

شناسایی و کلاس‌بندی سیگنال رادارهای LPI با استفاده از شبکه‌های لی نت و الکس نت در

یادگیری عمیق

قادر قدیمی^۱، یاسر نوروزی^{۲*}، رضا بایدرخانی^۳، محمدمهدی ناییبی^۴

۱- دانشجوی دکتری، دانشگاه آزاد اسلامی واحد تهران مرکز، ۲- استادیار، دانشگاه صنعتی امیرکبیر، تهران، ایران،

۳- استادیار، دانشگاه آزاد اسلامی واحد تهران مرکز، ایران، ۴- استاد، دانشگاه صنعتی شریف، تهران، ایران

(دریافت: ۹۸/۰۲/۱۳؛ پذیرش: ۹۸/۱۰/۱۰)

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 سامانه‌های شناسایی بسیار پائین است. بنابراین با ظهور این نوع فناوری 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 به عنوان 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 به صورت یک تصویر، به دو شبکه الکس نت و لی نت که از شبکه‌های یادگیری عمیق هستند، برای آشکارسازی و کلاس‌بندی انواع مدولاسیون‌های مورد استفاده در رادارهای LPI، داده خواهد شد. نتایج به دست آمده از این شبیه‌سازی‌ها نشان می‌دهد که در SNR (نسبت سیگنال به نویز) -5dB دقت عملکرد روش الکس نت $97/34\%$ و دقت عملکرد روش لی نت 94% است که نشان از عملکرد بهتر روش الکس نت است.

واژگان کلیدی

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

۱. مقدمه

به دلیل تکنولوژی خاص رادارهای LPI، این رادارها دارای توان ارسالی 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 الکتریکی و ... مشکل ساز است. به عبارتی 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 [۱]. قبل از پرداختن به مسئله آشکارسازی سیگنال رادارهای LPI، لازم است بدانیم این نوع از سیگنال‌ها با توجه به نوع مدولاسیون به کاررفته دارای انواع مختلفی می‌باشند که عبارتند از:

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 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 ارسال 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^۱ (LPI) دارند سعی در مخفی نگه داشتن سیگنال رادارها از دید گیرنده‌های جنگ الکترونیک دشمن را دارند.

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

*ایانامه نویسنده مسئول: y.norouzi@aut.ac.ir

^۱ Low Probability of Intercept (LPI)

سیگنال رادارهای LPI را از فرکانس و فاز لحظه‌ای جدا شده از سیگنال به دست می‌آورند. در [۶] آقای ژانگ و همکارانش با استفاده از توزیع CWD و یک شبکه CNN یک روش خودکار، برای تشخیص سیگنال‌های رادیویی را ارائه داده‌اند. در [۷] جی یو و همکارانش با استفاده از شبکه CNN الکسنت بهبود یافته و توزیع WVD در حوزه زمان-فرکانس برای تجزیه و تحلیل و کلاس‌بندی سیگنال رادارهای LPI را ارائه داده‌اند. در [۸] آقای وانگ و همکارانش با استفاده از یک شبکه CNN که خودشان طراحی کرده بودند، روشی را برای کلاس‌بندی سیگنال رادارهای LPI با استفاده از تصویر خروجی از تجزیه و تحلیل زمان - فرکانس را ارائه داده‌اند همچنین ویژگی‌های آماری نویز در این تصاویر مورد تجزیه و تحلیل قرار گرفته و نهایتاً رویکردی را برای کاهش نویز ارائه می‌دهند.

در این مقاله از شبکه‌های CNN الکسنت^۵ و لی‌نت^۶ برای کلاس‌بندی و تشخیص انواع مدولاسیون رادارهای LPI استفاده شده و نتایج آنها با روش‌های ارائه شده در [۵] و [۶] مورد مقایسه قرار خواهد گرفت.

این مقاله از قسمت‌های 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 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.

۲. سیگنال رادارهای LPI

در این بخش، مدل سیگنال‌های استفاده شده در این مقاله به همراه فرمول‌های مربوطه مورد بحث و بررسی قرار خواهد گرفت.

۲-۱. مشخصات سیگنال رادارهای LPI

در طول جنگ جهانی دوم محققان برای ناکارآمد کردن رادارها، مطالعات وسیعی را بر روی سیگنال رادارها آغاز کردند. در نتیجه این تحقیقات سرانجام توانستند توسط گیرنده‌های جنگ الکترونیک^۷ مشخصات سیگنال رادارها را پیدا کرده و در جهت جلوگیری از اقدامات دشمن اقدامات لازم را در این خصوص انجام دهند. در دهه‌های بعد یک فناوری جدید در مورد سیگنال رادارها رونمایی شد که امکان تشخیص سیگنال این نوع از رادارها را بسیار سخت می‌کرد. اصطلاحاً به این نوع از رادارها، رادارهای LPI اطلاق شد [۹]. یکی از مؤلفه‌های مهم که در رادارهای

که حاصل از ترکیب دو مدولاسیون PSK و FSK می‌باشد.

هدف اصلی این مقاله ارائه روشی برای آشکارسازی و کلاس‌بندی سیگنال رادارهای LPI است. در زمینه آشکارسازی و کلاس‌بندی سیگنال این نوع از رادارها در گذشته روش‌هایی ارائه شده است. از جمله این روش‌ها می‌توان به تجزیه و تحلیل زمان-فرکانس موج، برای تشخیص نوع مدولاسیون و استخراج پارامترهای این نوع از سیگنال‌ها می‌باشد. در این روش توان سیگنال در حوزه زمان فرکانس نمایش داده شده و می‌توان از آن به صورت یک تابع زمان-فرکانس برای تجزیه و تحلیل سیگنال استفاده کرد. خروجی تجزیه و تحلیل زمان-فرکانس به صورت یک تصویر است که می‌توان از آن برای شناسایی نوع سیگنال و استخراج پارامترهای آن استفاده کرد. تا به حال روش‌هایی برای تجزیه و تحلیل زمان-فرکانس این نوع از سیگنال رادارها، ارائه شده است که عبارت‌اند از: توزیع واینر ویل^۱ [۱]، روش سری فوریه زمان-کوتاه^۲ [۲] و روش سوم توزیع چوئی ویلیامز^۳ [۱]، [۳]. مشکل اصلی روش‌های موجود در آشکارسازی و استخراج مشخصات سیگنال‌های رادارهای LPI، در سیگنال به نویز (SNR)های پائین است. برای حل این مشکل روش‌های متعددی ارائه شده است. یکی از این روش‌ها، استفاده از روش یادگیری عمیق است. در این روش با استفاده از یک شبکه عصبی کانولوشنال^۴ (CNN) انواع مدولاسیون این نوع از رادارها را می‌توان آشکارسازی و کلاس‌بندی کرد. در این مقاله سعی شده است با استفاده از شبکه‌های CNN، نوع مدولاسیون رادارهای LPI را در SNRهای پائین تشخیص داده و کلاس‌بندی کرد.

هدف یادگیری عمیق ایجاد شبکه‌های عصبی بزرگ است که می‌توانند یاد بگیرند و بدون دخالت انسان در مورد مسائل فکر کنند. شبکه‌های عصبی کانولوشنال که CNNs یا ConvNets نیز نامیده می‌شوند یکی از مهم‌ترین روش‌های یادگیری عمیق هستند که در آنها چندین لایه آموزش داده می‌شود تا از این آموزش بهره‌برداری‌های لازم برداشته شود. این روش بسیار کارآمد بوده و یکی از رایج‌ترین روش‌ها در کاربردهای مختلف بینایی کامپیوتر است. این شبکه‌ها در زمینه‌های زیادی از جمله تشخیص الگو، تشخیص سخنان یک نفر، پردازش زبان طبیعی و پردازش تصویر کاربرد دارد. شبکه‌های عصبی کانولوشنال تا حد بسیار زیادی شبیه شبکه‌های عصبی مصنوعی هستند.

در [۴] آقای وانگ و همکارانش با استفاده از یک شبکه CNN روشی را برای کلاس‌بندی ۱۲ نوع از مدولاسیون رادارهای LPI، ارائه کرده‌اند. در [۵] آقای ژانگ و همکارانش مشخصات

⁵ AlexNet

⁶ Le.Net-5

⁷ electronic ware (EW)

¹ Wigner Ville Distribution (WVD)

² Short-Time Fourier Transform (STFT)

³ Choi-William Distribution (CWD)

⁴ Convolutional Neural Networks (CNN)

$$s(t) = R\{Ae^{j(2\pi f_c t + \phi_k)}\} \quad (1)$$

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 ۹ شکل موج رادار LPI ذکر شده در این مقاله را، در دو نوع مدولاسیون فرکانس^۱ و مدولاسیون فاز^۲ می‌توان جمع‌بندی کرد [۱۰]. 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 [۱۱]. فاز φ_k برای تمامی مدولاسیون‌ها به غیر از مدولاسیون FM، به صورت $\varphi_{i,j}$ نشان داده شده است که نشانگر آامین نمونه از آامین فرکانس است. جدول (۱) مشخصات ۹ مدولاسیون رادار LPI را که در این مقاله استفاده شده است را نشان می‌دهد.

جدول (۱): مشخصات انواع مدولاسیون رادارهای LPI

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

^۱ Frequency Modulation (FM)

^۲ Phase Modulation (PM)

دارای اهمیت است روش فشرده‌سازی پالس می‌باشد. 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.

۱-۱-۲. 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 ۱ برای مدولاسیون FM، B نشانگر پهنای باند سیگنال و τ_p نشانگر فاصله بین پالس‌ها است [۱].

۲-۱-۲. 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 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 ۱ آمده است.

در روابط ذکر شده برای کدهای P1, P2, P3, P4، که به صورت $\varphi_{i,j}$ بیان شده‌اند نشانگر فاز در آامین نمونه از آامین فرکانس است. همچنین برای کدهای چند زمانه T1, T2, T3, T4 که به صورت $\varphi_{i,j}(t)$ بیان شده، نشانگر فاز در آامین نمونه از آامین فرکانس در لحظه t می‌باشد [۱].

۲-۲. 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 رابطه (۱) می‌توان نشان داد:

زاویه‌ای و t به‌عنوان متغیر زمان است. یکی دیگر از روش‌هایی که برای تجزیه و تحلیل 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:

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

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

۳. 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 تجزیه و تحلیل و کلاس‌بندی تصاویر است. دو روش اولیه در حوزه کلاس‌بندی تصاویر، روش لی‌نت و الکس‌نت است که این دو روش به‌عنوان روش‌های مورد استفاده در آشکارسازی و کلاس‌بندی تصاویر مورد استفاده قرار گرفته است. توضیحات این دو روش به‌صورت زیر می‌باشد.

۳-۱. معماری شبکه لی‌نت

شبکه لی‌نت به‌عنوان یک شبکه CNN کلاسیک در سال ۱۹۹۸ توسط آقای یان لکون^۲ و همکارانش معرفی گردید. این معماری در شکل (۱) نشان داده شده است. همان‌طور که در شکل (۱) مشاهده می‌گردد؛ ورودی این شبکه به‌صورت یک تصویر 32×32 است. این شبکه از دو لایه کانولوشن و ۳ لایه اتصال کامل تشکیل شده است. در مرحله اول توسط ۶ ضریب متفاوت کانولوشن تصویر ورودی محاسبه و خروجی به‌صورت یک تصویر 28×28 می‌شود در مرحله بعدی با استفاده از عمل مکس پولینق بر روی ۶ تصویر به‌دست‌آمده از کانولوشن، ۶ تصویر با ابعاد 14×14 به‌دست می‌آید. مرحله بعد که لایه دوم کانولوشن است از تصویر 14×14 به‌دست‌آمده از مرحله اول کانولوشن با ۱۶ ضریب متفاوت گرفته شده و بعد از این مرحله با استفاده از عمل مکس پولینق یک تصویر 5×5 با ۱۶ لایه به‌دست می‌آید. خروجی این لایه به‌صورت یک ماتریس است. بنابراین، در مرحله اتصال کامل ابتدا ماتریس به‌صورت بردار تبدیل شده و در سه

۳-۲. تحلیل 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 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، پهنای باند، پهنای باند مدولاسیون، دوره تناوب مدولاسیون 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.

در پردازش سیگنال، تجزیه و تحلیل زمان-فرکانس روشی است که سیگنال را در دو حوزه زمان و فرکانس به‌طور هم‌زمان مورد بررسی قرار می‌دهد. علاوه بر این، تجزیه و تحلیل زمان-فرکانس مجموعه‌ای از فنون و روش‌ها، برای تعیین مشخصات سیگنال‌هایی است که مشخصات آنها در زمان تغییر می‌کند [۱۲]. این نوع از تجزیه تحلیل همان گسترش‌یافته تبدیل فوریه است که مشخصات فرکانسی سیگنال در حوزه زمان تغییر می‌کند. برای شناسایی پارامترهای فرستنده، تحلیل فوریه سریع^۱ 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 [۱]. 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 [۱۳]:

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

در رابطه ۳، $x(t)$ 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 ۱۹۳۲ به‌صورت رابطه ۴ ارائه شد.

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

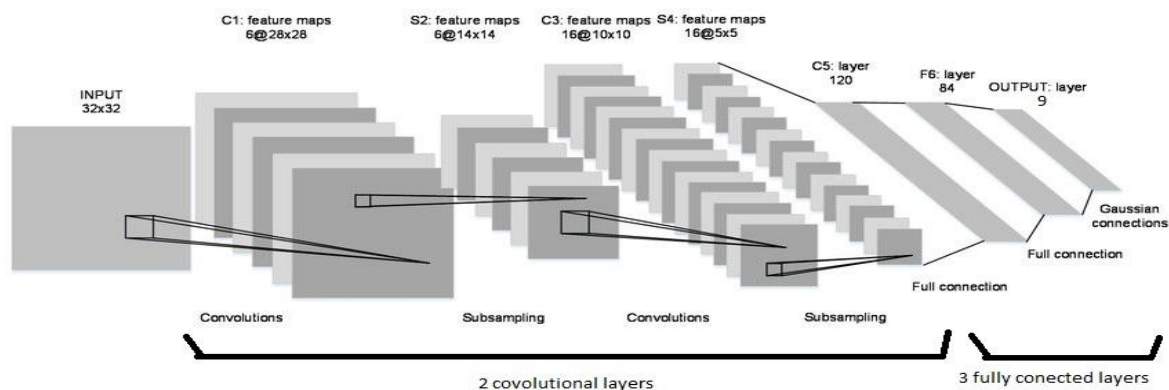
در رابطه ۴، (*) نشان‌دهنده مزدوج سیگنال و w فرکانس

² Yann LeCun


¹ Fast Fourier Analysis(FFT)

که در شکل (۱) تعداد کلاس‌ها ۹ می‌باشد که نشان داده شده است.

مرحله با استفاده از لایه‌های اتصال کامل می‌توان با توجه به کلاس‌های انتخاب‌شده، خروجی همان کلاس‌ها را مشاهده کرد



شکل (۱): ساختار شبکه لی نت [۱۴]:



شکل (۲): معماری شبکه الکس نت [۱۵]:

۴. ارائه روش پیشنهادی برای آشکارسازی و

کلاس‌بندی سیگنال رادارهای LPI

هدف از این مقاله آشکارسازی و کلاس‌بندی سیگنال رادارهای LPI، با استفاده از یادگیری عمیق است. دانشمندی که در زمینه یادگیری عمیق فعالیت می‌کنند معماری‌های متفاوتی را برای این روش پیشنهاد داده‌اند که هر کدام از این روش‌ها تکمیل‌کننده روش قبلی می‌باشد. اولین روش که در این حوزه معرفی شده است شبکه لی نت است که در سال ۱۹۹۸ 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 ۲۰۱۲ با پیشرفت سخت‌افزارهای رایانه‌ای امکان راه‌اندازی این شبکه به وجود آمد. اولین کاربرد این شبکه برای تشخیص اعداد دست‌نوشته ۰ تا ۹ انگلیسی که به مجموعه MNIST معروف هستند، بود. دانشمندی که در این حوزه

۲-۳. معماری شبکه الکس نت

همان‌طور که در شکل (۲) نشان داده شده است این شبکه دارای ۸ لایه می‌باشد که شامل ۵ لایه کانولوشن و ۳ لایه اتصال کامل است. همچنین ورودی این شبکه به صورت یک تصویر ۲۲۴×۲۲۴ است. همانند شبکه لی نت که در بالا توضیح داده شد، ابتدا از تصویر ورودی با استفاده از ۹۶ ضرب مجزا عمل کانولوشن گرفته می‌شود که خروجی به صورت یک تصویر ۵۵×۵۵ در می‌آید در مرحله بعد با استفاده از یک لایه مکس پولینگ با اندازه ۵×۵ خروجی به صورت یک تصویر ۲۷×۲۷ در می‌آید. این عملیات را در ۵ 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 ۳ لایه اتصال کامل می‌توان به تعداد کلاس‌ها، خروجی را مشاهده کرد.

۱۶،۰۴ (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 (۲) اشاره شده است.

جدول (۲): 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

۲-۴. مشخصات سیگنال‌های استفاده شده

مشخصات سیگنال‌های مورد استفاده در این مقاله در جدول (۳) نشان داده شده است. که در آن F_s نرخ نمونه‌برداری، f_c فرکانس سیگنال کریر، 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 (۳): 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

روش تبدیل فوریه زمان کوتاه و یا همان STFT است. بعد از انجام این پیش‌پردازش خروجی این مرحله به صورت یک تصویر با فرمت JPG به شبکه CNN داده می‌شود.

۲-۳-۴. شبکه کانولوشنال (CNN)

خروجی تجزیه و تحلیل 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 پیش‌پردازشی 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 پیش‌پردازش به عنوان ورودی برای شبکه CNN محسوب می‌شود. نهایتاً از

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 خوردروهای بدون سرنشین و... بگیرند. برای رسیدن به این منظور آقای الکسنت و همکارانش توانستند دومین معماری در این حوزه را در سال ۲۰۱۲ که به نام الکسنت معروف است، به ثبت برسانند.

هدف از ارائه این مقاله استفاده از دو معماری ذکر شده در یادگیری عمیق برای آشکارسازی و کلاس‌بندی سیگنال رادارهای LPI است. برای این منظور ۹ نوع متفاوت از سیگنال این رادارها برای آشکارسازی و کلاس‌بندی انتخاب شده‌اند که عبارت‌اند از: LFM, P1, P2, P3, P4, T1, T2, T3, T4

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

۱-۴. مشخصات محیط نرم‌افزاری و سخت‌افزاری

تمامی پیاده‌سازی‌ها در لینوکس و در محیط ابونتو نسخه


۳-۴. 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 تشخیص سیگنال بتواند کلاس سیگنال را برای ما مشخص کند.

۱-۳-۴. تجزیه و تحلیل زمان-فرکانس

دلیل استفاده از تجزیه و تحلیل زمان-فرکانس به عنوان یک پیش‌پردازش این است که طیف سیگنال را در دو حوزه زمان و فرکانس 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 تجزیه و تحلیل زمان-فرکانسی که در این مقاله استفاده شده است

نشان داده شده است نشان می‌دهد روش الکس نت تا SNR، ۱۱dB - دقت عملکرد آشکارسازی سیگنال از نویز ۱۰۰ درصد بوده و در SNR، ۲۰dB - به ۸۸ درصد می‌رسد یعنی امکان تشخیص سیگنال از نویز که مسئله آشکارسازی را بیان می‌کند برای این روش مناسب است. با مقایسه دو روش می‌توان نتیجه گرفت که عملکرد روش الکس نت در مقایسه با روش لی نت بهتر است ولی هر دو نتایج قابل قبولی را دارند.



شکل (۳): نتایج آموزش شبکه‌های الکس نت و لی نت برای دو کلاس کاری در محدوده SNR، ۲۰dB تا ۰dB

۵-۱. مقایسه عملکرد روش‌های پیشنهادی با روش

[۵]

در روش مرجع [۵]، نویسنده در ۳ مرحله مجزا و پیوسته به هم ۸ نوع متفاوت از سیگنال رادارهای LPI را به صورت اتوماتیک کلاس‌بندی می‌کند. در اولین مرحله ابتدا سیگنال با استفاده از توزیع چوئی ویلیام در حوزه زمان-فرکانس تجزیه و تحلیل شده و خروجی آن به یک شبکه که معروف به شبکه ENN (Elman Neural Network) که خود به صورت مجزا از دو زیر شبکه تشکیل شده است داده می‌شود. هر یک از این زیر شبکه‌ها به صورت مجزا ۴ نوع مدولاسیون را می‌توانند کلاس‌بندی کنند. نتایج شبیه‌سازی نشان می‌دهد که در SNR، ۲dB - در حالت کلی (حالتی که دقت عملکرد تمامی مدولاسیون‌ها به صورت هم‌زمان محاسبه می‌شود همانند شکل (۴-الف) دقت عملکرد ۹۵٪ است.

شکل (۴) نتایج شبیه‌سازی و مقایسه روش‌های لی نت و الکس نت را با روش [۵] که برای کلاس‌بندی سیگنال رادارهای LPI، اخیراً ارائه شده است را نشان می‌دهد. مدولاسیون‌هایی که در [۵] برای کلاس‌بندی استفاده شده، مدولاسیون‌های LFM، Costas، Frank، P1، P2، P3، P4 BPSK است که ۵ نوع مدولاسیون P4، P3، P2، P1، LFM به دلیل اشتراک با

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 الکس نت است.

۴-۳-۳. 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 این جا هر نوع مدولاسیون را به عنوان 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 به صورت زیر است.

در این مقاله از ۹ مدولاسیون متفاوت (LFM, P1, P2, P3, P4, T1, T2, T3, T4) رادارهای LPI به همراه نویز، با مشخصاتی که در جدول (۳) نشان داده شده برای تولید سیگنال‌ها جهت آموزش در دو شبکه کانولوشنال لی نت و الکس نت استفاده شده است. به همین منظور برای هر نوع از این مدولاسیون‌ها به تعداد ۲۰ هزار تصویر سیگنال با SNR هائی در بازه ۱۰dB - تا ۰dB در نرم‌افزار متلب با استفاده از روش STFT تولید شده که خروجی آن به صورت یک تصویر ذخیره می‌گردد و جمعاً ۲۰۰,۰۰۰ تصویر برای آموزش شبکه‌های پیشنهادی، استفاده شده است. همچنین برای هر نوع مدولاسیون تعداد ۲۰۰۰ تصویر سیگنال در بازه ۲۰dB - تا ۰dB که جمعاً ۲۰,۰۰۰ هزار تصویر می‌گردد، برای انجام تست بر روی انواع مدولاسیون‌ها و بررسی دقت عملکرد این روش‌ها در زمان آموزش شبکه استفاده می‌شود.

۵. 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 شبکه‌های لی نت و الکس نت را با دو کلاس نویز و سیگنال (شامل ۹ نوع متفاوت سیگنال راداری اشاره شده در این مقاله) هر کدام با ۹۰,۰۰۰ سیگنال با SNR در محدوده ۱۰dB - تا ۰dB که به صورت تصویر ذخیره شده، جهت آموزش به شبکه‌های مورد نظر می‌دهیم. نتایج حاصل از این شبیه‌سازی که در شکل (۳)

¹ accuracy

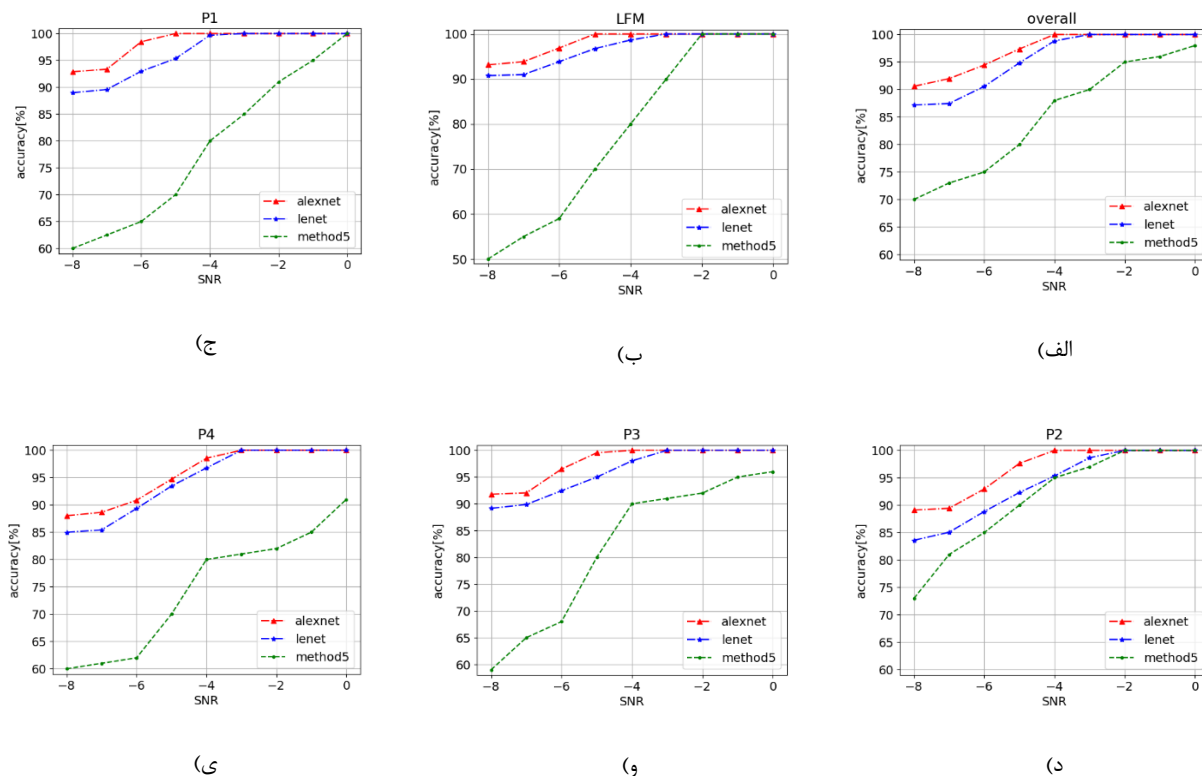
جدول (۴): مشخصات سخت‌افزاری استفاده شده در مرجع [۵]

RAM	16G DDR3 1600
CPU	E5-1620V2 (Intel)
M.B	ASUS Z270 GAMING
GPU	NVS315 (Quadro)

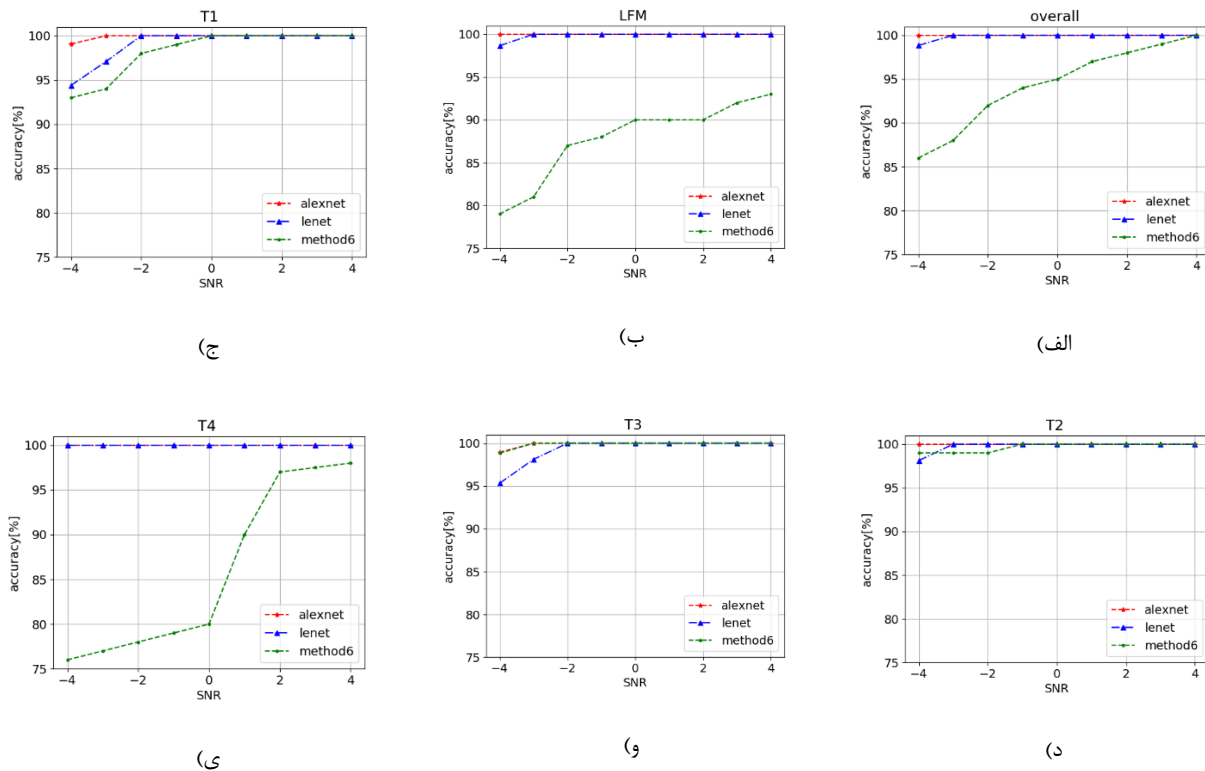
۲-۵. مقایسه عملکرد روش‌های پیشنهادی با روش [۶]

در این قسمت روش‌های پیشنهاد شده در این مقاله با روش ارائه شده در مرجع [۶] مورد مقایسه و تجزیه و تحلیل قرار خواهد گرفت. در روش ارائه شده در مرجع [۶] تشخیص نوع مدولاسیون سیگنال در ۳ مرحله انجام می‌گردد. در مرحله اول سیگنال دریافتی توسط گیرنده با استفاده از توزیع چوئی و بلیام در حوزه زمان-فرکانس مورد تجزیه و تحلیل قرار گرفته و خروجی به صورت یک تصویر ۲ بعدی به مرحله بعدی داده می‌شود و در مرحله بعد که می‌توان از آن به عنوان مرحله پیش پردازش نام برد، اندازه تصویر با توجه به نوع شبکه CNN تغییر کرده و در نهایت نرمالیزه شده و آماده برای ورود به شبکه CNN جهت تشخیص نوع مدولاسیون داده می‌شود.

مدولاسیون‌های مورد استفاده در این مقاله، برای مقایسه انتخاب شده‌اند. همان‌طور که در شکل (۴-الف)، حالت کلی نشان داده شده است، اگر مبنای دقت عملکرد ۱۰۰ درصد در نظر گرفته شود روش‌های لی‌نت و الکس‌نت در SNR، -۴dB، دقت عمل تقریباً ۱۰۰ درصدی را نشان می‌دهد در حالی که در روش [۵] دقت عمل در ۰dB نزدیک به ۱۰۰ درصد است. یعنی عملکرد کلاس‌بندی تمامی مدولاسیون‌ها در حالت کلی به اندازه ۴dB از روش ارائه شده در [۵] بهتر است. همچنین برای مقایسه دقت عمل روش‌ها چنانچه در شکل (۴-الف) مشاهده می‌گردد، در SNR، -۴dB، روش‌های پیشنهادی دارای دقت عملکرد ۱۰۰ درصدی و در روش [۵] در همان SNR دارای دقت عملکرد ۸۸ درصدی است که نشان از عملکرد خوب روش‌های پیشنهادی می‌باشد. با دقت در بقیه مدولاسیون‌های شکل (۴) می‌توان دریافت که در تمامی مدولاسیون‌ها دو شبکه CNN ارائه شده در این مقاله دارای عملکرد بهتری نسبت به روش ارائه شده در [۵] است. سخت‌افزار مورد استفاده در این مرجع، در جدول (۴) نشان داده شده است. همچنین شبیه‌سازی‌ها این مرجع در محیط متلب با ورژن ۲۰۱۲ انجام گرفته است.



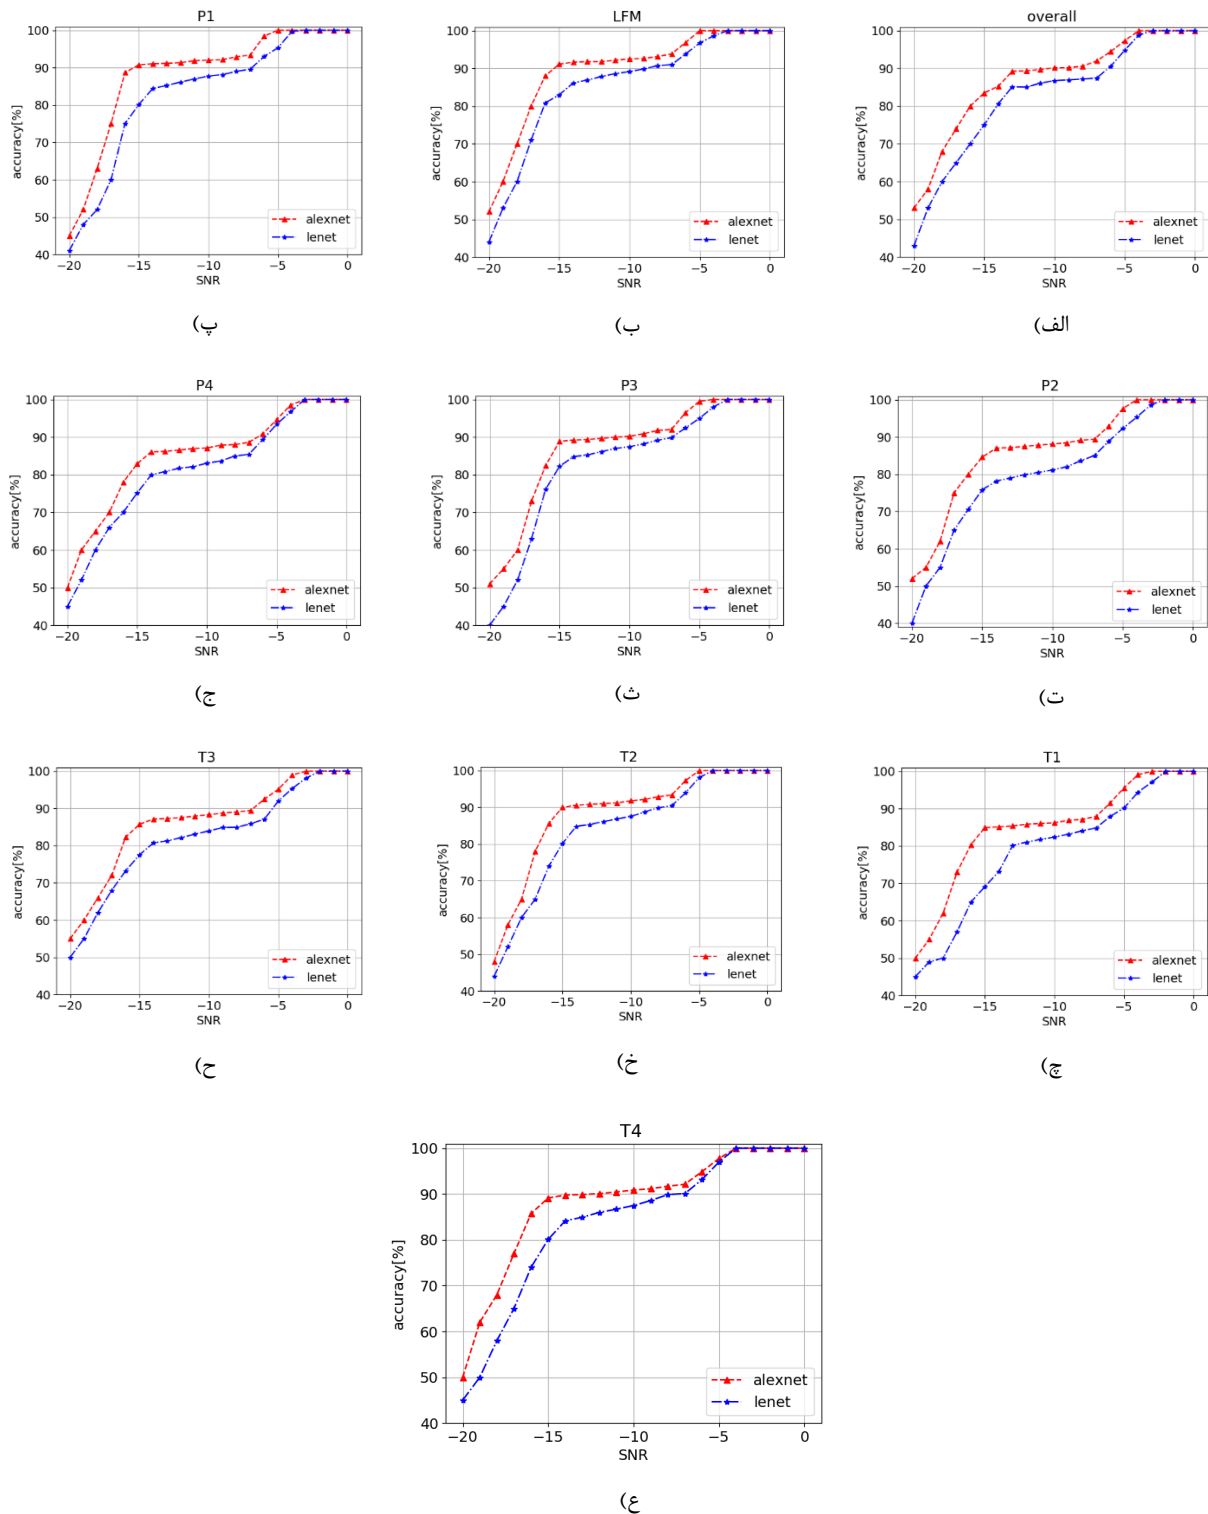
شکل (۴): مقایسه روش‌های پیشنهادی با روش [۵]. (الف) حالت کلی، (ب) LFM، (ج) P1، (د) P2، (و) P3، (ی) P4



شکل (۵): مقایسه روش‌های پیشنهادی با روش [۶]، (الف) حالت کلی، (ب) LFM، (ج) T1، (د) T2، (و) T3، (ی) T4

کلاس‌بندی تمامی مدولاسیون‌ها در روش‌های ارائه شده در این مقاله به اندازه ۷ dB از روش ارائه شده در [۶] بهتر است. همچنین در SNR، ۴ dB- دقت عمل روش‌های پیشنهادی در حالت کلی حدوداً برابر با ۱۰۰ درصد و برای روش ارائه شده در [۶] تقریباً برابر با ۸۵ درصد است. بهترین عملکرد روش‌های پیشنهادی در مقایسه با روش [۶] برای مدولاسیون‌های LFM، T4 است. تنها نقطه ضعف روش‌های پیشنهادی در مدولاسیون T3 می‌باشد که عملکرد روش [۶] نسبت به روش لی نت در مدولاسیون‌های T1، T2، دارای دقت عمل؛ کرد بهتری است.

شکل (۵) نتایج شبیه‌سازی روش‌های لی نت و الکس نت با روش [۶] را نشان می‌دهد. مدولاسیون‌هایی که در [۶] برای کلاس‌بندی استفاده شده، مدولاسیون‌های LFM، BPSK، Costas، Frank، T1، T2، T3، T4 است که ۵ 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 شکل (۵-الف) که حالت کلی است، نشان داده شده، اگر مبنای دقت عملکرد را ۱۰۰ درصد در نظر بگیریم روش‌های لی نت و الکس نت در SNR، ۴ dB- دارای دقت عملکرد ۱۰۰ درصدی هستند ولی در روش ارائه شده در [۶] تقریباً در ۳ dB دارای دقت عملکرد ۱۰۰ درصدی است پس می‌توان نتیجه گرفت عملکرد



شکل (۶): دقت عمل دو روش لی نت و الکسنت برای ۹ مدولاسیون ذکر شده در این مقاله، (الف) حالت کلی، (ب) LFM، (پ) P1، (ت) P2، (ث) P3، (ج) P4، (چ) T1، (خ) T2، (ح) T3، (ع) T4

جدول (۵): ماتریس کانفیوژن برای روش الکس نت در SNR=-5db.

mod	LFM	P1	P2	P3	P4	T1	T2	T3	T4	Noise
LFM	۲۰۰۰	۰	۰	۰	۰	۰	۰	۰	۰	۰
P1	۳۸	۱۹۴۰	۱۲	۰	۰	۱۰	۰	۰	۰	۰
P2	۰	۰	۲۰۰۰	۰	۰	۰	۰	۰	۰	۰
P3	۸	۴	۳	۱۹۶۰	۰	۱	۲۰	۱	۳	۰
P4	۱۰	۰	۰	۱۱	۱۹۷۱	۱	۱	۰	۶	۰
T1	۲	۷	۰	۰	۰	۱۹۸۰	۳	۳	۵	۰
T2	۲۰	۰	۰	۷	۰	۰	۱۹۴۰	۸	۵	۰
T3	۸	۰	۰	۱۴	۰	۱۰	۷	۱۹۵۶	۶	۰
T4	۱۰	۲۳	۰	۶	۱۷	۴	۰	۶	۱۹۳۴	۰
Noise	۰	۰	۰	۰	۰	۰	۰	۰	۰	۲۰۰۰

۲۰۰۰ تصویر است. با دقت در جدول مشخص است بهترین عملکرد برای تمامی سیگنال‌ها رخ داده است.

۶. نتیجه‌گیری

در این مقاله شناسایی و کلاس‌بندی اتوماتیک انواع مدولاسیون رادارهای LPI با استفاده از تحلیل زمان-فرکانس STFT و شبکه‌های لی نت و الکس نت که به‌عنوان شبکه‌های CNN می‌باشند برای ۹ نوع سیگنال این رادارها (LFM, P1, P2, P3, P4, T1, T2, T3, T4) با SNRهایی در محدوده -۲۰dB تا ۰dB انجام شد. با توجه به نتایج نشان داده شده در شکل (۶)، در شکل (۶-الف) که بیانگر حالت کلی است در SNR، ۱۵dB- شبکه الکس نت دارای دقت عملکرد ۸۳ درصد و در همان SNR شبکه لی نت دارای دقت عملکرد ۷۵ درصد را برای تمامی ۹ مدولاسیون، دارا می‌باشد. همچنین با پائین آمدن SNR از دقت عملکرد هر دو شبکه کاسته شده و در برخی موارد همانند P1, T2، تا زیر ۵۰ درصد هم نزول می‌کند. مقایسه دو روش لی نت و الکس نت نشان می‌دهد که روش الکس نت دارای نتایج و دقت عملکرد بهتری نسبت به روش لی نت در تمام ۹ سیگنال معرفی شده در SNRهای متفاوت را دارد. در روش الکس نت در حالت کلی برای SNR، ۶dB- دارای دقت ۹۳/۲ درصد است. بنابراین در عمل، روش الکس نت می‌تواند دارای عملکرد بهتری در آشکارسازی و کلاس‌بندی انواع سیگنال رادارهای LPI داشته باشد. به‌عنوان کارهای آتی می‌توان برای استخراج مشخصات این نوع از سیگنال‌ها در SNRهای پائین از پردازش سیگنال در حوزه یادگیری عمیق استفاده کرد.

۵-۳. عملکرد کلاس‌بندی سیگنال رادارهای LPI با استفاده از روش‌های لی نت و الکس نت

شکل (۶) نحوه عملکرد دو شبکه لی نت و الکس نت را برای SNRهایی در محدوده -۲۰dB تا ۰dB را نشان می‌دهد. نتایج مشاهده شده، نشان می‌دهد برای SNR، ۵dB- دقت عملکرد برای هر دو روش بالاتر از ۹۵ درصد است. همچنین مقایسه نتایج در تمامی مدولاسیون‌ها، نشان از عملکرد مناسب روش الکس نت با دقت عملکرد بالاتر نسبت به روش لی نت است. با توجه به شکل (۶-الف) هر دو روش در SNR، ۴dB- با ۱۰۰ درصد، بهترین عملکرد را دارند. همچنین برای ۹ مدولاسیون انتخابی در شکل (۶) با کم شدن میزان SNR رفته رفته دقت عملکرد این روش‌ها کم شده و در برخی از سیگنال‌ها در SNR، ۲۰dB- دقت عملکرد به زیر ۵۰ درصد هم می‌رسد.

۵-۴. ماتریس کانفیوژن

در علم یادگیری ماشین، بخصوص در زمینه کلاس‌بندی ورودی‌ها، ماتریس کانفیوژن به‌عنوان یک ماتریس خطا شناخته می‌شود. در حقیقت ماتریس کانفیوژن یک جدول است که برای تعیین عملکرد کلاس‌بندی یک مدل، بر روی ورودی‌هایی که به‌عنوان تست شبکه مورد استفاده قرار گرفته‌اند، بکار می‌رود. جدول (۵) ماتریس کانفیوژن را برای روش الکس نت در SNR، ۵dB- نشان می‌دهد. این جدول برای ۹ نوع مدولاسیون به همراه نویز تهیه شده است. تعداد تصاویر تست که برای هر کدام از ۱۰ نوع متفاوت از سیگنال‌ها در نظر گرفته شده است هر کدام

۷. مراجع

- [8] 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.
- [9] 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.
- [10] N. Levanon and E. Mozeson, "Radar Signals," New York, NY, USA: Wiley, 2004.
- [11] J. E. Fielding, "Polytime coding as a means of pulse compression," IEEE Trans. on Aerospace and Electronic Systems, vol. 35, pp. 716-721, 1999.
- [12] E. Sejdić, I. Djurović, and J. Jiang, "Time-frequency feature representation using energy concentration: An overview of recent advances," Digital Signal Processing, vol. 19, pp. 153-183, 2009.
- [13] K. Konopko, "A Detecton Algorithm of Lpi Radar Signals," SPA IEEE, Conference paper, 2007.
- [14] Y. LeCun and et al., "Gradient-Based Learning Applied to Document Recognition," Proceedings of the IEEE, vol. 86, pp. 2278-2324, 1998.
- [15] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "Image Net Classification with Deep Convolutional Neural Networks," IEEE Computer Society Conference paper, 2009.
- [1] P. E. Pace, "Detecting and Classifying Low Probability of Intercept Radar," Norwood, MA, USA: Artech House, 2009.
- [2] 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, pp. 879-898, 2005.
- [3] E. R. Zilberman and P. E. Pace, "Autonomous time-frequency morphological feature extraction algorithm for LPI radar modulation classification," IEEE Conference paper, 2006.
- [4] Seung-Hyun Kong, Minjun Kim, Linh Manh Hoang, and Eunhui Kim, "Automatic LPI Radar Waveform Recognition Using CNN," IEEE Access, vol. 6, pp. 4207-4219, 2018.
- [5] M. Zhang, L. Liu, and M. Diao, "LPI radar waveform recognition based on time-frequency distribution," Sensors, vol. 16, pp. 1682, 2016.
- [6] M. Zhang, M. Diao, and L. Guo, "Convolutional neural networks for automatic cognitive radio waveform recognition," IEEE Access, vol. 5, pp. 11074-11082, 2017.
- [7] GUO Limin and Chen Xin, "Low Probability of Intercept Radar Signal Recognition Based on the Improved AlexNet Model," ICOSP Conference paper, 2018.

Using LeNet-5 and AlexNet Architectures in Deep Learning Approach to Detect and Classify LPI Radar Signals

Gh. Ghadimi, Y. Norouzi^{*}, R. Bayderkhani, M. M. Nayebi

^{*} Amirkabir University of Technology, Tehran, Iran

(Received: 03/05/2019, Accepted: 31/12/2019)

Abstract

Low probability of intercept (LPI) radars are difficult to detect and identify by electronic intelligence receivers due to their low power, wide bandwidth and frequency variability. With the emergence of this technology, new methods of signal and image processing are constantly required to first identify, then classify, and finally extract the characteristics of these radar signals. To solve the problem, today deep learning is an important technical method in the signal and image processing fields. Through using this method, this paper will investigate the possibility of detecting and classifying different signals of LPI radars. To do this, using Short-Time Fourier Transform (STFT), we will analyze the received signal in the time-frequency domain, and then to detect and classify the LPI radar signal waveforms we send the output, in image format, to the AlexNet and the LeNet deep convolutional neural network (CNN) models. The simulation results show that, in SNR=-5dB, the accuracy of the AlexNet and the LeNet methods are 97.34% and 94% respectively, indicating the better performance of the AlexNet method.

Keywords: Deep Learning, Deep Convolutional Neural Network (CNN), LPI Radar

^{*} Corresponding author E-mail: y.norouzi@aut.ac.ir