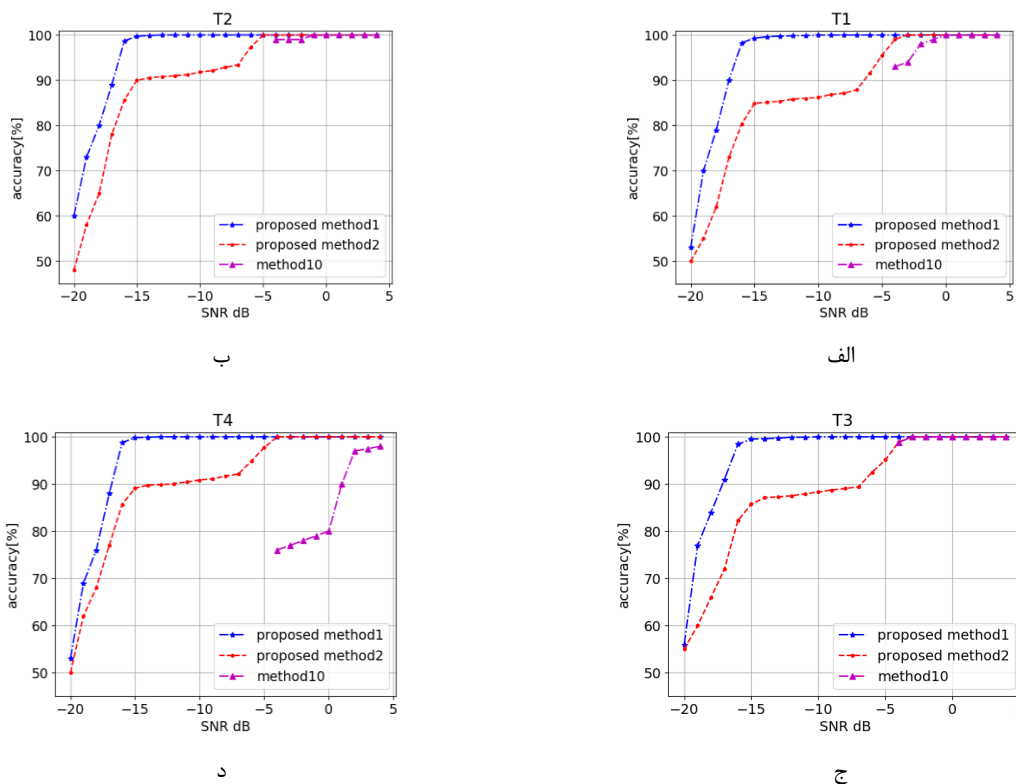
شکل 8 مقایسه بین روش‌های method1,2 و روش‌های ارائه شده در مراجع 10 و 14 که اخیراً منتشر شده است را برای حالت کلی (حالتی که دقت عملکرد تمامی مدولاسیون‌ها به صورت هم‌زمان محاسبه می‌شود) و مدولاسیون LFM نشان می‌دهد. کارایی روش‌های ارائه شده در مراجع [10,14] به ترتیب تا SNRهای -4db و -8db مورد بررسی قرار 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 می‌باشند در حالی که روش‌های [10,14] در همین SNR حدوداً دارای دقت عملکرد 87 درصدی در حالت کلی می‌باشند که این حالت نشان از کارایی بهتر روش‌های 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 درصد برای حالت کلی است در حالی که در همین SNR برای روش‌های method2 و [14] به ترتیب برابر با



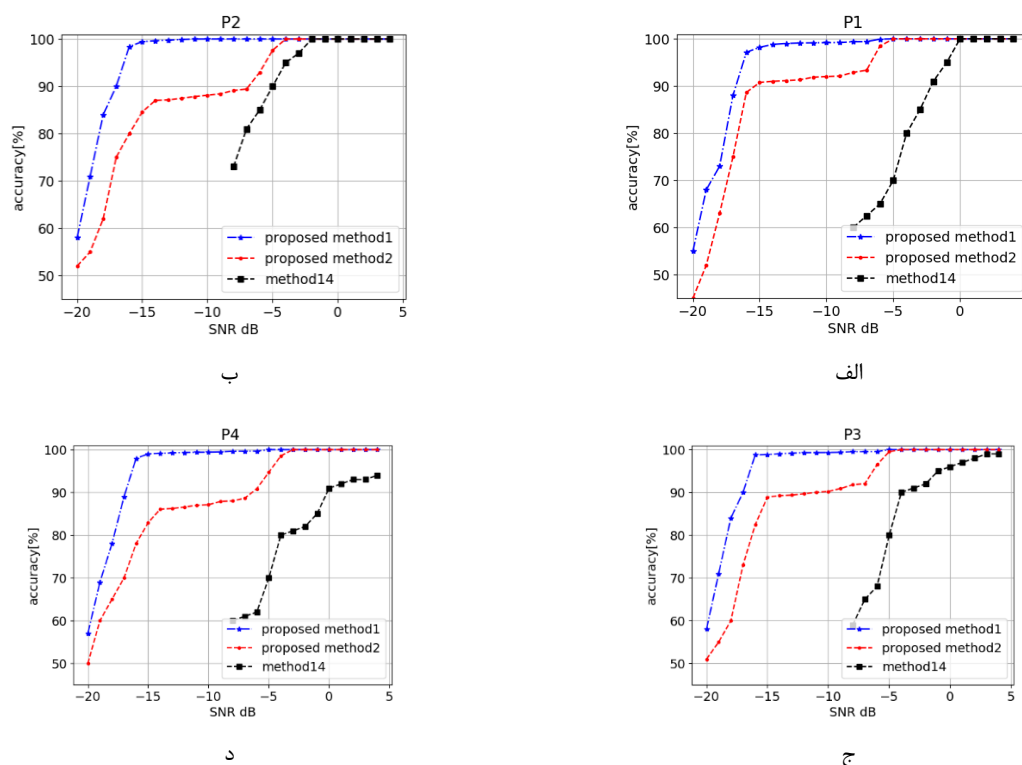
شکل (8): مقایسه روشهای پیشنهادی این مقاله **method1** و **method2** با روش‌های ارائه شده در [10,14] الف- حالت کلی ب-مدولاسیون LFM

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 **method10** 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.

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 **method10** 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.



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



شکل (10): مقایسه روش‌های method1 و method2 با روش ارائه شده در [14] الف- مدولاسیون P1 ب- مدولاسیون P2 ج- مدولاسیون P3 د- مدولاسیون P4

2-5. ماتریس درهم ریختگی (کانفیوژن)

در علم یادگیری ماشین، بخصوص در زمینه کلاس‌بندی ورودی‌ها، ماتریس کانفیوژن به عنوان یک ماتریس خطا شناخته می‌شود. در حقیقت ماتریس کانفیوژن یک جدول است که برای تعیین عملکرد کلاس‌بندی یک مدل، بر روی ورودی‌هایی که به عنوان تست شبکه مورد استفاده قرار گرفته‌اند، بکار می‌رود. جدول (4) ماتریس کانفیوژن را برای روش method1 در SNR، -15dB نشان می‌دهد. این جدول برای 9 نوع مدولاسیون به همراه نویز تهیه شده است. 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 مشخص است بهترین عملکرد برای تمامی

سیگنال‌ها رخ داده است.

شایان ذکر است که، همچنین جدول شامل کلاس null است که فقط مربوط به نویز است. همانطور که در جدول مشاهده شد، روش پیشنهادی method1 به عنوان یک روش کلاس‌بندی و هم یک الگوریتم تشخیص، عملکرد قابل قبولی دارد.

جدول 4- 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

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 method 1، با توجه به بیشتر بودن تعداد لایه‌های این روش نسبت به روش method 2، 128 ساعت و 50 دقیقه و برای روش method 2، 100 ساعت و 28 دقیقه طول کشیده است. همچنین با عنایت به اینکه در مرحله تست از 2000 تصویر برای دو روش method 1,2 استفاده شده است، برای روش method 1 این مرحله 12 دقیقه و 42 ثانیه، و برای روش method 2، 8 دقیقه و 28 ثانیه طوی کشیده است.

6. نتیجه گیری

معماری گوگل نت 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 method 1 نام گذاری شد. همچنین با اعمال همین تغییر در معماری الکس نت، تغییر یافته این معماری، با عنوان روش method 2 نام گذاری شد که در این روش نیز نتایج خوبی را در راستای اهداف این مقاله بدست آمد. روش‌های پیشنهادی method 1,2 و همچنین روش STFT برای آنالیز سیگنال در حوزه زمان-فرکانس برای آشکارسازی و کلاس‌بندی 9 نوع از سیگنال رادارهای LPI (P4, T1, T2, T3, T4 P3, P2, P1, LFM,) با SNR هائی در محدوده -20dB تا 0dB انجام شد. نتایج بدست آمده نشان می‌دهد که روش method 1 در SNR=-15db دارای

دقت عملکرد 98,70 درصدی می‌باشد در مقابل روش method 2 در همین SNR دارای دقت عملکرد 80 درصدی است. همچنین کارایی روش method 1 در مقایسه با روش‌های ارائه شده در مراجع [10,14] دارای دقت عملکرد بسیار بالایی 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 method 2 این عدد برابر با -4db و برای روش method 1 برابر با -13db است. بنابراین، می‌توان نتیجه گرفت که روش پیشنهادی method 1 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.

- [6] S. Wei, Q. Qu, M. Wang, et al., "Automatic modulation recognition for radar signals via multi-branch ACSE networks," *IEEE Access*, 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.al., "Gradient-Based Learning Applied to Document Recognition,," *Proceedings of the IEEE*, vol: 86, pp: 2278 – 2324, 1998.

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.