

## بررسی تأثیر عوامل مخرب در تشخیص نوع مدولاسیون PRI با استفاده از دو مدل DCNN با ساختار و روش یادگیری متفاوت: یک مطالعه موردی

سید مجید حسنی اژداری<sup>۱\*</sup>، محمد کاظمی راد<sup>۲</sup>، محمد خویشه<sup>۳</sup>

۱، ۲ و ۳. دانشکده مهندسی برق، دانشگاه علوم دریایی امام خمینی (ره)، نوشهر، ایران.

### چکیده

مقاله حاضر به بررسی اثرات عوامل مخرب بر تشخیص مدولاسیون PRI در سیگنال های راداری با استفاده از دو مدل شبکه عصبی کانولوشنی VGG 16 و LeNet 5 با دو ساختار متفاوت می پردازد. مقاله از شبیه سازی های مبتنی بر محیط واقعی برای تولید داده ها استفاده می کند و عوامل مخرب را با درصد های مختلف مدنظر قرار می دهد تعداد تصاویر حاصل با اعمال مجموع عوامل مخرب بر روی آن برای هر محدوده عوامل مخرب (با درصد های مختلف) در نظر گرفته شده ۳۰۰۰۰ تصویر برای ۶ نوع مدولاسیون رایج هست. سپس، مدل VGG 16 با استفاده از روش یادگیری انتقالی و مدل LeNet 5 با استفاده از روش آموزش از صفر، آموزش داده می شوند. نتایج شبیه سازی نشان می دهد با افزایش درصد عوامل مخرب، دقت آموزش و آزمون مدل ها با مقدار قابل توجهی کاهش می یابد. همچنین، تأثیرات عوامل مخرب بر عملکرد مدل ها بررسی شده و نتایج نشان داده اند که LeNet 5 نسبت به مخرب ها مقاوم تر هستند و دقت بیشتری را حفظ می کنند. در نهایت، این تجزیه و تحلیل نشان می دهد که برای انتخاب مدل مناسب برای سامانه های شناسایی و پشتیبانی الکترونیکی می بایست تغییرات ناشی از مخرب ها، با توجه به این عوامل فراهم شود و استراتژی های مناسبی اعمال گردد. **واژه های کلیدی:** بازه تکرار پالس، رادار، شبکه عصبی کانولوشنی عمیق، یادگیری انتقالی.

## Investigating the effect of destructive factors in the detection of PRI modulation type using two DCNN models with different structures and learning methods: A case study

Seyed Majid Hasani Azhdari<sup>1\*</sup>, Mohammad Kazemirad<sup>2</sup>, Mohammad Khishe<sup>3</sup>

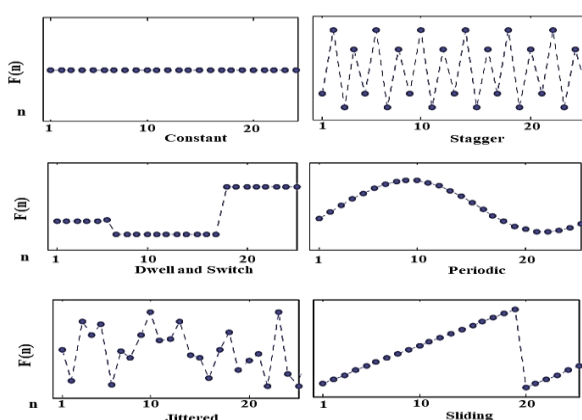
1,2,3. Department of Electronic Warfare, Faculty of Electrical Engineering, Imam Khomeini University of Marine Sciences, Nowshahr, Iran

### Abstract

This article examines the effects of destructive factors on detecting PRI modulation in radar signals using two convolutional neural network models, VGG 16 and LeNet 5, with two different structures. The paper uses simulations based on the actual environment to generate data and consider malicious agents with various percentages. The number of images obtained by applying the sum of malicious agents on it for each range of malicious agents (with different percentages) considered is 30,000 images for 6 Modulation type is standard. Then, the VGG16 model is trained using the transfer learning method, and the LeNet 5 model is trained using the zero training method. The simulation results show that the accuracy of training and testing the models decreases significantly with the increase in the percentage of destructive factors. Also, destructive agents' effects on models' performance have been investigated. The results have shown that LeNet 5 is more resistant to malicious agents and maintains more accuracy. Finally, this analysis indicates that to choose the right model for electronic identification and support systems, the changes caused by malicious agents should be provided according to these factors, and appropriate strategies should be applied.

**Key words:** Pulse repetition interval, Radar, Deep convolutional neural network, Transfer learning.

- در ابتدا مجموعه داده موردنظر با درصد مختلف عوامل مخرب تهیه گردید. برای هر نوع مدولاسیون و هر محدوده عوامل مخرب ۵۰۰۰ تصویر شبیه‌سازی گردیده است و مجموع عوامل مخرب بر روی هر تصویر اعمال شده است.
- سپس دو نوع شبکه DCNN (VGG 16 و LeNet 5) با ساختارهای متفاوت مبتنی بر یادگیری انتقالی و یادگیری از صفر با استفاده از مجموعه داده‌های مختلف آموزش داده می‌شوند و عملکرد آن‌ها بر روی هر مجموعه داده مورد ارزیابی قرار خواهد گرفت.
- در نهایت تجزیه و تحلیل‌های لازم به توجه به موضوع مقاله انجام خواهد گرفت.



شکل ۱- انواع مدولاسیون PRI

خودکار و خودکافی‌سازی در محیط پیچیده جنگ الکترونیک مدرن یک مسئله حیاتی و ضروری در سامانه‌های شناسایی الکترونیکی<sup>۱</sup> (ELINT)، سامانه‌های پشتیبانی الکترونیکی<sup>۲</sup> (ESM) و همچنین سامانه‌های هشداردهنده راداری<sup>۳</sup> (RWR) هست. وظیفه این سامانه‌ها جستجو، کشف، تجزیه و تحلیل و شناسایی پارامترهای سیگنال‌های راداری است. یکی از مسائل کلیدی در این سامانه‌های هوشمند مدرن تشخیص مدولاسیون بازه (زمان) تکرار پالس<sup>۴</sup> (PRI) هست. یکی از جنبه‌های اصلی تحلیل سیگنال و منبع مهمی برای شناسایی منبع تابش در این سامانه‌ها و تشخیص دقیق تهدیدات راداری است [۱-۴]. در فناوری راداری مدرن، انواع مختلف مدولاسیون PRI پیچیده به جای الگوی ثابت ساده استفاده می‌شود؛ بنابراین، شناسایی الگوی مدولاسیون PRI به شناسایی منابع انتشار کمک شایانی می‌کند. با این حال، این عمل به دلیل اثرات مخرب از جمله پالس‌های ازدست‌رفته، پالس‌های ناخواسته و اثرات نامطلوب اسکن آنتن (نقاط پرت بزرگ) که منجر به دنباله نویزی مدولاسیون PRI می‌شوند به یکی از مسائل چالش‌برانگیز بزرگ در حوزه شنود و تجزیه و تحلیل سیگنال‌های راداری تبدیل شده است. بعلاوه گوناگونی پارامترها در هر نوع مدولاسیون PRI وظیفه شناسایی را بسیار دشوارتر می‌کند. به‌طور کلی، رادارها از شش نوع اصلی مدولاسیون PRI به شرح جدول (۱) استفاده می‌کنند [۱، ۵]. در شکل (۱) نمونه‌ای از انواع مدولاسیون PRI آورده شده است [۵].

مشارکت‌های اصلی مقاله به شرح زیر می‌باشد:

- در این مقاله در نظر است میزان تأثیر عوامل مخرب در شناسایی ۶ نوع مدولاسیون اصلی PRI سیگنال‌های راداری با استفاده از ۲ مدل شبکه DCNN مبتنی بر یادگیری انتقالی و یادگیری از صفر مورد بحث و ارزیابی قرار گیرد.

جدول ۱- انواع مدولاسیون PRI

مشخصات	نوع مدولاسیون PRI	ردیف
در PRI نوع Constant تغییرات نوعاً کمتر از ۱٪ از مقدار میانگین PRI‌های ثابت با پایداری زیاد متناسب با سامانه‌های پالس دوپلر (MTI) هست.	Constant	۱
در PRI نوع Jitter، تغییرات زیاد تا حدود ۳۰٪ متوسط PRI وجود دارد که برای مقاومت در برابر اهداف ضدراداری (اخلال راداری) و کاهش تداخل با سیگنال‌های دیگر استفاده می‌شود.	Jitter	۲
در PRI نوع Dwell and switch، خوشه‌هایی از پالس‌ها، هر کدام با PRI ثابت که از یک خوشه به خوشه‌ی دیگر تغییر می‌کند، مورد استفاده قرار می‌گیرد، به منظور رفع ابهام در محاسبه سرعت یا برد اهداف و افزایش دقت در تشخیص در رادارها استفاده می‌گردد.	Dwell and Switch	۳
در PRI نوع Stagger، چندین PRI ثابت بر مبنای پالس به پالس و الگوی تناوبی تکرار می‌شود که برای حذف اثرات سرعت کور در سامانه‌های MTI و افزایش دقت در تشخیص اهداف استفاده می‌شود.	Stagger	۴
در PRI نوع Sliding، حداکثر PRI (در حداقل ارتفاع) معمولاً کمتر از شش برابر حداقل PRI (در حداکثر ارتفاع) استفاده می‌شود، به منظور تأمین پوشش ثابت در ارتفاع در حین مرور زاویه‌ی فراز یا اجتناب از گرفتگی استفاده می‌گردد.	Sliding	۵
در PRI نوع Periodic، تغییرات سینوسی تا ۵٪ میانگین PRI یا فرکانس تا ۵۰ هرتز یا بیشتر وجود دارد که برای هدایت موشک، احتراز از گرفتگی و فاصله‌یابی در رادارهای نظامی استفاده می‌شود.	Periodic	۶

<sup>4</sup> Pulse repetition interval

<sup>1</sup> Electronic intelligence

<sup>2</sup> Electronic measures

<sup>3</sup> Radar warning receiver

## ۲- بررسی ادبیات تحقیق

در فناوری راداری‌های مدرن، انواع مختلف مدولاسیون PRI پیچیده به جای الگوی ثابت ساده استفاده می‌شود؛ بنابراین، شناسایی مدولاسیون PRI به شناسایی منابع انتشار کمک شایانی می‌کند. با این وجود این مسئله به دلیل اثرات مخرب - از دست دادن درصدی از پالس‌ها و پالس‌های ناخواسته و نقاط پرت بزرگ - که ممکن است باعث دنباله بسیار نویزی مدولاسیون PRI شود، یک مسئله پیچیده‌ای است. علاوه بر این، گوناگونی پارامترها در هر نوع مدولاسیون PRI وظیفه شناسایی را بسیار دشوارتر و به یک چالش بزرگ در شناسایی انواع مدولاسیون PRI تبدیل کرده است. برای حل مسئله تشخیص و طبقه‌بندی مدولاسیون PRI، تحقیقات گسترده‌ای انجام شده است. روش‌های موجود را می‌توان به طور کلی به ۳ دسته مبتنی بر آمار، مبتنی بر درخت تصمیم و مبتنی بر یادگیری تقسیم‌بندی نمود که خود یادگیری به دو تکنیک مبتنی بر یادگیری و مبتنی بر یادگیری عمیق تقسیم‌بندی می‌شوند [۴، ۶]. در روش‌های مبتنی بر آمار کلاسیک از تکنیک هیستوگرام برای تشخیص انواع مدولاسیون PRI استفاده می‌کنند. چون این روش‌ها ساده هستند، قادر به تشخیص تعداد کمی از مدولاسیون PRI می‌باشند و عملکرد آن‌ها تحت شرایط نویزی بسیار کاهش می‌یابد [۴، ۶]. روش‌های مبتنی بر درخت تصمیم [۴، ۶] به آستانه‌های دست‌ساز بسیار نیازمند است که علاوه بر زمان بر بودن نسبت به میزان نویز و تغییر پارامترهای PRI بسیار حساس هستند. روش‌های مبتنی بر خودهمبستگی باینکه در پالس‌های از دست‌رفته عملکرد مطلوبی دارند ولی در برابر پالس‌های نویزی بسیار آسیب‌پذیر هستند. در مرجع [۷] طبقه‌بندی کننده شبکه عصبی با یک لایه پنهان منفرد پیشنهاد شده است که مجموعه‌ای از تفاوت‌های دوم زمان‌های ورودی (TOA) آموزش داده شده است. نتایج شبیه‌سازی نشان می‌دهد که روش پیشنهادی در ۱۰٪ پالس‌های از دست‌رفته در ۲۰۰۰۰ مجموعه داده به دقت تشخیص ۹۹/۹۵٪ در چهار نوع مدولاسیون PRI رسیده است. در مرجع [۸] یک شبکه عصبی پیش‌خور معرفی شده است که متشکل از یک لایه ورودی با سه ویژگی مستقل شده و یک لایه پنهان منفرد از هشت نورون است. این روش فقط می‌تواند چهار نوع مدولاسیون PRI را طبقه‌بندی کند. در این رویکرد دقت تشخیص در ۱۵٪ پالس‌های از دست‌رفته و ۲۵٪ پالس‌های نویزی به بیشتر از ۹۹٪ برای ۶۰۰۰۰ داده رسیده است. قابل ذکر است که همه روش‌های مبتنی بر یادگیری فوق‌الذکر نیاز به طراحی دقیق ویژگی‌ها و فرایند استخراج ویژگی قبل از استفاده از شبکه عصبی دارند. این اشکال از انطباق سریع روش‌ها با تغییرات در مدولاسیون PRI جلوگیری می‌کند. با این حال، مزیت این روش‌های هوشمند ذکر شده در بالا این است که آن‌ها می‌توانند برخی از حالت‌های اساسی مدولاسیون PRI را با روش‌های مختلف تشخیص دهند. با این حال، معایب کاملاً مشابه هستند زیرا آن‌ها

مقدار زیادی کار در پیش‌پردازش داده‌ها دارند و نتایج نمی‌توانند با نسبت بالای پالس‌های از دست‌رفته و پالس‌های ناخواسته، با محیط سازگار شوند. اخیراً، یادگیری عمیق [۹-۱۱] به عنوان ابزاری قدرتمند برای بسیاری از کارهای طبقه‌بندی ظهور کرده است و برخی از محققان یادگیری عمیق را برای تشخیص الگوی تغییرات سیگنال رادار معرفی کرده‌اند [۳، ۱۱-۱۴]، چون یادگیری عمیق می‌تواند به صورت خودکار مشخصات سیگنال‌ها را استخراج کند و موفقیت بزرگی در خیلی از زمینه‌ها، همانند پردازش تصویر، تشخیص صحبت، آشکارسازی اشیاء و به همین ترتیب داشته است [۱۵]. در مرجع [۳] نویسندگان از یک شبکه عصبی بازگشتی برای شناسایی چهار نوع مدولاسیون PRI تحت شرایط ۲-۳٪ پالس‌های از دست‌رفته اقدام نموده‌اند. نتایج شبیه‌سازی نشان می‌دهد رویکرد پیشنهادی به دقت ۹۹/۹۱٪ برای ۴۵۰۰۰۰ داده دست‌یافته است.

در مرجع [۱۶] نویسندگان یک شبکه عصبی پیش‌خور مبتنی بر یادگیری برای تشخیص هفت نوع مدولاسیون PRI ارائه دادند و این روش از طبقه‌بندی کننده‌های پیش‌رفته PRI در طیف گسترده‌ای از پارامترهای شبیه‌سازی و تحت پالس‌های از دست‌رفته بین ۰-۱۰٪ و پالس‌های ناخواسته بین ۰-۱۰٪ بر روی ۱۴۰۰۰۰ مجموعه داده شبیه‌سازی شده به دقت تشخیص ۹۹/۵۹٪ بهتر عمل می‌کند. در [۱۷] نویسندگان یک رویکرد تلفیقی یادگیری چندوظیفه‌ای مبتنی بر یادگیری عمیق ۲ (DMTL) را برای تشخیص پنج نوع مدولاسیون PRI معرفی کرده‌اند. یافته‌های شبیه‌سازی بر روی ۱۰۰۰۰ نمونه نشان می‌دهد که دقت تشخیص مدولاسیون ۷۲/۳٪ است. در این رویکرد درصد پالس‌های از دست‌رفته و پالس‌های ناخواسته هر کدام ۳۰٪ در نظر گرفته شده است. نویسندگان در [۱۸] یک چارچوب تشخیص مبتنی بر توجه ۳، معروف به شبکه عصبی بازگشتی ۴ (ARNN) را برای تشخیص شش نوع مدولاسیون PRI ارائه داده‌اند. این چارچوب برای پاسخ به نسبت‌های بالایی از پالس‌های گمشده و ناخواسته طراحی شده است. نتایج شبیه‌سازی نشان می‌دهد که این مدل در بهترین حالت به دقت تشخیص ۹۲/۱۸٪ دست می‌یابد. این مطالعه شامل مجموعه داده‌ای از ۲۴۰۰۰۰ نمونه داده، با نرخ پالس ناخواسته ۷۰٪ و نرخ پالس از دست‌رفته ۵۰٪ است. در سال‌های اخیر، محققان استفاده از شبکه‌های عصبی کانولوشنال عمیق ۵ (DCNN) را برای تشخیص الگوی تغییرات PRI بررسی کرده‌اند [۱۹]. DCNN ها نوعی شبکه عصبی مصنوعی هستند که معمولاً در تشخیص تصویر و گفتار استفاده می‌شوند [۲۰-۲۲]. DCNN ها به دلیل توانایی خود در یادگیری و استخراج ویژگی‌ها از داده‌های خام به طور خودکار در کاربردهای مختلف موفق بوده‌اند [۲۳-۲۵]. نویسندگان [۲۶] روشی مبتنی بر DCNN برای تشخیص هفت الگوی مختلف مدولاسیون PRI پیشنهاد کردند. نتایج شبیه‌سازی نشان می‌دهد که دقت تشخیص کل برابر ۹۶/۱٪، با حداکثر ۵۰٪

4 Recurrent neural network

5 Deep convolutional neural network

1 Time Of Arrival

2 Deep learning-based multitasking learning

3 Attention-based recognition framework

پالس‌های ازدست‌رفته و ۲۰٪ پالس‌های ناخواسته است. مجموعه داده‌های استفاده‌شده در این رویکرد برابر ۲۵۰۰۰ نمونه هست. مرجع [۶] یک DCNN برای طبقه‌بندی هفت الگوی متمایز تغییرات PRI استفاده می‌کند. یافته‌های شبیه‌سازی نشان می‌دهد که دقت تشخیص کلی تقریباً ۹۶٪ است درحالی‌که نرخ پالس‌های ازدست‌رفته و پالس‌های ناخواسته به‌طور تصادفی از ۲۵٪ تا ۳۰٪ متغیر است. مجموعه داده شامل ۳۰۰۰ نمونه برای هر نوع مدولاسیون PRI است. مرجع [۲۷] یک رویکرد جدید را معرفی می‌کند که از ویژگی ذاتی شبکه کانولوشنال زمانی (TCN) استفاده می‌کند. یافته‌های شبیه‌سازی نشان می‌دهد که این روش می‌تواند به‌طور دقیق هفت نوع متمایز از مدولاسیون PRI را طبقه‌بندی کند، در این رویکرد دقت تشخیص بیش از ۹۸٪ در درصد پالس‌های ازدست‌رفته و پالس‌های ناخواسته ۳۰٪ و نقاط پرت بزرگ (که در اثر اسکن آنتن‌های رادار ایجاد می‌شود) -- ۱۰٪ حاصل شده است. نتایج از حجم نمونه ۴۰۰۰۰ آزمایشی به‌دست‌آمده است که به‌طور تصادفی از مجموعه‌ای از هفت مدولاسیون مجزا انتخاب‌شده‌اند که هر کدام دارای احتمال یکسانی برای انتخاب می‌باشند. در مطالعه [۱۹]، نویسندگان یک سیستم DCNN را برای طبقه‌بندی مدولاسیون PRI ارائه کردند. نتایج شبیه‌سازی نشان می‌دهد که این روش می‌تواند هشت نوع مجزا از مدولاسیون PRI را با دقت طبقه‌بندی کند و به‌دقت تشخیص کلی ۹۸/۵٪ دست یابد. در این روش درصد پالس‌های از دست رفته و پالس‌های ناخواسته ۱۵٪ در نظر گرفته شده است. مجموعه داده شامل ۱۶۰۰۰ نمونه برای هر نوع مدولاسیون PRI است. یک تکنیک منحصربه‌فرد مبتنی بر DCNN در [۴] معرفی شده است. در این رویکرد از ۶۰۰۰۰ داده واقعی جهت ارزیابی روش پیشنهادی استفاده شده است. این روش به‌دقت ۹۷/۰۵٪ در


تشخیص پنج نوع مدولاسیون PRI سیگنال‌های راداری واقعی دست‌یافته است. در جدول (۲) به‌طور خلاصه روش‌های مبتنی بر یادگیری و یادگیری عمیق در تشخیص نوع مدولاسیون PRI خلاصه شده است. در حال حاضر، تشخیص دقیق مدولاسیون بازه تکرار پالس سیگنال‌های راداری با اثرات مخرب به چالش‌هایی مواجه است که می‌تواند دقت و قابلیت اطمینان این سامانه‌ها را تحت تأثیر قرار دهد. با توجه به مطالب بالا، عملکرد قابل توجه DCNN‌ها در تشخیص مدولاسیون PRI منجر به پذیرش گسترده آن‌ها در سال‌های اخیر شده است. باین وجود، کمبود تحقیقات عمیق در مورد اینکه چگونه عوامل مخرب مانند پالس‌های ازدست‌رفته، پالس‌های ناخواسته و نقاط پرت بزرگ بر دقت شناسایی PRI با استفاده از DCNN در ادبیات موجود تأثیر می‌گذارد، وجود ندارد. برای رفع این نیاز، در این تحقیق ما از دو نوع DCNN با دو ساختار متفاوت برای تعیین تأثیر درجات مختلف عوامل مخرب بر دقت تشخیص استفاده کردیم. ما نشان می‌دهیم که چگونه این عوامل بر عملکرد هر معماری DCNN با استفاده از مجموعه‌های داده با درجات مختلف عوامل تأثیر می‌گذارند. این استحکام مدل‌های مختلف را نیز روشن می‌کند. با مقایسه دو مدل DCNN، می‌توان دید که کدام یک بهتر می‌تواند در برابر این نوع حملات مقاومت کنند که در شرایط سخت، نقاط قوت و ضعف DCNN را روشن می‌کند. این روش که برای درک کاربردهای دنیای واقعی شبکه‌ها مهم است، راه‌هایی را که استحکام و عملکرد آن‌ها متفاوت است روشن می‌کند. این تحقیق به چگونگی تأثیر عوامل مخرب بر دقت تشخیص به ادبیات موجود می‌افزاید.

جدول ۲- خلاصه روش‌های مبتنی بر یادگیری و یادگیری عمیق.

مرجع	دقت (%)	تعداد مدولاسیون	مجموعه داده	عوامل مخرب			روش	ردیف
				نقاط پرت بزرگ	پالس‌های ناخواسته	پالس‌های ازدست‌رفته		
[۷]	۹۹/۹۵٪	۴ نوع	۲۰۰۰۰	---	---	۱۰٪	شبکه عصبی با یک لایه پنهان	۱
[۸]	۹۹٪	۴ نوع	۶۰۰۰۰	--	۲۵٪	۱۵٪	شبکه عصبی پیش‌خور با یک لایه پنهان	۲
[۱۶]	۹۹/۵۹٪	۷ نوع	۱۴۰۰۰۰	--	۱۰-۰٪	۱۰-۰٪	شبکه عصبی پیش‌خور	۳
[۱۷]	۷۲/۳٪	۷ نوع	۱۰۰۰۰	--	۳۰٪	۳۰٪	یادگیری چندوظیفه‌ای مبتنی بر یادگیری عمیق (DMTL)	۴
[۳]	۹۹/۹۱٪	۴ نوع	۴۵۰۰۰۰	--	--	۳۰-۲٪	شبکه عصبی بازگشتی	
[۱۸]	۹۲/۱۸٪	۶ نوع	۲۴۰۰۰۰	--	۷۰٪	۵۰٪	شبکه عصبی بازگشتی	۵
[۲۶]	۹۶/۱٪	۷ نوع	۲۵۰۰۰	--	۲۰٪	۵۰٪	شبکه عصبی کانولوشنی عمیق	۶
[۶]	۹۶٪	۷ نوع	۲۱۰۰۰	--	۳۰-۲۵٪	۳۰-۲۵٪	شبکه عصبی کانولوشنی عمیق	۷
[۲۷]	بیش از ۹۸٪	۷ نوع	۴۰۰۰۰	۱۰-۰٪	۳۰٪	۲۰٪	شبکه عصبی کانولوشن زمانی	۸
[۱۹]	۹۸/۵٪	۸ نوع	۱۶۰۰۰	--	۱۵٪	۱۵٪	شبکه عصبی کانولوشنی عمیق	۹
[۴]	۹۷/۰۵٪	۵ نوع	۶۰۰۰۰	داده‌های واقعی			شبکه عصبی کانولوشنی عمیق بهبودیافته	۱۰

### ۳- دانش پیشینه

این بخش به مروری اساسی به مفاهیم بازه تکرار پالس (PRI) و شبکه‌های عصبی کانولوشنی می‌پردازد.



شکل ۳- معماری DCNN.

یکی از موفق‌ترین مدل‌های یادگیری عمیق برای تحلیل تصویر تا به امروز، DCNN است. انواع مختلفی از DCNN در مطالعات مختلف پیشنهاد شده است، مانند LeNet-5 [۳۰]، AlexNet [۳۱]، ZfNet [۳۲]، GoogleNet [۳۳]، VGGNet [۳۴]، ResNet [۳۵] و غیره.

#### ۳-۲-۱- شبکه VGG16

شبکه VGG16 یکی از معماری‌های معروف شبکه‌های عصبی کانولوشنی است که توسط گروه Visual Geometry Group از دانشگاه آکسفورد در سال ۲۰۱۴ طراحی شد. این شبکه دارای ۱۶ لایه است که شامل ۱۳ لایه کانولوشنی و ۳ لایه کاملاً متصل ۴ هست. ویژگی برجسته VGG16 استفاده از فیلترهای کوچک ۳\*۳ در لایه‌های کانولوشنی است که به شبکه این امکان را می‌دهد تا ویژگی‌های پیچیده‌تری را از تصاویر استخراج کند. همچنین، در این شبکه از لایه‌های ادغام حداکثری ۵ برای کاهش ابعاد و کاهش تعداد پارامترها استفاده می‌شود. ساختار ساده و متقارن آن با استفاده از فیلترهای کوچک، آن را قادر می‌سازد تا ویژگی‌های پیچیده تصاویر را با کارایی بالا شبیه‌سازی کند، در حالی که تعداد پارامترها نسبتاً زیاد است. این مدل در مسابقات بینایی ماشین مانند ImageNet موفقیت چشمگیری داشت و به یکی از معماری‌های پایه‌ای برای بسیاری از کاربردهای بینایی کامپیوتری تبدیل شد [۳۶، ۳۷].

#### ۳-۲-۲- شبکه LeNet 5

شبکه LeNet-5 یکی از اولین شبکه‌های عصبی کانولوشنی (CNN) است که توسط یان لکن در سال ۱۹۹۸ برای تشخیص دست‌نوشته‌های ارقام در سامانه‌های پستی ایالات متحده طراحی شد. این شبکه شامل ۷ لایه است که شامل لایه‌های کانولوشنی، لایه‌های ادغام ۶ و لایه‌های کاملاً متصل است. ساختار LeNet-5 شامل دو لایه کانولوشنی، دو لایه ادغام و سه لایه کاملاً متصل است. شبکه به‌طور ویژه برای شناسایی الگوها در تصاویر ساده و کوچک طراحی شده بود و به‌عنوان یکی از پایه‌گذاران شبکه‌های عصبی عمیق در کارهای پردازش تصویر و بینایی ماشین شناخته می‌شود. ویژگی اصلی این شبکه

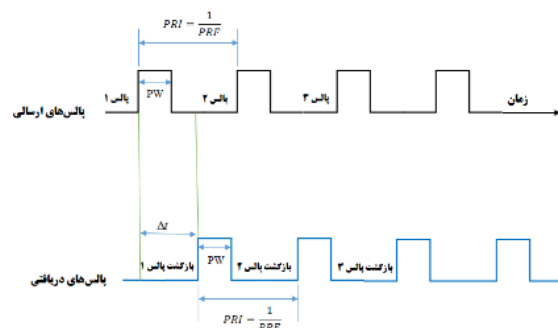
### ۳-۱- بازه تکرار پالس

یک سامانه رادار سیگنالی به نام پالس» به سمت هدف ارسال می‌کند. فاصله بین شروع یک پالس تا شروع پالس بعدی، بازه تکرار پالس (PRI) نامیده می‌شود. در شکل (۲) پالس ارسال و دریافتی در یک رادار مشاهده می‌شود [۵]. عکس PRI را فرکانس تکرار پالس (PRF) گویند که برحسب واحد فرکانس بیان می‌گردد. هر سری پالس به‌عنوان یک قطار پالس شناخته می‌شود و می‌توان آن را به‌عنوان یک سری زمانی پیوسته از داده‌ها مشاهده کرد. الگویی که بازه تکرار پالس را تعریف می‌کند، اغلب به‌عنوان مدولاسیون PRI شناخته می‌شود. مدولاسیون‌های مختلف PRI وجود دارند که بیشتر آن‌ها می‌توانند در دسته‌های خاصی دسته‌بندی شوند. PRI پارامتر مهمی هست، زیرا با شناسایی مدولاسیون آن هدف و عملکرد رادار در بسیاری از موارد آشکار می‌گردد [۴، ۲۸، ۲۹]. معادله زیر تابع عمومی برای یک دنباله PRI که شامل N پالس است را نشان می‌دهد. در اینجا tn زمان ورود پالس‌ها است. یک فرستنده مشخص می‌کند که چقدر باید قبل از ارسال پالس جدید منتظر بماند و بنابراین از نسخه‌های مختلف تابع F(n) استفاده می‌کند [۵، ۲۸، ۲۹]:

$$F(n) = t_{n+1} - t_n, n \in Z_n \quad (1)$$

### ۳-۲- شبکه‌های عصبی کانولوشنی

شبکه عصبی کانولوشنی عمیق (DCNN) یک شبکه عصبی پیش‌خوری را نشان می‌دهد که شامل ترکیب‌های مختلفی از لایه‌های کانولوشنی، لایه‌های ادغام ۳ و یک شبکه عصبی با اتصال کامل است. این نوع شبکه از همبستگی مکانی ویژه‌ای با استفاده از یک الگوی اتصالی محلی بین نورون‌های لایه‌های هم‌جوار بهره‌برداری می‌کند [۱۰]. ساختار مذکور در شکل (۳) نشان داده شده است [۵].



شکل ۲- قطار پالس ارسال و دریافتی در یک رادار

<sup>4</sup> Fully Connected

<sup>5</sup> Max-Pooling

<sup>6</sup> Pooling

<sup>1</sup> Pulse Repetition Frequency

<sup>2</sup> Deep convolutional neural network

<sup>3</sup> Pooling layers

استفاده از فیلترهای کانولوشنی برای استخراج ویژگی‌های مهم از تصاویر و کاهش تعداد پارامترها از طریق لایه‌های ادغام است که به کاهش پیچیدگی محاسباتی کمک می‌کند [۳۸, ۳۹]. در جدول (۳) پارامترهای شبکه‌های VGG16 و LeNet-5 آورده شده است.

#### ۴- روش پیشنهادی

در این رویکرد، ما از دو مدل شبکه کانولوشنی VGG 16 و LeNet 5 با ساختار متفاوت و دو مدل یادگیری استفاده کردیم. برای آموزش LeNet 5 از یادگیری از صفر<sup>۱</sup> و برای آموزش VGG 16 از یادگیری انتقالی<sup>۲</sup> استفاده کردیم. روش آموزش LeNet-5 که در آن کل شبکه را از ابتدا با داده‌های خود آموزش داده می‌شوند. در این روش، هیچ وزنه یا ویژگی از پیش آموزش دیده شده‌ای وجود ندارد و تمامی پارامترهای شبکه از طریق فرآیند آموزش و بر اساس داده‌های ورودی جدید بهینه می‌شوند. برای آموزش VGG 16، ما از یک روش یادگیری انتقال استفاده می‌کنیم که از VGG 16 از پیش آموزش دیده استفاده می‌کند. قبلاً این معماری‌ها را بر روی مجموعه داده ImageNet آموزش داده شده است که پایه‌ای قوی برای استخراج ویژگی از مجموعه‌های داده تصویری مختلف فراهم می‌کند. اصلاح لایه‌های کاملاً متصل این شبکه‌ها به ما این امکان را می‌دهد که آن‌ها را باهدف طبقه‌بندی مدولاسیون PRI خاص خود تنظیم کنیم. این مدل‌ها از نمایش‌های ویژگی‌هایی که قبلاً آموخته‌اند سود می‌برند، زیرا هر شبکه لایه‌های کانولوشنال خود را با وزن‌هایی از آموزش ImageNet حفظ می‌کند. ما لایه‌های کاملاً متصل اصلی (۳ لایه) را با جایگزینی لایه‌های جدید دوباره آموزش می‌دهیم: لایه اول با ۵۱۲ نورون فعال شده توسط یک تابع فعال‌ساز ReLU، لایه دوم با ۱۲۸ نورون فعال شده توسط یک تابع فعال‌ساز ReLU و لایه خروجی نهایی با ۶ نورون، یکی برای هر مدولاسیون PRI که توسط یک تابع فعال‌ساز Softmax برای ارائه

نتایج طبقه‌بندی فعال می‌شود. با استفاده از این روش، می‌توانیم مدولاسیون‌های PRI را تحت تنظیمات مخرب مختلف با استفاده از ویژگی‌های غنی از پیش آموزش دیده شده DCNN و اصلاح لایه‌های نهایی، به‌دقت دسته‌بندی کنیم. به‌منظور آموزش شبکه‌های به‌روز شده برای این کار طبقه‌بندی خاص، از داده‌های سیگنال رادار خود استفاده می‌کنیم.

#### ۴-۱- مجموعه داده

مدل توضیح داده شده در بخش قبل بر روی مجموعه‌ای از داده‌های تولید شده با شبیه‌سازی محیط واقعی مرتبط آموزش و آزمایش شده است. برای شبیه‌سازی سناریوهای واقعی، ابتدا اثرات اسکن آنتن رادار در نظر گرفته شد. این پدیده‌ها به‌وضوح منجر به تغییرات بسیار زیادی در دو زمان ورود سیگنال متوالی (در مقایسه با PRI اصلی) می‌شوند که می‌توانند به‌عنوان ده‌ها تا هزاران پالس از دست‌رفته مجاور در نظر گرفته شوند. اگرچه تعداد این موارد پرت خیلی زیاد نیست (تقریباً ۱۰-۱٪)، اما می‌تواند به‌طور چشمگیری دقت طبقه‌بندی را کاهش دهد [۵, ۲۷]. برخلاف کارهای تحقیقاتی قبلی در این زمینه، ما به مشکل تشخیص مدولاسیون PRI با در نظر گرفتن تمام اثرات مخرب در دنیای واقعی می‌پردازیم. موضوع مهم دیگر تعداد پالس‌هایی است که در سیستم تشخیص و طبقه‌بندی کننده اعمال می‌شود. هنگامی که مدولاسیون پیچیده است یا دوره بزرگ است، نوع مدولاسیون را می‌توان تنها در صورتی تشخیص داد که تعداد پالس‌های کافی دریافت شود. به‌طور شهودی و تجربی، ۱۰۰-۲۵۰ پالس برای این منظور کافی است [۵, ۲۷]. محدوده PRI ورودی یکی دیگر از موضوعات کلیدی در این زمینه است. در مراجع [۱۸, ۲۶, ۴۰-۴۳]، PRI های متوسط برای ارزیابی روش‌های پیشنهادی شبیه‌سازی شدند. با این حال، در یک سیستم ESM یا ELINT واقعی، طیف وسیعی از PRI ها باید تجزیه و تحلیل شوند.

جدول ۳- پارامترهای VGG16 و LeNet-5

پارامترها	VGG16	LeNet-5
اندازه ورودی	224x224x3	224x224x3
تعداد کانال‌های ورودی	3 (RGB)	3 (RGB)
تعداد کلاس‌ها (خروجی)	۶ (انواع مدولاسیون PRI)	۶ (انواع مدولاسیون PRI)
تعداد لایه‌های کانولوشن	۱۳ لایه کانولوشن	۲ لایه کانولوشن
ابعاد فیلترها	3x3	5x5
پولینگ	Max Pooling (2x2)	Average Pooling (2x2)
لایه‌های Fully Connected	۳ لایه (۴۰۹۶, ۴۰۹۶ و ۶ نورون خروجی)	۲ لایه (۵۱۲, ۱۲۸ و ۶ نورون خروجی)
عملگر فعال‌سازی	ReLU	ReLU
Dropout	بله (۰/۵) در لایه‌های Fully Connected	در صورت نیاز (برای Fully Connected)
وزن‌های اولیه	از ImageNet (Transfer Learning)	آموزش از صفر
تعداد پارامترها	حدود 138 میلیون	حدود 60 هزار
روش یادگیری	Fully Learning Transfer با تغییر در Connected	یادگیری از صفر
داده‌های ورودی	تصاویر رنگی حاصل از تبدیل سیگنال‌های PRI	مشابه

<sup>2</sup> Transfer learning

<sup>1</sup> Training from Scratch

Sliding PRI:  $F(n)$

$$= PRI_0 + \delta \quad (5)$$

$$* (n \bmod M), PRI_0 > 0, \delta \in R.$$

که  $PRI_0 > 0$  مقدار اولیه دوره لغزش و  $\delta \in R$  نشان نده نرخ تغییر PRI در طول دوره لغزش است و  $M$  تعداد پالس ها در هر پنجره لغزش است.

$$Stagger PRI: F(n) = y_i, y_i > 0, i = n \bmod M, \quad (6)$$

PRI تکراری از یک دنباله با مقادیر ثابت  $M$  است.  $Dwell and switch PRI$  شامل چندین دنباله از اعداد تعریف شده توسط تابع  $F(x)$  به صورت زیر است. در هر دنباله، PRI بر روی یک مقد (dwell) با مقدار مشابه  $y_i > 0$  و تعداد  $x_i - x_{i-1}$  باقی می ماند قبل از اینکه به مقدار بعدی  $y_{i+1}$  سوئیچ کند.

$$F(x) = \begin{cases} y_1, 0 \leq (n \bmod x_M) \leq x_1, \\ y_2, x_1 \leq (n \bmod x_M) \leq x_2, \\ \vdots \\ y_M, x_{M-1} \leq (n \bmod x_M) \leq x_M. \end{cases} \quad (7)$$

در جدول (5) مجموعه داده های شبیه سازی شده استفاده شده در این تحقیق آورده شده است. شایان ذکر هست در کلیه داده ها درصد نقاط پرت بزرگ ۱-۱۰٪ در نظر گرفته شده است.

#### ۴-۲- آزمایش و نتایج

برای آموزش DCNN های پیشنهادی از سخت افزار Intel-corei7-13700K, 32GB RAM, Nvidia RTX 3080 شبکه استفاده شده است. مدل های مورد نظر با استفاده از کتابخانه های تنسورفلو<sup>۱</sup> و کراس<sup>۲</sup> در زبان برنامه نویسی پایتون پیاده سازی شده است. تعداد دوره<sup>۳</sup> برای تمامی شبکه ها برابر ۲۵ و اندازه ی دسته<sup>۴</sup> برای تمامی شبکه ها برابر ۱۶ انتخاب گردیده و میزان تقسیم مجموعه داده ۷۰٪ آموزش<sup>۵</sup>، ۱۵٪ اعتبارسنجی<sup>۶</sup> و ۱۵٪ ارزیابی<sup>۷</sup> در نظر گرفته شده است. وزن های VGG 16 از پیش آموزش دیده شده برای یادگیری انتقالی در روش ارائه شده از کتابخانه ی تنسورفلو مقداردهی شده اند. برای نرخ آموزش شبکه ها ابتدا مقدار ۰.۰۰۱ در نظر گرفته می شود و سپس چنانچه مقدار دقت داده های ارزیابی برای ۵ دوره کاهش پیدا نکرد، مقدار نرخ آموزش به نصف کاهش پیدا می کند و کمترین مقدار نرخ آموزش برابر ۰.۰۰۰۰۱ است.

رادهای واقعی PRI اغلب در محدوده ۲ میکروثانیه تا ۵۰ میلی ثانیه قرار دارند این ممکن است در ابتدا چندان جدی به نظر نرسد، زیرا داده های ورودی در مرحله پیش پردازش عادی می شوند [۵، ۲۷]. با این حال، هنگامی که مشکلات پالس های ازدست رفته و ناخواسته رخ می دهد، این موضوع به وضوح خودنمایی می کند. به طور کلی، هرچه مقادیر PRI کمتر باشد، اثرات پالس های ناخواسته جدی تر است و هر چه مقادیر PRI بیشتر باشد، اثرات پالس های ازدست رفته شدیدتر است [۵، ۲۷]. بر اساس مباحث فوق الذکر، اثرات پالس های ازدست رفته و پالس های ناخواسته باید برای انواع مدولاسیون ها به بردارهای PRI اضافه شود. درصد معقول برای هر دو اثر مخرب ۵-۳۰٪ است [۵، ۲۷]. با این حال، باید توجه داشت که مجموع دو درصد باید کمتر از ۵۰٪ باشد، زیرا حداقل نیمی از اعضاء در یک بردار PRI باید به سناریوی واقعی تعلق داشته باشند [۵، ۲۷]. جدول (۴) مشخصات کلی داده های واقع بینانه را نشان می دهد.

جدول ۴- مشخصات کلی سناریوهای واقع بینانه [۵].

مشخصات	مقدار
محدوده PRI	2(μs)-50 (ms)
لرزش ناخواسته	0-1 (%)
نقاط پرت بزرگ	1-10 (%)
تعداد پالس ها	100-250

اکنون، برای تولید داده های شبه واقعی، با توجه به معادله (۱) مشخصات هر نوع مدولاسیون باید در نظر گرفته شود. مدولاسیون PRI شش الگوهای مختلفی دارند و تعریف های زیر مستقیماً از پایان نامه های [۲۸، ۲۹] گرفته شده است، محققینی که پایان نامه خود را در مورد طبقه بندی PRI بر روی دنباله های PRI نوشته اند [۲۸، ۲۹]:

$$Sin PRI: F(n) = PRI_0 + A \sin(w * x_n + \varphi), PRI_0 > 0 \quad (2)$$

$A$  دامنه،  $w$  فرکانس و  $\varphi$  فاز و  $n$  مقداری است که با توجه به  $n$  دقت نمونه برداری را تعیین می کند.

$$Fixed PRI: F(n) = k, k > 0 \quad (3)$$

در اینجا PRI اغلب ثابت است.

$$Jitter PRI: The PRI is random with a mean value, \mu, and some spread, \sigma \quad (4)$$

PRI یک مقدار تصادفی با میانگین  $\mu$  و محدوده گسترش  $\sigma$  است.

<sup>4</sup> Batch size

<sup>5</sup> Train

<sup>6</sup> Validation


<sup>7</sup> Test

<sup>1</sup> Tensorflow

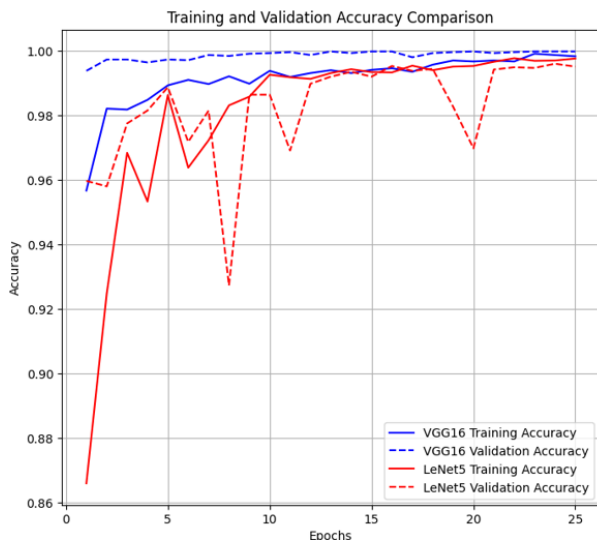
<sup>2</sup> Keras

<sup>3</sup> Epoch

نتایج شبکه‌های مختلف بر روی مجموعه داده با پالس‌های ازدست‌رفته و پالس‌های ناخواسته ۲۵-۳۰٪ در شکل‌های (۱۵ و ۱۶) و جدول (۱۲) نشان داده شده است.



(الف)



(ب)

شکل ۴- نمودارهای دقت آموزش و اعتبارسنجی و تلفات آموزش و اعتبارسنجی شبکه‌ها بر روی مجموعه داده بدون اعمال عوامل مخرب

در ادامه جدول نتایج و نمودار نتایج شبکه‌های مختلف به ترتیب در جداول و شکل‌های جداگانه با توجه به درصد عوامل مخرب نشان داده شده است. شایان ذکر هست برای تمامی حالات نقاط پرت بزرگ در محدوده ۱-۱۰٪ در نظر گرفته شده است. برای ارزیابی عملکرد شبکه‌های پیشنهادی از پنج معیار رایج [۴۴, ۴] به شرح زیر استفاده می‌کنیم.

$$Recall = \frac{TP}{TP+FN} \quad (۸)$$

$$Accuracy = \frac{TP+TN}{TP+FP+FN+TN} \quad (۹)$$

$$F_1 - score = \frac{TP}{TP+\frac{1}{2}(FP+FN)} \quad (۱۰)$$


$$Precision = \frac{TP}{TP+FP} \quad (۱۱)$$

$$MCC = \frac{TP \times TN - TP \times FN}{\sqrt{(FP+TP) \times (FP+TN) \times (FN+TP) \times (FN+TN)}} \quad (۱۲)$$

در ادامه نتایج عملکردی شبکه‌ها بر روی مجموعه داده بدون عوامل مخرب و مجموعه داده با درصد‌های مختلف عوامل مخرب آورده شده است. نتایج شبکه‌ها بر روی مجموعه داده بدون عوامل مخرب در شکل‌های (۴ و ۵) و جدول (۶) نشان داده شده است. نتایج شبکه‌های مختلف بر روی مجموعه داده با پالس‌های ازدست‌رفته و پالس‌های ناخواسته ۰-۵٪ در شکل‌های (۶ و ۷) و جدول (۷) نشان داده شده است. نتایج شبکه‌های مختلف بر روی مجموعه داده با پالس‌های ازدست‌رفته و پالس‌های ناخواسته ۵-۱۰٪ در شکل‌های (۸ و ۹) و جدول (۸) نشان داده شده است. نتایج شبکه‌های مختلف بر روی مجموعه داده با پالس‌های ازدست‌رفته و پالس‌های ناخواسته ۱۰-۱۵٪ در شکل‌های (۹ و ۱۰) و جدول (۹) نشان داده شده است. نتایج شبکه‌های مختلف بر روی مجموعه داده با پالس‌های ازدست‌رفته و پالس‌های ناخواسته ۱۵-۲۰٪ در شکل‌های (۱۱ و ۱۲) و جدول (۱۰) نشان داده شده است. نتایج شبکه‌های مختلف بر روی مجموعه داده با پالس‌های ازدست‌رفته و پالس‌های ناخواسته ۲۰-۲۵٪ در شکل‌های (۱۳ و ۱۴) و جدول (۱۱) نشان داده شده است. در جدول (۱۳) و شکل (۱۷) نتایج شبکه‌های مختلف به صورت هم‌زمان برای درصد‌های عوامل مخرب به منظور مقایسه آورده شده است

جدول ۵- شرح مجموعه داده‌های شبیه‌سازی شده.

مجموعه داده	نقاط پرت بزرگ	پالس‌های ازدست‌رفته	پالس‌های ناخواسته	تعداد تصاویر حاصل
مجموعه داده اول	0%	0%	0%	۳۰۰۰۰ تصویر (هر نوع مدولاسیون ۵۰۰۰ تصویر)
مجموعه داده دوم	1-10%	0-5%	0-5%	۳۰۰۰۰ تصویر (هر نوع مدولاسیون ۵۰۰۰ تصویر)
مجموعه داده سوم	1-10%	5-10%	5-10%	۳۰۰۰۰ تصویر (هر نوع مدولاسیون ۵۰۰۰ تصویر)
مجموعه داده چهارم	1-10%	10-15%	10-15%	۳۰۰۰۰ تصویر (هر نوع مدولاسیون ۵۰۰۰ تصویر)
مجموعه داده پنجم	1-10%	15-20%	15-20%	۳۰۰۰۰ تصویر (هر نوع مدولاسیون ۵۰۰۰ تصویر)
مجموعه داده ششم	1-10%	20-25%	20-25%	۳۰۰۰۰ تصویر (هر نوع مدولاسیون ۵۰۰۰ تصویر)
مجموعه داده هفتم	1-10%	25-30%	25-30%	۳۰۰۰۰ تصویر (هر نوع مدولاسیون ۵۰۰۰ تصویر)



(ب)

شکل ۶- نمودارهای دقت آموزش و اعتبارسنجی و تلفات آموزش و اعتبارسنجی شبکه‌ها بر روی مجموعه داده با اعمال پالس‌های ازدست‌رفته و پالس‌های ناخواسته +۰-۵٪ و نقاط پرت بزرگ ۱-۱۰٪.

VGG 16

Constant	749	1	0	0	0	0
Dwell & switch	0	750	0	0	0	0
Jittered	0	0	749	0	0	1
Periodic	0	0	0	750	0	0
Sliding	0	0	0	0	750	0
Stagger	0	0	0	0	0	750
True Labels	Constant	Dwell & switch	Jittered	Periodic	Sliding	Stagger

(الف)

LeNet5

Constant	750	0	0	0	0	0
Dwell & switch	0	750	0	0	0	0
Jittered	0	0	741	0	0	9
Periodic	0	0	0	750	0	0
Sliding	0	0	0	0	750	0
Stagger	0	0	3	1	0	746
True Labels	Constant	Dwell & switch	Jittered	Periodic	Sliding	Stagger

(ب)

شکل ۵- ماتریس اغتشاش شبکه‌ها بر روی مجموعه داده بدون اعمال عوامل مخرب

VGG 16

Constant	748	0	0	0	0	2
Dwell & switch	0	743	0	0	6	1
Jittered	0	0	736	0	0	14
Periodic	0	0	0	750	0	0
Sliding	1	1	0	0	748	0
Stagger	0	0	26	0	0	724
True Labels	Constant	Dwell & switch	Jittered	Periodic	Sliding	Stagger


(الف)

LeNet5


Constant	747	0	0	0	3	0
Dwell & switch	2	735	0	0	12	1
Jittered	0	0	734	0	0	16
Periodic	0	0	0	749	0	1
Sliding	1	2	0	0	743	4
Stagger	1	2	39	2	1	705
True Labels	Constant	Dwell & switch	Jittered	Periodic	Sliding	Stagger

(ب)

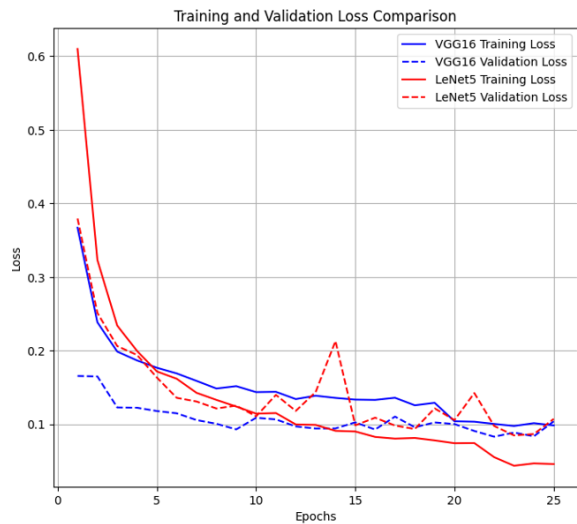
شکل ۷. ماتریس اغتشاش شبکه‌ها بر روی مجموعه داده با اعمال پالس‌های ازدست‌رفته و پالس‌های ناخواسته +۰-۵٪ و نقاط پرت بزرگ ۱-۱۰٪.




(الف)




(الف)



(الف)



(ب)



(ب)

شکل ۹. نمودارهای دقت آموزش و اعتبارسنجی و تلفات آموزش و اعتبارسنجی شبکه‌ها بر روی مجموعه داده با اعمال پالس‌های از دست‌رفته و پالس‌های ناخواسته ۱۰-۱۵٪ و نقاط پرت بزرگ ۱-۱۰٪.

شکل ۸- نمودارهای دقت آموزش و اعتبارسنجی و تلفات آموزش و اعتبارسنجی شبکه‌ها بر روی مجموعه داده با اعمال پالس‌های از دست‌رفته و پالس‌های ناخواسته ۵-۱۰٪ و نقاط پرت بزرگ ۱-۱۰٪.

		VGG 16					
		Constant	Dwell & switch	Jittered	Periodic	Sliding	Stagger
True Labels	Constant	750	0	0	0	0	0
	Dwell & switch	0	738	0	0	11	1
	Jittered	0	0	650	0	1	99
	Periodic	0	0	0	749	1	0
	Sliding	1	1	0	0	748	0
	Stagger	0	1	118	0	0	631
			Constant	Dwell & switch	Jittered	Periodic	Sliding
		Predicted Labels					

(الف)

		VGG 16					
		Constant	Dwell & switch	Jittered	Periodic	Sliding	Stagger
True Labels	Constant	750	0	0	0	0	0
	Dwell & switch	0	734	0	0	13	3
	Jittered	2	0	711	0	0	37
	Periodic	0	0	0	748	2	0
	Sliding	0	0	0	0	750	0
	Stagger	0	1	61	0	1	687
			Constant	Dwell & switch	Jittered	Periodic	Sliding
		Predicted Labels					

شکل ۹- ماتریس اغتشاش شبکه‌ها بر روی مجموعه داده با اعمال پالس‌های از دست‌رفته و پالس‌های ناخواسته ۵-۱۰٪ و نقاط پرت بزرگ ۱-۱۰٪.


True Labels \ Predicted Labels	Constant	Dwell & switch	Jittered	Periodic	Sliding	Stagger
Constant	750	0	0	0	0	0
Dwell & switch	0	739	0	0	9	2
Jittered	0	1	672	0	0	77
Periodic	0	0	0	750	0	0
Sliding	1	5	0	0	744	0
Stagger	0	0	241	0	0	536

(الف)

True Labels \ Predicted Labels	Constant	Dwell & switch	Jittered	Periodic	Sliding	Stagger
Constant	750	0	0	0	0	0
Dwell & switch	0	735	0	3	12	0
Jittered	0	1	696	0	2	51
Periodic	0	1	0	742	7	0
Sliding	1	6	0	12	731	0
Stagger	0	0	120	0	3	627

(ب)

شکل ۱۲- ماتریس اغتشاش شبکه‌ها بر روی مجموعه داده با اعمال پالس‌های ازدست‌رفته و پالس‌های ناخواسته ۱۵-۲۰٪ و نقاط پرت بزرگ ۱-۱۰٪.




(الف)


True Labels \ Predicted Labels	Constant	Dwell & switch	Jittered	Periodic	Sliding	Stagger
Constant	750	0	0	0	0	0
Dwell & switch	0	736	0	1	10	3
Jittered	0	0	715	0	1	34
Periodic	0	2	0	740	8	0
Sliding	0	3	0	5	742	0
Stagger	0	1	85	0	1	663

(ب)

شکل ۱۰- ماتریس اغتشاش شبکه‌ها بر روی مجموعه داده با اعمال پالس‌های ازدست‌رفته و پالس‌های ناخواسته ۱۰-۱۵٪ و نقاط پرت بزرگ ۱-۱۰٪.




(الف)




(ب)

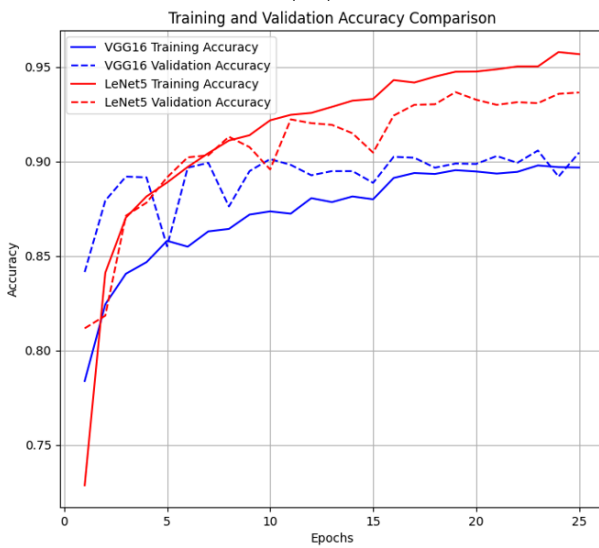
شکل ۱۱- نمودارهای دقت آموزش و اعتبارسنجی و تلفات آموزش و اعتبارسنجی شبکه‌ها بر روی مجموعه داده با اعمال پالس‌های ازدست‌رفته و پالس‌های ناخواسته ۱۵-۲۰٪ و نقاط پرت بزرگ ۱-۱۰٪.



(الف)



(ب)



(ب)

شکل ۱۵. نمودارهای دقت آموزش و اعتبارسنجی و تلفات آموزش و اعتبارسنجی شبکه‌ها بر روی مجموعه داده با اعمال پالس‌های ازدست‌رفته و پالس‌های ناخواسته ۲۰-۳۰٪ و نقاط پرت بزرگ ۱-۱۰٪.

		VGG 16					
		Constant	Dwell & switch	Jittered	Periodic	Sliding	Stagger
True Labels	Constant	750	0	0	0	0	0
	Dwell & switch	1	742	0	0	6	1
	Jittered	0	0	609	0	0	141
	Periodic	0	3	0	746	1	0
	Sliding	1	13	0	0	735	1
	Stagger	0	0	223	2	1	524
			Constant	Dwell & switch	Jittered	Periodic	Sliding

(الف)

شکل ۱۳. نمودارهای دقت آموزش و اعتبارسنجی و تلفات آموزش و اعتبارسنجی شبکه‌ها بر روی مجموعه داده با اعمال پالس‌های ازدست‌رفته و پالس‌های ناخواسته ۲۰-۲۵٪ و نقاط پرت بزرگ ۱-۱۰٪.

		VGG 16					
		Constant	Dwell & switch	Jittered	Periodic	Sliding	Stagger
True Labels	Constant	750	0	0	0	0	0
	Dwell & switch	0	734	0	2	14	0
	Jittered	0	0	632	0	0	118
	Periodic	0	3	0	745	1	1
	Sliding	2	3	0	3	741	1
	Stagger	0	0	212	0	2	536
			Constant	Dwell & switch	Jittered	Periodic	Sliding

(الف)

		LeNet5					
		Constant	Dwell & switch	Jittered	Periodic	Sliding	Stagger
True Labels	Constant	750	0	0	0	0	0
	Dwell & switch	0	739	1	2	8	0
	Jittered	0	0	644	0	1	105
	Periodic	0	2	0	741	6	1
	Sliding	0	4	0	10	735	1
	Stagger	0	1	119	2	2	626
			Constant	Dwell & switch	Jittered	Periodic	Sliding

(ب)

شکل ۱۴. ماتریس اغتشاش شبکه‌ها بر روی مجموعه داده با اعمال پالس‌های ازدست‌رفته و پالس‌های ناخواسته ۲۰-۲۵٪ و نقاط پرت بزرگ ۱-۱۰٪.

با توجه به شکل‌ها و جداول بالا و همچنین جدول (۱۳) و شکل (۱۷) می‌توان تحلیل زیر را برای عملکرد شبکه‌ها عنوان نمود:

### مقایسه عملکرد اولیه:

VGG 16 با تعداد پارامترهای بیشتری نسبت به LeNet 5 شروع به کار کرده و در شرایط بدون عوامل مخرب عملکرد بسیار بهتری از خود نشان داده است؛ و در تمامی معیارهای سنجش بالاتر از LeNet 5 است. با افزایش درصد عوامل مخرب، عملکرد VGG 16 کاهش می‌یابد، به طوری که در نهایت LeNet 5 در شرایطی که درصد عوامل مخرب به بالاتر ۵-۱۰٪ می‌رسد، عملکرد بهتری نسبت به VGG 16 دارد.

### تحلیل تغییرات در مواجهه با عوامل مخرب:

با افزایش درصد پالس‌های از دست‌رفته و پالس‌های ناخواسته، عملکرد هر دو مدل کاهش می‌یابد. این کاهش در VGG 16 شدیدتر است، در حالی که LeNet 5 به تدریج و با افت کمتری دچار کاهش عملکرد می‌شود. VGG 16 به دلیل داشتن تعداد پارامترهای بیشتر و پیچیدگی بالاتر، به نظر می‌رسد که به طور ذاتی در برابر داده‌های نامناسب و نویزی حساس‌تر است. این باعث می‌شود که در شرایط نامطلوب، عملکرد این مدل به طور قابل توجهی کاهش یابد. در این تحقیق، درصد نقاط پرت بزرگ در تمامی شرایط ثابت بوده و تأثیر مستقیمی بر روی تفاوت عملکرد دو مدل مشاهده نمی‌شود. این می‌تواند نشان‌دهنده این باشد که هر دو مدل توانایی مقابله با این نوع از داده‌های غیر نرمال را دارند، اما وقتی با سایر عوامل مخرب ترکیب می‌شود، VGG 16 به نسبت LeNet 5 تحت تأثیر بیشتری قرار می‌گیرد.

### زمان آموزش:

زمان آموزش در هر دو مدل تقریباً نزدیک به یکدیگر است، اما LeNet 5 با تعداد پارامترهای کمتر و ساده‌تر بودن معماری، در برخی موارد کمی سریع‌تر عمل می‌کند.


### جمع‌بندی:

VGG 16 در شرایط بدون عوامل مخرب و یا با درصد کم عوامل مخرب عملکرد بهتری دارد، اما با افزایش درصد عوامل مخرب، LeNet 5 بهتر عمل می‌کند. این می‌تواند به دلیل ساده‌تر بودن معماری LeNet 5 و مقاومت آن در برابر نویز و داده‌های نرمال‌سازی نشده باشد. LeNet 5 با تعداد پارامترهای کمتر و ساختار ساده‌تر، عملکرد قابل قبولی را در شرایط با نویز بالا ارائه می‌دهد. این نشان می‌دهد که برای محیط‌های با نویز بالا، LeNet 5 گزینه مناسب‌تری می‌تواند باشد. از طرف دیگر، اگر محیطی با داده‌های تمیز و بدون نویز در دسترس باشد، VGG 16 به دلیل دقت بالا و عملکرد بهتر در شرایط بدون نویز، انتخاب بهتری خواهد بود.

True Labels \ Predicted Labels	Constant	Dwell & switch	Jittered	Periodic	Sliding	Stagger
Constant	750	0	0	0	0	0
Dwell & switch	2	741	0	0	7	0
Jittered	0	0	631	0	0	119
Periodic	0	6	0	737	6	1
Sliding	2	5	0	2	741	0
Stagger	0	3	162	4	2	579

(ب)

شکل ۱۶. ماتریس اغتشاش شبکه‌ها بر روی مجموعه داده با اعمال پالس‌های از دست‌رفته و پالس‌های ناخواسته ۲۵-۳۰٪ و نقاط پرت بزرگ ۱-۱۰٪.



شکل ۱۷. نتایج شبکه‌های مختلف با درصدهای مختلف عوامل مخرب (نقاط پرت بزرگ در اینجا ۱-۱۰٪ در نظر گرفته شده است).

جدول ۶- نتایج شبکه‌ها بر روی مجموعه داده بدون اعمال عوامل مخرب

Model	Destructive factors			Training Time (s)	Evaluation measurements				
	Missing pulses (%)	Spurious pulses (%)	Large outliers (%)		ACC (%)	MCC (%)	F1 score (%)	Recall (%)	Precision (%)
LeNet 5	0	0	0	3694.1368	99.7555	99.6535	99.7110	99.7111	99.37119
VGG 16				3681.2177	99.9777	99.9467	99.9555	99.9555	99.9556

جدول ۷- نتایج شبکه‌های مختلف بر روی مجموعه داده با پالس‌های ازدست‌رفته و پالس‌های ناخواسته ۰-۵٪ و نقاط پرت بزرگ ۱-۱۰٪

Model	Destructive factors			Training Time (s)	Evaluation measurements				
	Missing pulses (%)	Spurious pulses (%)	Large outliers (%)		ACC (%)	MCC (%)	F1 score (%)	Recall (%)	Precision (%)
LeNet 5	0-5	0-5	1-10	3607.3665	97.6222	97.6836	98.0643	98.0666	98.0801
VGG 16				3625.6141	98.7777	98.6408	98.8671	98.8666	98.8716

جدول ۸- نتایج شبکه‌های مختلف بر روی مجموعه داده با پالس‌های ازدست‌رفته و پالس‌های ناخواسته ۰-۵٪ و نقاط پرت بزرگ ۱-۱۰٪

Model	Destructive factors			Training Time (s)	Evaluation measurements				
	Missing pulses (%)	Spurious pulses (%)	Large outliers (%)		ACC (%)	MCC (%)	F1 score (%)	Recall (%)	Precision (%)
LeNet 5	5-10	5-10	1-10	3628.6259	0.977111	97.2591	97.7077	97.7111	97.7331
VGG 16				3624.0723	0.973777	96.8043	97.3315	97.3333	97.3509

جدول ۹- نتایج شبکه‌های مختلف بر روی مجموعه داده با پالس‌های ازدست‌رفته و پالس‌های ناخواسته ۱۰-۱۵٪ و نقاط پرت بزرگ ۱-۱۰٪

Model	Destructive factors			Training Time (s)	Evaluation measurements				
	Missing pulses (%)	Spurious pulses (%)	Large outliers (%)		ACC (%)	MCC (%)	F1 score (%)	Recall (%)	Precision (%)
LeNet 5	10-15	10-15	1-10	3668.0896	0.966444	95.9082	96.5741	96.5777	96.6419
VGG 16				3663.4022	0.945555	93.7625	94.7976	94.8000	94.8073

جدول ۱۰- نتایج شبکه‌های مختلف بر روی مجموعه داده با پالس‌های ازدست‌رفته و پالس‌های ناخواسته ۱۵-۲۰٪ و نقاط پرت بزرگ ۱-۱۰٪

Model	Destructive factors			Training Time (s)	Evaluation measurements				
	Missing pulses (%)	Spurious pulses (%)	Large outliers (%)		ACC (%)	MCC (%)	F1 score (%)	Recall (%)	Precision (%)
LeNet 5	15-20	15-20	1-10	3680.3797	95.0444	94.1869	95.1189	95.1333	95.2336
VGG 16				3677.4842	93.1555	91.8601	93.0807	93.1333	93.4778

جدول ۱۱- نتایج شبکه‌های مختلف بر روی مجموعه داده با پالس‌های ازدست‌رفته و پالس‌های ناخواسته ۲۰-۲۵٪ و نقاط پرت بزرگ ۱-۱۰٪

Model	Destructive factors			Training Time (s)	Evaluation measurements				
	Missing pulses (%)	Spurious pulses (%)	Large outliers (%)		ACC (%)	MCC (%)	F1 score (%)	Recall (%)	Precision (%)
LeNet 5	20-25	20-25	1-10	3697.7588	94.2888	92.9347	94.1056	94.1111	94.1071
VGG 16				3689.2414	91.7999	90.3944	91.9235	91.9555	92.1004

جدول ۱۲- نتایج شبکه‌های مختلف بر روی مجموعه داده با پالس‌های ازدست‌رفته و پالس‌های ناخواسته ۲۵-۳۰٪ و نقاط پرت بزرگ ۱-۱۰٪

Model	Destructive factors			Training Time (s)	Evaluation measurements				
	Missing pulses (%)	Spurious pulses (%)	Large outliers (%)		ACC (%)	MCC (%)	F1 score (%)	Recall (%)	Precision (%)
LeNet 5	25-30	25-30	1-10	3712.9317	92.9333	91.4524	92.8409	92.8666	92.8712
VGG 16				3712.0945	91.3111	89.5297	91.2141	91.2444	91.3394

تحلیل نتایج ارائه شده نشان می‌دهد که در محیط پیچیده جنگ الکترونیک، عوامل مخربی مانند پالس‌های ازدست‌رفته، پالس‌های ناخواسته و نقاط پرت بزرگ بر دقت تشخیص مدولاسیون PRI سیگنال‌های راداری تأثیرگذار هستند. این تحلیل با توجه به مقادیر دقت آموزش و آزمون مدل‌های مختلف نشان می‌دهد که با افزایش درصد عوامل مخرب، دقت تشخیص مدولاسیون PRI کاهش می‌یابد. تحلیل عملکرد مدل‌های LeNet 5 و VGG 16 در سطوح مختلف عوامل مخرب بینش‌های مهمی را درباره استحکام و دقت این معماری‌ها در تشخیص مدولاسیون PRI آشکار می‌کند. همان‌طور که انتظار می‌رفت، هر دو مدل با افزایش درصد عوامل مخرب، کاهش عملکرد را نشان می‌دهند. با این حال، VGG 16 دقت و مقاومت بالاتری نسبت به LeNet 5 زمانی که عوامل مخرب در سطح کم هستند از خود نشان می‌دهد، اما با افزایش میزان عوامل مخرب، LeNet 5 عملکرد بهتری دارد. این موضوع نشان می‌دهد که LeNet 5 برای مقابله با محیط‌های نویزی مناسب‌تر است و آن را به انتخابی قابل اطمینان‌تر برای سامانه‌های ESM و ELINT تبدیل می‌کند که در آن‌ها تداخل سیگنال رایج است. از این رو، انتخاب مدل مناسب برای کاربردهای ویژه مانند سامانه ESM، سامانه ELINT و سامانه RWR باید با توجه به عوامل مختلفی از جمله دقت، زمان آموزش و مقدار عوامل مخرب انجام شود. در واقع، این یافته‌ها اهمیت انتخاب معماری مناسب را بر اساس نیازهای خاص کاربرد مورد نظر، به ویژه در سامانه‌های جنگ الکترونیک که توانایی شناسایی دقیق تهدیدات راداری در حضور تداخل امری حیاتی است، برجسته می‌کند.

مقاله حاضر به بررسی اثرات عوامل مخرب - پالس‌های ازدست‌رفته، پالس‌های ناخواسته و نقاط پرت بزرگ (ناشی از روبش آنتن) - بر تشخیص مدولاسیون PRI در سیگنال‌های راداری با استفاده از دو شبکه عصبی کانولوشنی عمیق VGG 16 و LeNet 5 می‌پردازد. مقاله از شبیه‌سازی‌های مبتنی بر محیط واقعی برای تولید داده‌ها استفاده می‌کند و عوامل مخرب را با درصد‌های مختلف مدنظر قرار می‌دهد. تعداد تصاویر حاصل با اعمال مجموع عوامل مخرب بر روی آن برای هر نوع مدولاسیون و هر محدوده در نظر گرفته شده عوامل مخرب ۵۰۰۰ تصویر هست. سپس، مدل VGG 16 با استفاده از روش یادگیری انتقالی و مدل LeNet 5 با استفاده از روش آموزش داده می‌شوند. نتایج شبیه‌سازی نشان می‌دهد با افزایش درصد عوامل مخرب، دقت آموزش و آزمون مدل‌ها به مقدار قابل توجهی کاهش می‌یابد. همچنین، تأثیرات نوع مدل بر عملکرد مدل‌ها بررسی شده و نتایج نشان داده‌اند که LeNet 5 نسبت به مخرب‌ها مقاوم‌تر است و دقت بیشتری را حفظ می‌کند. در نهایت، این تجزیه و تحلیل نشان می‌دهد که به منظور خودکار و خودکافی‌سازی سامانه‌های شناسایی و پشتیبانی الکترونیکی در محیط جنگ الکترونیک مدرن می‌بایست به عوامل مخرب توجه ویژه‌ای داشت و در طراحی و پیاده‌سازی سامانه‌ها آن‌ها را به‌طور خاص در نظر گرفت. در ادامه، به منظور ادامه کار پیشنهاد می‌گردد ساختار DCNN با مطلوب‌ترین عملکرد با توجه به مجموع داده‌ها با استفاده از الگوریتم‌های بهینه‌ساز طراحی و پیاده‌سازی گردد.

جدول ۱۳- نتایج شبکه‌های مختلف با درصد‌های مختلف عوامل مخرب

Model	Destructive factors			Training Time (s)	Evaluation measurements				
	Missing pulses (%)	Spurious pulses (%)	Large outliers (%)		ACC (%)	MCC (%)	F1 score (%)	Recall (%)	Precision (%)
LeNet 5	0	0	1-10	3694.1368	99.7555	99.6535	99.7110	99.7111	99.37119
	0-5	0-5	1-10	3607.3665	97.6222	97.6836	98.0643	98.0666	98.0801
	5-10	5-10	1-10	3628.6259	97.7111	97.2591	97.7077	97.7111	97.7331
	10-15	10-15	1-10	3668.0896	96.6444	95.9082	96.5741	96.5777	96.6419
	15-20	15-20	1-10	3680.3797	95.0444	94.1869	95.1189	95.1333	95.2336
	20-25	20-25	1-10	3697.7588	94.2888	92.9347	94.1056	94.1111	94.1071
	25-30	25-30	1-10	3712.9317	92.9333	91.4524	92.8409	92.8666	92.8712
VGG 16	0	0	1-10	3681.2177	99.9777	99.9467	99.9555	99.9555	99.9556
	0-5	0-5	1-10	3625.6141	98.7777	98.6408	98.8671	98.8666	98.8716
	5-10	5-10	1-10	3624.0723	97.3777	96.8043	97.3315	97.3333	97.3509
	10-15	10-15	1-10	3663.4022	94.5555	93.7625	94.7976	94.8000	94.8073
	15-20	15-20	1-10	3677.4842	93.1555	91.8601	93.0807	93.1333	93.4778
	20-25	20-25	1-10	3689.2414	91.7999	90.3944	91.9235	91.9555	92.1004
	25-30	25-30	1-10	3712.0945	91.3111	89.5297	91.2141	91.2444	91.3394

- [19] Hekrdla, M. and A. Heřmánek. Deep Convolutional Neural Network Classifier of Pulse Repetition Interval Modulations. in 2019 International Radar Conference (RADAR). 2019. IEEE.
- [20] Zheng, W., X. Liu, and L. Yin, Research on image classification method based on improved multi-scale relational network. *PeerJ Computer Science*, 2021. 7: p. e613.
- [21] Zhou, G., et al., Selection of optimal building facade texture images from UAV-based multiple oblique image flows. *IEEE Transactions on Geoscience and Remote Sensing*, 2020. 59(2): p. 1534-1552.
- [22] Zhou, W., H. Wang, and Z. Wan, Ore image classification based on improved CNN. *Computers and Electrical Engineering*, 2022. 99: p. 107819.
- [23] Liu, F., G. Zhang, and J. Lu, Multisource heterogeneous unsupervised domain adaptation via fuzzy relation neural networks. *IEEE Transactions on Fuzzy Systems*, 2020. 29(11): p. 3308-3322.
- [24] Zhang, K., et al., Training effective deep reinforcement learning agents for real-time life-cycle production optimization. *Journal of Petroleum Science and Engineering*, 2022. 208: p. 109766.
- [25] Li, B., et al., A distributionally robust optimization based method for stochastic model predictive control. *IEEE Transactions on Automatic Control*, 2021. 67(11): p. 5762-5776.
- [26] Li, X., et al., Toward convolutional neural networks on pulse repetition interval modulation recognition. *IEEE Communications Letters*, 2018. 22(11): p. 2286-2289.
- [27] Dadgarnia, A. and M.T. Sadeghi, Automatic recognition of pulse repetition interval modulation using temporal convolutional network. *IET Signal Processing*, 2021. 15(9): p. 633-648.
- [28] Barrios, K., Automation of Pulse Repetition Interval Modulation Classification. 2021.
- [29] Norgren, E., Pulse repetition interval modulation classification using machine learning. 2019.
- [30] LeCun, Y., LeNet-5, convolutional neural networks. URL: <http://yann.lecun.com/exdb/lenet>, 2015. 20(5): p. 14.
- [31] Krizhevsky, A., I. Sutskever, and G.E. Hinton, Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 2012. 25.
- [32] Zeiler, M.D. and R. Fergus. Visualizing and understanding convolutional networks. in *Computer Vision—ECCV 2014: 13th European Conference, Zurich, Switzerland, September 6-12, 2014, Proceedings, Part I* 13. 2014. Springer.
- [33] Szegedy, C., et al. Going deeper with convolutions. in *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2015.
- [34] Simonyan, K. and A. Zisserman, Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*, 2014.
- [35] Szegedy, C., et al. Inception-v4, inception-resnet and the impact of residual connections on learning. in *Proceedings of the AAAI conference on artificial intelligence*. 2017.
- [36] Jiang, Z.-P., et al., An improved VGG16 model for pneumonia image classification. *Applied Sciences*, 2021. 11(23): p. 11185.
- [37] Tammina, S., Transfer learning using vgg-16 with deep convolutional neural network for classifying images. *International Journal of Scientific and Research Publications (IJSRP)*, 2019. 9(10): p. 143-150.
- [38] Zhang, J., et al., A novel deep LeNet-5 convolutional neural network model for image recognition. *Computer Science and Information Systems*, 2022. 19(3): p. 1463-1480.
- [1] Wiley, R., *ELINT: The interception and analysis of radar signals*. 2006: Artech.
- [2] Zhuang, Y., Design of deep learning based pulse repetition interval modulation classification and recognition. 2023.
- [3] Qu, W., G. Yao, and L. Meng. Research on Radar PRI Modulation Pattern Recognition Based on Recurrent Neural Network. in 2023 4th International Conference on Computer Vision, Image and Deep Learning (CVIDL). 2023. IEEE.
- [4] Azhdari, S.M.H., et al., Pulse repetition interval modulation recognition using deep CNN evolved by extreme learning machines and IP-based BBO algorithm. *Engineering Applications of Artificial Intelligence*, 2023. 123: p. 106415.
- [5] Khodabandeh, M., A. Mahmoodzadeh, and H. Agahi, Investigating the effects of destructive factors on pulse repetition interval modulation type recognition using deep convolutional neural networks based on transfer learning. *IET Radar, Sonar & Navigation*, 2024.
- [6] Nguyen, H.P., H.Q. Nguyen, and D.T. Ngo. Deep Learning for Pulse Repetition Interval Classification. in *ICPRAM*. 2019.
- [7] Noone, G.P. A neural approach to automatic pulse repetition interval modulation recognition. in 1999 Information, Decision and Control. Data and Information Fusion Symposium, Signal Processing and Communications Symposium and Decision and Control Symposium. *Proceedings (Cat. No. 99EX251)*. 1999. IEEE.
- [8] Liu, Y. and Q. Zhang. An improved algorithm for PRI modulation recognition. in 2017 IEEE International Conference on Signal Processing, Communications and Computing (ICSPCC). 2017. IEEE.
- [9] LeCun, Y., Y. Bengio, and G. Hinton, Deep learning. *nature*, 2015. 521(7553): p. 436-444.
- [10] Goodfellow, I., Y. Bengio, and A. Courville, *Deep learning*. 2016: MIT press.
- [11] Guo, T., et al., Anti-interrupted sampling repeater jamming method for random pulse repetition interval and intra-pulse frequency agile radar. *IET Radar, Sonar & Navigation*, 2023. 17(12): p. 1796-1811.
- [12] Chunjie, Z., L. Yuchen, and S. Weijian, PRI modulation recognition and sequence search under small sample prerequisite. *Journal of Systems Engineering and Electronics*, 2023.
- [13] Wu, H., et al., Towards Radar Emitter Recognition in Changing Environments with Domain Generalization. *arXiv preprint arXiv:2302.09359*, 2023.
- [14] Liang, Y.-S. and M.-Y. Ku. Generation of Modern Pulse Radar Signals for Electronic Warfare Applications. in 2023 IEEE 6th International Conference on Knowledge Innovation and Invention (ICKII). 2023. IEEE.
- [15] Chen, X., et al., 3d object proposals for accurate object class detection. *Advances in neural information processing systems*, 2015. 28.
- [16] Nguyen, P.H. and H.Q. Nguyen. Classification of pulse repetition interval modulations using neural networks. in 2018 IEEE Symposium Series on Computational Intelligence (SSCI). 2018. IEEE.
- [17] Han, J.-W. and C.H. Park, A unified method for deinterleaving and PRI modulation recognition of radar pulses based on deep neural networks. *IEEE Access*, 2021. 9: p. 89360-89375.
- [18] Li, X., Z. Liu, and Z. Huang, Attention-based radar PRI modulation recognition with recurrent neural networks. *IEEE Access*, 2020. 8: p. 57426-57436.

- [42] Sridharan, S., et al., Improved pulse repetition interval (PRI) deinterleaving for electronic support measure (ESM) receiver. *Int. Journal of Advanced Computing and Electronics Technology (IJACET)*, 2015. 2(3): p. 37-43.
- [43] Bagheri, M. and M.H. Sedaaghi, A new approach to pulse deinterleaving based on adaptive thresholding. *Turkish Journal of Electrical Engineering and Computer Sciences*, 2017. 25(5): p. 3827-3838.
- [44] Chicco, D. and G. Jurman, The advantages of the Matthews correlation coefficient (MCC) over F1 score and accuracy in binary classification evaluation. *BMC genomics*, 2020. 21: p. 1-13.
- [39] Zhou, L. and W. Yu, Improved Convolutional Neural Image Recognition Algorithm based on LeNet-5. *Journal of Computer Networks and Communications*, 2022. 2022(1): p. 1636203.
- [40] Ahmadi, M. and K. Mohamedpour, PRI modulation type recognition using level clustering and autocorrelation. *American Journal of Signal Processing*, 2012. 2(5): p. 83-91.
- [41] Kumar, N.U., V. Dhananjayulu, and V.A. Kumar, Deinterleaving of radar signals and its parameter estimation in EW environment. *International Journal of Emerging Technology and Advanced Engineering*, 2014. 4(9): p. 490-494.