

عنوان تشخیص و طبقه‌بندی مدولاسیون زمان تکرار پالس مبتنی بر شبکه‌های عصبی کانولوشنی عمیق بهبودیافته با ماشین یادگیری افراطی

تاریخ دریافت:

۱۰ مردادماه ۱۴۰۲

تاریخ پذیرش:

۵ مهرماه ۱۴۰۲

سید مجید حسنی اژدری^{۱*}، محمد خویشه^۱

۱. گروه مهندسی برق دانشگاه علوم دریایی امام خمینی (ره)، نوشهر، ایران

چکیده

تشخیص و طبقه‌بندی مدولاسیون PRI یک کار حیاتی در سامانه‌های ESM و ELINT برای تشخیص دقیق تهدیدات راداری است. با این حال، این عمل به دلیل پالس‌های ازدست‌رفته و پالس‌های ناخواسته و اثرات نامطلوب اسکن آنتن که منجر به دنباله نویزی مدولاسیون PRI می‌شوند در محیط واقعی چالش‌برانگیز هست. برای پرداختن به این مسئله در این تحقیق سه روش مبتنی بر شبکه عصبی عمیق کانولوشنی (LeNet5, AlexNet, GoogNet) که با استفاده از ماشین یادگیری افراطی (ELM) بهینه گردیده‌اند، پیشنهاد گردیده است. در واقع در مرحله اول، یک شبکه عصبی کانولوشنی عمیق (DCNN) به عنوان استخراج‌کننده ویژگی استفاده می‌شود. سپس، در مرحله دوم ماشین یادگیری افراطی (ELM) برای تشخیص و طبقه‌بندی بلادرنگ مدولاسیون PRI استفاده می‌شود. برای ارزیابی روش‌های پیشنهادی داده‌های متناسب با داده‌های واقعی طراحی و شبیه‌سازی گردیدند و تمامی اثرات مخرب بر دنباله PRI در نظر گرفته شده‌اند. نتایج شبیه‌سازی‌ها بروی ۶۰۰۰۰ تصویر نشان‌دهنده عملکرد بهتر شبکه AlexNet-ELM در اکثر معیارهای ارزیابی بوده و به دقت بالای ۹۳٪ دست‌یافته است.

واژه‌های کلیدی: مدولاسیون PRI، شبکه عصبی کانولوشنی عمیق، ماشین یادگیری افراطی

Title Detection and Classification of Pulse Repetition Time Modulation Based on Deep Convolutional Neural Networks Improved with Extreme Learning Machine

Abstract

PRI modulation detection and classification is a critical task in ESM and ELINT systems to accurately detect radar threats. However, this practice is challenging in a real environment due to missed pulses and unwanted pulses and undesirable antenna scanning effects that lead to noisy PRI modulation sequences. To address this issue in this research, three methods based on deep convolutional neural network (LeNet5, AlexNet, GoogNet) which have been optimized using extreme learning machine (ELM) have been proposed. In fact, in the first step, a deep convolutional neural network (DCNN) is used as a feature extractor. Then, in the second step extreme learning machine (ELM) is used for real-time detection and classification of PRI modulation. To evaluate the proposed methods, data corresponding to the real data were designed and simulated, and all the destructive effects on the PRI sequence were considered. The results of simulations on 60,000 images show the better performance of the AlexNet-ELM network in most of the evaluation criteria and have achieved a high accuracy of 93%.

Key words: PRI Modulation, Deep Convolutional Neural Network, Extreme Learning Machine

معمولاً از ۳ مرحله تشکیل شده‌اند: اول، یک روش کاهش نویز برای جبران تأثیر پالس‌های ازدست‌رفته و پالس‌های ناخواسته در دنباله PRI استفاده می‌شود. دوم، ویژگی‌های افتراقی از دنباله PRI نویز زدایی شده استخراج می‌گردد؛ و سرانجام یک درخت تصمیم برای تمایز انواع مدولاسیون PRI انجام می‌شود. نقص اصلی رویکردهای مبتنی بر درخت تصمیم، به آستانه‌های دست‌ساز بسیار نیازمند است که علاوه بر زمان بر بودن نسبت به میزان نویز و تغییر پارامترهای PRI بسیار حساس هستند. تکنیک‌های هیستوگرام چون این روش‌ها ساده هستند، جوابگوی تعداد محدودی از مدولاسیون PRI می‌باشند و عملکرد آن‌ها به شدت در حالت‌های نویزی کم می‌گردد [۶]. در مرجع [۷]، نویسندگان روشی را بر اساس سه ویژگی دنباله PRI در حوزه زمان و فرکانس ارائه داده‌اند. نتایج شبیه‌سازی نشان می‌دهد که این روش در یک درصد مشخصی از پالس‌های نویز و نسبت سیگنال به نویز (SNR) کم (3-dB) قوی است. در مرجع [۸] نیز یک روش طبقه‌بندی بر اساس خودهمبستگی پیشنهاد شده است تا چهار نوع مدولاسیون PRI را تشخیص دهد نتایج شبیه‌سازی نشان می‌دهد که الگوریتم در تشخیص چهار مدولاسیون PRI تحت شرایط ۲۵٪ پالس‌های ازدست‌رفته عملکرد خوبی دارد. ویژگی خودهمبستگی در پالس‌های نویز مقاوم است ولی در برابر از دست دادن پالس آسیب‌پذیر است. در مرجع [۹] طبقه‌بندی کننده شبکه عصبی با یک لایه پنهان منفرد پیشنهاد شده است که مجموعه‌ای از تفاوت‌های دوم زمان‌های ورود (TOA) آموزش داده شده است. در مرجع [۱۰] 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. 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 ازدست‌رفته و پالس‌های ناخواسته، با محیط سازگار شوند. اخیراً، یادگیری عمیق [۱۱، ۱۲] به‌عنوان 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، چون یادگیری عمیق می‌تواند به‌صورت 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 [۱۳]. مفهوم شبکه عصبی عمیق (DNN) یا یادگیری عمیق ابتدا در مرجع [۱۴] پیشنهاد شد و سپس سریعاً به یکی از موضوعات پرکاربرد در هوش مصنوعی در سال‌های اخیر تبدیل شد. پس از آن، الگوریتم‌های شبکه باور عمیق

امروزه به دلیل پیچیدگی روزافزون محیط‌های جنگ الکترونیک (EW)، خودکار بودن یک مسئله حیاتی در سامانه‌های شناسایی الکترونیکی (ELINT) و پشتیبانی الکترونیکی (ESM) مدرن است. برای این منظور باید جداسازی پالس‌های درهم‌آمیخته رادارهای انجام گرفته و هر سیگنال راداری بدون دخالت انسان بر اساس آن شناسایی و تجزیه و تحلیل شود. یکی از چالش برانگیزترین حوزه‌های تحلیل سیگنال راداری در سامانه‌های ESM و ELINT نحوه تشخیص مدولاسیون بازه تکرار پالس (PRI) است. به‌طور کلی، رادارها از ۶ نوع اصلی مدولاسیون PRI استفاده می‌کنند [۱]. تشخیص مدولاسیون PRI یکی از جنبه‌های اصلی تجزیه و تحلیل سیگنال راداری هستند، زیرا اطلاعات ضروری را در مورد منبع تشعشع و تهدیدات بالقوه ارائه می‌دهند [۳، ۴]. در سال‌های اخیر، محققان در توسعه الگوریتم‌ها و تکنیک‌های تشخیص مدولاسیون PRI پیشرفت چشمگیری داشته‌اند [۵]. این عمل چالش‌های مهمی را به دلیل شکل موج‌های پیچیده و تنوع در شرایط عملیاتی ایجاد می‌کند. توانایی تکنیک‌های سنتی پردازش سیگنال اغلب برای تشخیص دقیق مدولاسیون PRI ها محدود است. این محدودیت‌ها عمدتاً به دلیل مشکلات در طراحی الگوریتم‌هایی است که نمی‌توانند تغییرپذیری پارامترهای PRI مانند فرکانس تکرار پالس، عرض پالس و طرح‌های تغییرات PRI را کنترل کنند. علاوه بر این، درجه بالایی از پیچیدگی و تنوع تغییرات PRI ها چالش‌های مهمی را برای توسعه الگوریتم‌های یادگیری ماشین برای تشخیص مدولاسیون PRI ایجاد می‌کند. یکی از چالش‌های مهم توسعه الگوریتم‌های یادگیری ماشین، نیاز به حجم زیادی از داده‌های آموزشی است که در بسیاری از کاربردهای عملی می‌تواند دشوار باشد. چالش دیگر طراحی الگوریتم‌هایی است که در برابر تغییرات در پارامترهای PRI، مانند تغییرات در زمان یا فرکانس تکرار پالس یا نسبت سیگنال به نویز، مقاوم هستند. پرداختن به این چالش‌ها برای توسعه روش‌های تشخیص دقیق و قوی الگوی تغییرات PRI که برای تجهیزات راداری مدرنی که از طیف گسترده‌ای از PRI ها استفاده می‌کنند، ضروری است. همان‌طور که بیان گردید، در فناوری راداری مدرن، انواع مختلف مدولاسیون PRI پیچیده به‌جای الگوی ثابت ساده استفاده می‌شود؛ بنابراین، شناسایی مدولاسیون PRI به شناسایی منابع انتشار کمک شایانی می‌کند. با این وجود این مسئله به دلیل از دست دادن درصدی از پالس‌ها و پالس‌های ناخواسته 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 می‌کند. برای حل مسئله تشخیص و طبقه‌بندی مدولاسیون PRI، تحقیقات گسترده‌ای انجام شده است. روش‌های موجود را می‌توان به‌طور کلی به ۴ دسته مبتنی بر آمار، مبتنی بر درخت تصمیم، روش هیستوگرام و مبتنی بر یادگیری تقسیم‌بندی نمود [۶]. روش‌های مبتنی بر درخت تصمیم [۶]

(DBN) [۱۵] و شبکه عصبی کانولوشنی (CNN) [۱۶] به طور موفقیت آمیز پیشنهاد شدند. یک CNN می تواند مشکلات را با شبیه سازی مغز تحلیل کند و برای دستیابی به سطح بالاتر داده های سطح پایین را ترکیب و ویژگی های انتزاعی را فراهم نماید و توانایی یادگیری ویژگی مناسبی دارد به همین دلیل برای تشخیص و طبقه بندی پارامترهای سیگنال رادار مناسب است و همچنین به طور گسترده در پردازش تصویر و صحبت استفاده می گردد. در مرجع [۱۰] الگوریتم بهبود یافته مبتنی بر شبکه عصبی سه لایه برای تشخیص چهار نوع الگوی تغییرات PRI استفاده می شود. نتایج شبیه سازی نشان می دهد که روش بهبود یافته قابلیت اطمینان و دقت تشخیص را بهبود می بخشد، اما سه ویژگی قبل از شناسایی باید استخراج شوند. در مرجع [۱۷] نویسندگان یک روش مبتنی بر یادگیری برای تشخیص هفت نوع مدولاسیون PRI ارائه دادند و این روش از طبقه بندی کننده های پیشرفته PRI در طیف گسترده ای از پارامترهای شبیه سازی و تحت پالس های ازدست رفته و پالس های ناخواسته بهتر عمل می کند. با این حال، بیشتر روش ها هنوز به ویژگی های دست ساز وابسته هستند که به وسیله انواع الگوی تغییرات PRI داده شده تعیین می شوند و بسیاری از رویکردها قبل از شناسایی بر برخی پیش پردازش ها نیاز دارند. شایان ذکر است که اکثر روش ها تأثیر نویز سیگنال دریافتی SNR را کاملاً در نظر نمی گیرند.

در سال های اخیر، محققان استفاده از شبکه های عصبی کانولوشنال عمیق (DCNN) را برای تشخیص الگوی تغییرات PRI بررسی کرده اند [۱۸]. CNN ها نوعی شبکه عصبی مصنوعی هستند که معمولاً در تشخیص تصویر و گفتار استفاده می شوند [۱۹-۲۱]. CNN ها به دلیل توانایی خود در یادگیری و استخراج ویژگی ها از داده های خام به طور خودکار در کاربردهای مختلف موفق بوده اند [۲۲-۲۴]. در مرجع [۶]، یک طرح مبتنی بر یادگیری عمیق جدید ارائه شده است که در آن یک شبکه عصبی کانولوشنی عمیق (DCNN) برای طبقه بندی هفت نوع الگوی تغییرات PRI آموزش دیده است. روش ارائه شده، اولین روشی است که برای حل این مسئله رویکرد یادگیری عمیق را در پیش گرفته است (قید شده در خود مرجع). مزیت اصلی روش پیشنهادی این است که CNN دنباله خام را به عنوان ورودی در نظر می گیرد و بنابراین، روش های استخراج ویژگی را مانند روش های قبلی در نظر نمی گیرد. این روش، برای تشخیص و طبقه بندی مدولاسیون PRI در مقایسه با روش های موجود در مقابل نویز بسیار مقاوم است. به طور خاص، برای طیف وسیعی از پالس های ازدست رفته و پالس های ناخواسته روش پیشنهادی نسبت به سایر رقبا با فاصله دقت حداقل ۲٪ بهتر عمل می کند. این شکاف حتی با افزایش میزان نویز به سرعت افزایش می یابد. در مرجع [۲۵] یک روش خودکار مبتنی بر یک شبکه عصبی کانولوشنی (CNN) برای شناسایی هفت نوع مدولاسیون PRI پیشنهاد شده است. رویکرد مبتنی بر CNN عملکرد را ارتقاء می بخشد و همچنین برای پالس های ازدست رفته و ناخواسته قوی است.

نوآوری این تکنیک استفاده از ویژگی های CNN عدم تغییر در انتقال های کوچک از طریق استفاده از فیلتر محلی و حداکثر رساندن است. در این روش، دنباله PRI، مستقیماً وارد CNN می شود و نیازی به مراحل پیش پردازش اضافی برای استخراج ویژگی ندارند، زیرا ویژگی ها می توانند به طور خودکار از طریق شبکه های عصبی استخراج شوند. روش مبتنی بر CNN ارائه شده در این مقاله می تواند هفت نوع حالت تغییرات PRI را با دقت تشخیص ۹۶/۱٪ تحت حداکثر ۵۰٪ پالس های ازدست رفته و ۲۰٪ پالس های ناخواسته در سناریوی شبیه سازی تشخیص دهد. علاوه بر این، این روش نیازی به پیش پردازش داده ندارند، زیرا ویژگی ها می توانند به طور خودکار از طریق شبکه های عصبی استخراج شوند. در [۲۶] نویسندگان یک روش تشخیص عمیق مدولاسیون PRI مبتنی بر CNN را با استفاده از تصاویر طیف نگاری به عنوان ورودی پیشنهاد کردند. روش پیشنهادی به نرخ تشخیص بیش از ۹۵٪ برای چندین طرح الگوی تغییرات PRI دست یافت که نشان دهنده اثربخشی CNN های عمیق در تشخیص الگوی تغییرات PRI است. به طور مشابه، در [۲۷] نویسندگان یک روش مبتنی بر CNN عمیق برای تشخیص الگوی تغییرات PRI با استفاده از تصاویر فرکانس زمانی به عنوان ورودی پیشنهاد کردند. روش پیشنهادی به نرخ تشخیص بیش از ۹۸٪ برای چندین طرح الگوی تغییرات PRI دست یافت که از روش های سنتی مبتنی بر یادگیری ماشین بهتر عمل کرد. در مطالعه دیگری در [۲۸] نویسندگان یک روش مبتنی بر CNN عمیق برای تشخیص الگوی تغییرات PRI با استفاده از سیگنال های راداری خام به عنوان ورودی پیشنهاد کردند. روش پیشنهادی به نرخ تشخیص بیش از ۹۹٪ برای چندین طرح الگوی تغییرات PRI دست یافت که اثربخشی CNN های عمیق در تشخیص الگوی تغییرات PRI با استفاده از داده های خام را نشان می دهد.

مطالعه دیگری [۲۹] یک سیستم عمیق مبتنی بر CNN برای تشخیص الگوی تغییرات PRI پیشنهاد کرد. این سیستم بر روی یک مجموعه داده شامل ۱۲ نوع طرح الگوی تغییرات PRI، با SNR های مختلف آموزش داده شد. نتایج نشان داد که سیستم پیشنهادی نسبت به روش های سنتی به دقت تشخیص بالاتری دست یافت. در یک مطالعه جدیدتر، در [۳۰] یک سیستم عمیق مبتنی بر CNN برای تشخیص الگوی تغییرات PRI پیشنهاد کرد. این سیستم بر روی یک مجموعه داده شامل شش مدولاسیون PRI، با SNR های مختلف آموزش داده شد. نتایج نشان داد که سیستم پیشنهادی حتی در سناریوهای SNR پایین به دقت تشخیص بالایی دست یافت. با بررسی مطالعات بیان شده در بالا، اخیراً رویکردهای مبتنی بر شبکه عصبی کانولوشنی در تشخیص و طبقه بندی مدولاسیون PRI بسیار مورد توجه قرار گرفته اند. این روش ها شامل هیچ مرحله پیش پردازشی از جمله آماده سازی سیگنال و استخراج ویژگی نیست. نشان داده شده است که شبکه های عصبی کانولوشنال (CNN) انتخاب خوبی برای تشخیص

مدولاسیون PRI حتی در حضور پالس‌های از دست رفته و ناخواسته زیاد هستند. با این حال، یک اثر مخرب بسیار مهم نادیده گرفته شده است: نقاط پرت بزرگ که به دلیل اسکن آنتن رادار اتفاق می‌افتد. سایر رویکردهای مبتنی بر یادگیری عمیق دارای محدودیت‌های خاصی هستند که باید مورد توجه قرار گیرند. یکی از محدودیت‌ها این است که روش‌های موجود فقط بر ویژگی‌های دست‌ساز متکی هستند که ممکن است پیچیدگی و تنوع کامل الگوهای تغییرات PRI را نشان ندهند. علاوه بر این، این روش‌ها ممکن است در برابر نویز و تداخل مقاوم نباشند که می‌تواند عملکرد سیستم را در کاربردهای عملی کاهش دهد. بنابراین، در این مطالعه، بر اساس ماهیت و ویژگی‌های توالی‌های زمانی رادار، سه روش مبتنی بر شبکه‌های عصبی عمیق کانولوشنی بهبود یافته با ماشین یادگیری افراطی برای تشخیص مدولاسیون PRI ارائه شده است. روش‌های پیشنهادی نه تنها در برابر سطوح بالای پالس‌های از دست رفته و کاذب قوی است، بلکه می‌تواند طیف وسیعی از PRI های ورودی و مقادیر زیادی از نقاط دورافتاده مربوط به اسکن آنتن را کنترل کند. ما یک رویکرد جدید را پیشنهاد می‌کنیم که از CNN عمیق یا همان DCNN به عنوان استخراج‌کننده ویژگی، ELM برای تشخیص بی‌درنگ الگوهای تغییرات PRI استفاده می‌کند. رویکرد پیشنهادی برای غلبه بر محدودیت‌های روش‌های موجود و بهبود دقت و استحکام تشخیص و طبقه‌بندی مدولاسیون PRI در حضور نویز و تداخل طراحی شده است. علاوه بر این، توسعه مجموعه‌های داده جامع‌تر حاوی طیف وسیع‌تری از سیگنال‌های با مدولاسیون PRI با SNRهای مختلف می‌تواند به توسعه و ارزیابی سامانه‌های تشخیص کمک کند.

در این مطالعه ما از داده‌های شبیه‌سازی شده متناسب با محیط واقعی که کلیه جوانب از جمله پالس‌های از دست رفته، پالس‌های کاذب و ناخواسته و همچنین اثرات اسکن آنتن رادار و لوب‌های جانبی و لوب پستی که باعث ایجاد پالس‌های پرت می‌شوند، در نظر گرفته می‌شوند. لازم به ذکر است که در مطالعات بیان شده در پیشینه تحقیق یکی از اثرات پالس‌های از دست رفته و یا پالس‌های ناخواسته در نظر گرفته شده است و به اثرات اسکن آنتن پرداخته نشده است.

۲- دادگان شبیه‌سازی شده

همان‌طور که بیان گردید با بررسی پیشینه تحقیق در تولید داده‌های شبیه‌سازی شده اثر نامطلوب اثرات اسکن آنتن رادار و لوب‌های جانبی و لوب پستی آن در نظر گرفته نشده است و اثرات پالس‌های از دست رفته و پالس‌های ناخواسته تنها یک مورد و یا اگر هم هر دو اثر مورد استفاده قرار گرفته اثرات آن‌ها جداگانه در نظر گرفته شده است. در این مطالعه چون هدف شبیه‌سازی بر اساس داده‌های واقعی هست، برخلاف کارهای تحقیقاتی قبلی در این زمینه، ما به مشکل تشخیص مدولاسیون PRI با در نظر گرفتن تمام اثرات مخرب در دنیای واقعی می‌پردازیم. برای شبیه‌سازی سناریوهای واقعی، ابتدا اثرات اسکن آنتن رادار و لوب‌های جانبی و لوب پستی آن در نظر گرفته شد. این پدیده‌ها

مقدار	مشخصات
۲-۵۰۰۰	محدوده PRI (μs)
۱-۰	لرزش ناخواسته (%)
۱-۰	نقاط پرت بزرگ (%)
۲۵۰-۱۰۰	تعداد پالس
۳۰-۵	پالس‌های از دست رفته (%)
۳۰-۵	پالس‌های ناخواسته (%)

اکنون، برای تولید داده‌های تجربی، مشخصات هر نوع مدولاسیون باید در نظر گرفته شود. برای Simple PRI، یک PRI مرکزی به‌طور تصادفی از محدوده ذکر شده در جدول ۲ انتخاب می‌شود و بردار PRI با استفاده از معادله (۱) ایجاد می‌شود.

PRI_C است و تعداد نقاط در یک دوره یک عدد تصادفی بین ۲۰ - ۱۰۰ است.

۳- شرح بخش‌ها در روش پیشنهادی

۳-۱- شبکه عصبی کانولوشنی عمیق

شبکه‌های عصبی کانولوشنی که نوعی شبکه‌ی عصبی عمیق محسوب می‌شوند به‌منظور تقلید از فرایندهای بیولوژیکی بینایی انسان طراحی شده‌اند. این شبکه‌ها با استفاده از چندین لایه که به روش‌های مختلف مرتب‌شده‌اند تا ساختارهای متمایز شبکه را تشکیل دهند. CNN ها اغلب در شناسایی و طبقه‌بندی تصاویر استفاده می‌شوند و یکی از موفق‌ترین نوع مدل یادگیری عمیق برای تجزیه و تحلیل تصویر تا به امروز CNN است [۳۸، ۳۹]. CNN ها از لایه‌های زیادی تشکیل شده‌اند که ورودی خود را با فیلترهای کانولوشن تا حد کمی تغییر می‌دهند. انواع مختلفی از CNN ها در مطالعات مختلف ارائه شده است، مانند LeNet-5 [۴۰]، AlexNet [۴۱]، GoogLeNet [۴۲] و غیره.

۳-۱-۱- شبکه LeNet-5

LeNet برای تصاویر خاکستری و سیاه‌وسفید ساده و درعین‌حال مؤثر است. LeNet ساده‌ترین نوع CNN است که توسط Yann Le-Cun در اواخر دهه ۱۹۹۰ معرفی شد و به‌طور گسترده به‌عنوان اولین مجموعه از CNN های واقعی در نظر گرفته می‌شود [۴۰]. جدول (۲) جزئیات معماری LeNet-5 را نشان می‌دهد. این مفاهیم را می‌توان در کلاس‌های دولایه، از جمله لایه‌های زیر نمونه‌برداری و لایه‌های کانولوشنی مرتب کرد. همان‌طور که در شکل (۲) نشان داده شده است، لایه‌های پردازش شامل سه لایه کانولوشنی هستند که بین لایه‌های زیر نمونه‌برداری قرار دارند و به‌عنوان نقشه‌های ویژگی سازمان‌دهی شده‌اند. لایه‌های خروجی نهایی سه لایه کاملاً متصل هستند.

۳-۱-۲- شبکه AlexNet

AlexNet یک شبکه عصبی کانولوشنی است که یکی از بزرگ‌ترین شبکه‌های زمان خود محسوب می‌شود. این شبکه به‌منظور شناسایی و طبقه‌بندی تصاویر رنگی با سایز $۲۲۷ \times ۲۲۷ \times ۳$ ارائه شده است. به‌طور کلی این شبکه‌ی عصبی ۶۲ میلیون پارامتر یادگیری و ۱۱ لایه دارد. در این مدل، عمق شبکه در مقایسه با LeNet-5 افزایش یافته است [۴۳]. AlexNet دارای هشت لایه با پارامترهای قابل یادگیری است. این مدل از پنج لایه با ترکیب حداکثر ادغام و به دنبال آن ۳ لایه کاملاً متصل تشکیل شده است و در هر یک از این لایه‌ها به‌جز لایه خروجی از فعال‌سازی Relu استفاده می‌شود. در جدول (۳) و شکل (۳) جزئیات معماری AlexNet مورد استفاده در این مطالعه نشان داده شده است.

$$(1) \quad \left(1 - d/2\right) \times PRI_C \leq PRI \leq \left(1 + d/2\right) \times PRI_C$$

که در آن PRI_C نشان‌دهنده PRI ثابت و d مقدار لرزش ناخواسته است. D&S PRI می‌تواند به‌طور مشابه تولید شود. تنها تفاوت این است که ابتدا باید تعداد سطوح مشخص شود. اگرچه در رادارهای مدرن، سطح D&S PRI می‌تواند نامحدود باشد، یک عدد معمولی و معقول را می‌توان به‌طور تصادفی در محدوده ۲-۶۴ انتخاب کرد. لازم به ذکر است که در شبیه‌سازی ما بر روی این مدولاسیون، حداکثر و حداقل PRI از نابرابری (۲) تبعیت می‌کنند:

$$(2) \quad \text{Max}(PRI) \leq 10 \times \text{min}(PRI)$$

علاوه بر این، تعداد پالس‌ها در هر دوره در محدوده (۳) قرار می‌گیرد که در آن N تعداد کل پالس‌ها و L تعداد سطوح است.

$$(3) \quad [4(2N/L) - 4]$$

به‌طور مشابه، برای مدولاسیون Stagger PRI، یک عدد تصادفی بین ۲ - ۶۴ به‌عنوان تعداد سطوح در نظر گرفته می‌شود. سپس، یک توالی دوره‌ای بدون نویز در محدوده اتخاذ شده (به جدول ۲ مراجعه کنید) تولید می‌شود. سپس لرزش ناخواسته به‌طور جداگانه برای هر سطح PRI اضافه می‌شود. روش تولید PRI Jitter کاملاً مشابه روش ساده است، به‌جز d که در محدوده ۱٪ تا ۳۰٪ است. شایان‌ذکر است که با توجه به رابطه (۳) برای مقدار مشخص شده d ، مقدار حداکثر و حداقل دنباله PRI را می‌توان تعیین کرد که برای تولید PR Jitter یکنواخت و گاوسی مفید است. برای نوع گاوسی، توزیع را می‌توان با حل مجموعه معادلات (۴) تعیین کرد:

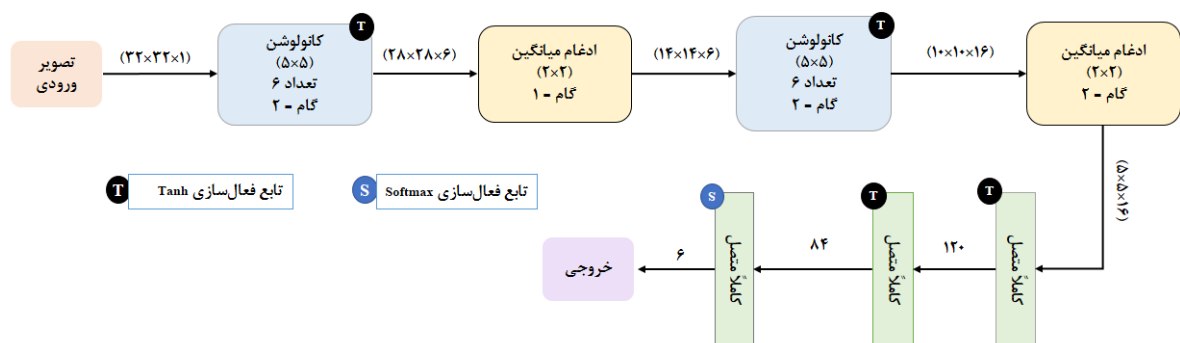
$$(4) \quad m - 4\sigma = PRI_m$$

$$m + 4\sigma = PRI_M$$

که در آن m و σ به ترتیب میانگین و انحراف معیار توزیع را نشان می‌دهند و PRI_m و PRI_M حداقل و حداکثر مقادیر PRI هستند. در این نوع مدولاسیون، نیازی به افزودن هرگونه لرزش ناخواسته نیست. برای مدولاسیون Agile PRI ابتدا تعداد سطوح که عددی تصادفی بین ۸ - ۱۲۸ است مشخص می‌شود. سپس PRI های مختلف بر این اساس مشخص می‌شوند و یک استراتژی سوئیچینگ تصادفی در بین آن‌ها انجام می‌شود. در مقابل PRI Jitter افزودن لرزش ناخواسته در این مدولاسیون ضروری است. در مدولاسیون Sliding PRI ابتدا نوع صعودی یا نزولی به‌صورت تصادفی انتخاب می‌شود. سپس حداکثر و حداقل مقدار PRI تعیین می‌شود. فاصله بین این دو مقدار به ۱۰۰-۱۰ سطح تقسیم می‌شود و در نهایت به هر سطح از سیگنال لرزش ناخواسته به سیگنال Sliding خالص اضافه می‌شود. همچنین، برای تولید PRI Periodic، ابتدا یک PRI مرکزی (PRI_C) در محدوده قابل‌قبول انتخاب می‌شود. سپس یک‌شکل موج سینوسی با فاز تصادفی در اطراف PRI_C ایجاد می‌شود به‌طوری‌که حداکثر اختلاف بین دامنه آن $0.2 \times$

جدول (۲) جزئیات معماری LeNet-5 [۴۰]

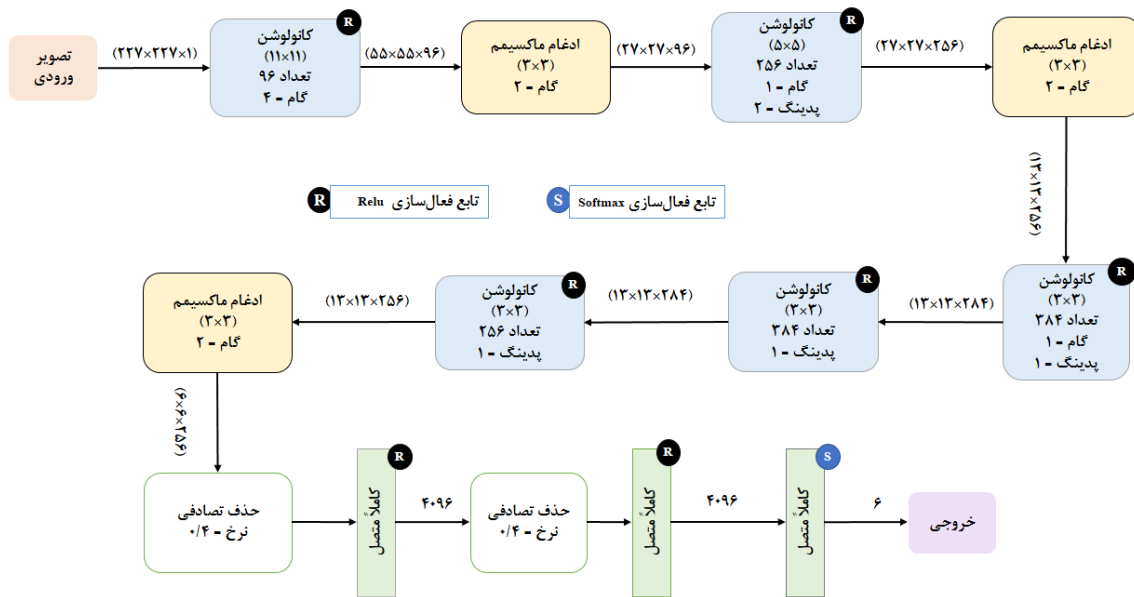
ویژگی‌های خروجی	استرید	پدینگ	اندازه کرنل	تعداد کرنل‌ها	لایه‌ها
۳۲×۳۲	-	-	-	-	ورودی
۲۸×۲۸	۱	+	۵×۵	۶	لایه کانولوشنی (C1)
۱۴×۱۴	۲	+	۲×۲	۶	لایه ادغام میانگین (S2)
۱۰×۱۰	۱	+	۵×۵	۱۶	لایه کانولوشنی (C3)
۵×۵	۲	+	۲×۲	۱۶	لایه ادغام میانگین (S4)
۱۲۰	-	-	-	-	لایه کاملاً متصل (C5)
۸۴	-	-	-	-	لایه کاملاً متصل (C6)
۶	-	-	-	-	لایه کاملاً متصل (C7)



شکل (۲) معماری LeNet-5


جدول (۳) جزئیات معماری AlexNet [۴۳]

ویژگی‌های خروجی	تابع فعال‌سازی	استرید	پدینگ	اندازه فیلتر	تعداد فیلتر	لایه‌ها
۲۲۷×۲۲۷×۱	-	-	-	-	-	ورودی
۵۵×۵۵×۹۶	ReLU	۴	-	۱۱×۱۱	۹۶	لایه کانولوشنی (C1)
۲۷×۲۷×۹۶	-	۲	-	۳×۳	-	لایه ادغام ماکسیمم (S2)
۲۷×۲۷×۲۵۶	ReLU	۱	۲	۵×۵	۲۵۶	لایه کانولوشنی (C3)
۱۳×۱۳×۲۵۶	-	۲	-	۳×۳	-	لایه ادغام ماکسیمم (S4)
۱۳×۱۳×۳۸۴	ReLU	۱	۱	۳×۳	۳۸۴	لایه کانولوشنی (C5)
۱۳×۱۳×۳۸۴	ReLU	-	۱	۳×۳	۳۸۴	لایه کانولوشنی (C6)
۱۳×۱۳×۲۵۶	ReLU	-	۱	۳×۳	۲۵۶	لایه کانولوشنی (C7)
۶×۶×۲۵۶	-	۲	-	۳×۳	-	لایه ادغام ماکسیمم (S8)
۶×۶×۲۵۶	-	-	-	-	نرخ=۰/۵	حذف تصادفی ۱
۴۰۹۶	ReLU	-	-	-	-	لایه کاملاً متصل (C9)
۴۰۹۶	-	-	-	-	نرخ=۰/۵	حذف تصادفی ۲
۴۰۹۶	ReLU	-	-	-	-	لایه کاملاً متصل (C10)
۶	Softmax	-	-	-	-	لایه کاملاً متصل (C11)



شکل (۳) جزئیات معماری AlexNet [۴۳]

وزن ها و بایاس های لایه خروجی مبتنی بر وزن ها و بایاس های لایه ورودی هستند. لازم به ذکر است که در یک ELM مانند شکل (۶) لایه ورودی دارای n نورون است، درحالی که لایه پنهان دارای L نورون و لایه خروجی دارای m نورون است. از ویژگی های مهم ELM می توان به سرعت آموزش سریع، قابلیت تعمیم خوب، همگرایی به حداقل سراسری و اجرای ساده اشاره نمود. بسیاری از انواع مختلف ELM در دسترس هستند که می توانند برای مسائل بلادرنگ مورد استفاده قرار گیرند [۴۶-۴۸].



شکل (۶) ماشین یادگیری تقویتی

تابع فعال سازی را می توان به صورت (۵) فرموله کرد [۴۵]:

$$Z_j = \sum_{i=1}^L \beta_i f(w_i, b_i, x_i) \quad (۵)$$

درجایی که w_i وزن اتصال ورودی را نشان می دهد، b_i نشان دهنده بایاس آمین نورون پنهان است، x_i مخفف وزن اتصال خروجی است و Z_j خروجی نهایی ELM است. نمایش ماتریسی معادله (۵) را می توان در معادله (۶) نشان داد [۴۵].

۳-۱-۳- معرفی GoogleNet

با افزایش تعداد لایه های شبکه عملکرد شبکه به طور چشمگیری افزایش می یابد. از طرفی افزایش لایه ها برای ایجاد شبکه های بزرگ تر هزینه بر است. شبکه های بزرگ اغلب مستعد مشکل بیش برآزش^۱ هستند و با مشکل محوشدگی گرادیان^۲ یا انفجار گرادیان^۳ مواجه هستند. به همین دلیل معماری GoogleNet معرفی شد که عمدتاً از طریق استفاده از ماژول Inception بیشتر مشکلات شبکه های بزرگ را برطرف کرد [۴۴]. ماژول Inception یک معماری شبکه ی عصبی است که شناسایی ویژگی را در مقیاس های مختلف از طریق لایه های کانولوشن با استفاده از فیلترهای مختلف انجام می دهد و هزینه ی محاسباتی آموزش یک شبکه بزرگ را از طریق کاهش ابعاد آن کاهش می دهد [۴۴]. معماری GoogleNet از ۲۲ لایه ی تشکیل شده است (با در نظر گرفتن لایه های ادغام ۲۷ لایه). از این تعداد ۹ لایه ی آن ماژول Inception است. در جدول (۴) و شکل (۴) معماری GoogleNet استفاده شده در این مطالعه نشان داده شده است. معماری ماژول Inception نیز در شکل (۵) آورده شده است.

۳-۲- ماشین یادگیری افراطی (ELM)

ماشین یادگیری افراطی (ELM) و سایر شبکه های عصبی تک لایه پنهان در یادگیری ماشینی رایج هستند [۴۵]. ابتدا مقادیر تصادفی برای وزن ها و بایاس های لایه ورودی ایجاد می شود که سپس آن ها برای تعیین وزن ها و بایاس های لایه خروجی استفاده می شوند. در واقع

³ Exploding Gradient

¹ Overfitting

² Vanishing Gradient

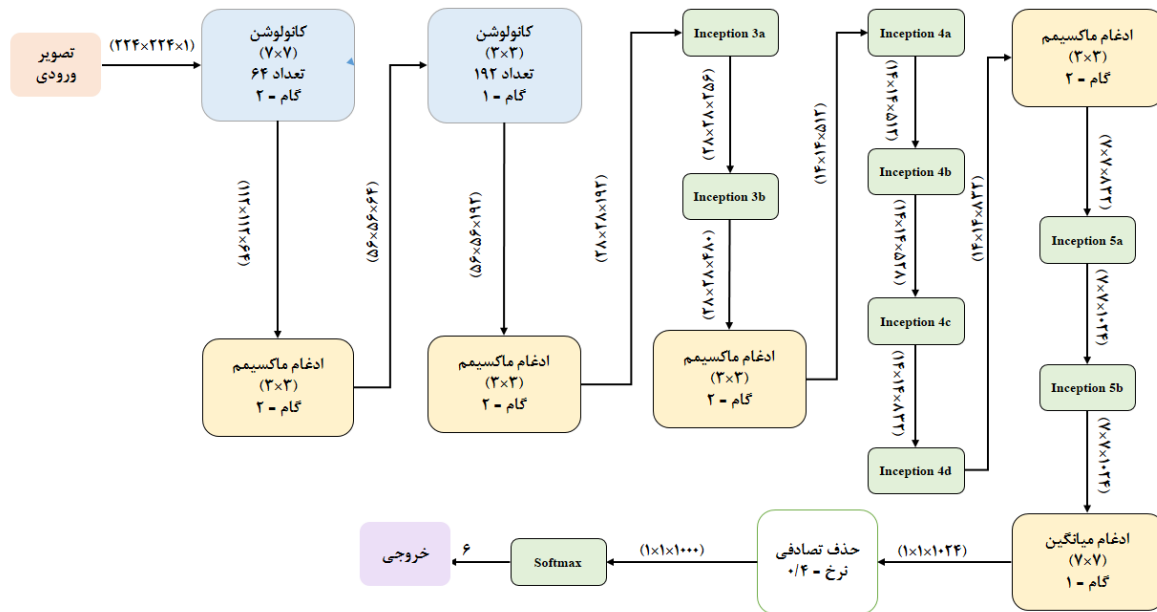
جدول (۴) جزئیات معماری GoogleNet [۴۴]

تعداد عملیات ریاضی (M)	تعداد پارامترهای یادگیری (K)	** فیلتر	# ۵×۵	## ۵×۵	#۳×۳	### ۳×۳	۱×۱#	عمق (تعداد لایه‌های هر عنصر)	مشخصات خروجی	اندازه گام	اندازه فیلتر	لایه‌ها
-	-	-	-	-	-	-	-	-	۲۲۴×۲۲۴×۱	-	-	ورودی
۳۴	۲۷	-	-	-	-	-	-	۱	۱۱۲×۱۱۲×۶۴	۲	۷×۷	کانولوشن
-	-	-	-	-	-	-	-	۰	۵۶×۵۶×۶۴	۲	۳×۳	ادغام ماکسیمم
۳۶۰	۱۱۲	-	-	-	۱۹۲	۶۴	-	۲	۵۶×۵۶×۱۹۲	۱	۳×۳	کانولوشن
-	-	-	-	-	-	-	-	۰	۲۸×۲۸×۱۹۲	۲	۳×۳	کانولوشن
۱۲۸	۱۵۹	۳۲	۳۲	۱۶	۱۲۸	۹۶	۶۴	۲	۲۸×۲۸×۲۵۶	-	-	Inception 3a
۳۰۴	۳۸۰	۶۴	۹۶	۳۲	۱۹۲	۱۲۸	۱۲۸	۲	۲۸×۲۸×۴۸۰	-	-	Inception 3b
-	-	-	-	-	-	-	-	۰	۱۴×۱۴×۵۱۲	۲	۳×۳	ادغام ماکسیمم
۷۳	۳۶۴	۶۴	۴۸	۱۶	۲۰۸	۹۶	۱۹۲	۲	۱۴×۱۴×۵۱۲	-	-	Inception 4a
۸۸	۴۳۷	۶۴	۶۴	۲۴	۲۲۴	۱۱۲	۱۶۰	۲	۱۴×۱۴×۵۱۲	-	-	Inception 4b
۱۰۰	۴۶۳	۶۴	۶۴	۲۴	۲۵۶	۱۲۸	۱۲۸	۲	۱۴×۱۴×۵۲۸	-	-	Inception 4c
۱۱۹	۵۸۰	۶۴	۶۴	۳۲	۲۸۸	۱۴۴	۱۱۲	۲	۱۴×۱۴×۸۳۲	-	-	Inception 4d
۱۷۰	۸۴۰	۱۲۸	۱۲۸	۳۲	۳۲۰	۱۶۰	۲۵۶	۲	۱۴×۱۴×۸۳۲	-	-	Inception 4e
-	-	-	-	-	-	-	-	۰	۷×۷×۸۳۲	۲	۳×۳	ادغام ماکسیمم
۵۴	۱۰۷۲	۱۲۸	۱۲۸	۳۲	۳۲۰	۲۵۶	۲۵۶	۲	۷×۷×۱۰۲۴	-	-	Inception 5a
۷۱	۱۳۸۸	۱۲۸	۱۲۸	۴۸	۳۸۴	۳۸۴	۳۸۴	۲	۷×۷×۱۰۲۴	-	-	Inception 5b
-	-	-	-	-	-	-	-	۰	۱×۱×۱۰۲۴	۱	۷×۷	ادغام میانگین
-	-	-	-	-	-	-	-	۰	۱×۱×۱۰۲۴	-	-	حذف تصادفی (%۴۰)
۱	۱۰۰۰	-	-	-	-	-	-	۱	۱×۱×۱۰۰۰	-	-	خطی سازی
-	-	-	-	-	-	-	-	۰	۱×۱×۶	-	-	Softmax

استفاده شده است؛ inception ۱×۱#، ۳×۳# و ۵×۵# اندازه‌ی فیلترهایی را نشان می‌دهد که در ماژول

۳×۳## و ۵×۵###: تعداد فیلترهای یک‌دریک را نشان می‌دهد که قبل از هر لایه کانولوشن به کاررفته است؛

استفاده شده است؛ Inception ** فیلتر: تعداد فیلترهای یک‌دریک را نشان می‌دهد که بعد از هر لایه‌ی ادغام در ماژول



شکل (۴) معماری [44] GoogleNet

وزن خروجی (β) با بهینه‌سازی مقدار حداقل مربعات در معادله (۹) ایجاد می‌شود؛ و نتیجه ممکن است به صورت معادله (۱۰) تعیین شود [۴۵].

$$\min_{\beta} \|H\beta - Z\| \quad (9)$$

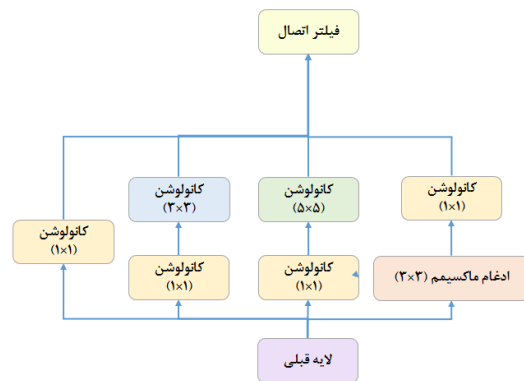
$$\beta = H^{-1}Z^T \quad (10)$$

درجایی که معکوس مور-پنروز تعمیم یافته ماتریس H با H^{-1} نشان داده می‌شود.

۴- روش پیشنهادی

این مقاله از ساختار AlexNet, LetNet-5 و GoogleNet برای شناسایی انواع مدولاسیون PRI استفاده می‌کند. هر کدام از این ساختار شامل تعدادی لایه کانولوشن و لایه ادغام است که به دنبال آن‌ها لایه‌های کاملاً متصل^۱ (FC) با استفاده از الگوریتم انتشار برگشتی مبتنی بر گرادیان^۲ (GDBP) برای یادگیری استفاده می‌شود. با توجه به کمبودهای GDBP ذکر شده، ما پیشنهاد می‌کنیم که از یک ELM تک لایه به جای لایه‌های FC برای طبقه‌بندی ویژگی‌های استخراج شده استفاده شود. وزن لایه‌های کانولوشن شبکه‌های استفاده شده روی یک مجموعه داده بزرگ به عنوان یک شبکه کانولوشنی عمیق کامل با یک الگوریتم یادگیری استاندارد GDBP از قبل آموزش داده شده است.

پس از مرحله پیش آموزش، لایه‌های FC حذف می‌شوند و لایه‌های باقی‌مانده برای بهره‌برداری به عنوان استخراج‌کننده ویژگی فرض



شکل (۵) معماری ماژول Inception

$$Z^T = H\beta \quad (6)$$

جایی که Z^T نشان‌دهنده ترانهاده ماتریس Z است، H و β می‌تواند به صورت زیر نمایش داده شود [۴۵]:

$$H = \begin{bmatrix} f(w_1, b_1, x_1) & f(w_2, b_2, x_1) & \dots & f(w_L, b_L, x_1) \\ \vdots & \vdots & \dots & \vdots \\ f(w_1, b_1, x_\beta) & f(w_2, b_2, x_\beta) & \dots & f(w_L, b_L, x_\beta) \end{bmatrix}_{\beta \times L} \quad (7)$$

$$\beta = [\beta_1, \beta_2, \dots, \beta_L]^T \quad (8)$$

² Gradient Descent-based Back Propagation

¹ Fully-Connected

می‌شوند. مقادیر ورودی شبکه ELM توسط ویژگی‌های ایجاد شده توسط stub-CNN ارائه می‌شود.

۴-۱- معیارهای سنجش

شش معیار پرکاربرد برای ارزیابی عملکرد طبقه‌بندی روش ما مورد استفاده قرار گرفت: تشخیص پذیری، حساسیت، امتیاز F1، دقت، صحت و ضریب همبستگی متیو (MCC) [۵۰]. از آنجایی که دقت و امتیاز F1 به دست آمده در ماتریس‌های اغتشاش، دو مورد از پرکاربردترین معیارها برای ارزیابی موفقیت یک کار طبقه‌بندی هستند، ما برای مقایسه با سایر مدل‌های معیار به آن‌ها تکیه کردیم [۵۱].

با این حال، این تکنیک‌های آماری می‌توانند به‌طور خطرناکی پیامدهای خوش‌بینانه اغراق‌آمیز را به‌ویژه در مجموعه‌های داده نامتعادل نشان دهند [۵۲]. از سوی دیگر، MCC معیار آماری قابل‌اعتمادتری است که تنها در صورتی امتیاز بالایی به دست می‌آورد که پیش‌بینی در هر یک از چهار دسته ماتریس اغتشاش (منفی کاذب، مثبت واقعی، منفی واقعی و مثبت کاذب) به‌خوبی متناسب با اندازه مؤلفه‌های مثبت و منفی مجموعه داده انجام شود. هدف از تشخیص پذیری معمولاً این است که نشان دهد یا ارزیابی کند که یک آزمایش چقدر می‌تواند وجود یک اختلال خاص را به‌طور دقیق رد کند. این شاخص دقت طبقه‌بندی تست در شرایطی که مثبت کاذب ممکن است بسیار باارزش باشد، بسیار مهم است. این آمار برای کاربردهای نظامی بسیار مهم است. رابطه بین حساسیت و تشخیص پذیری معکوس است: با افزایش حساسیت، تشخیص پذیری کاهش می‌یابد و بالعکس. بر اساس [۵۰]، حساسیت و تشخیص پذیری سنجش‌های برتر از دقت برای تعیین موفقیت‌آمیز بودن یک آزمون هستند. آن‌ها را می‌توان با استفاده از فرمول‌های زیر محاسبه کرد [۵۳]:

$$Specificity = \frac{TN}{TN + FP} \quad (11)$$

$$Sensitivity = \frac{TP}{TP + FN} \quad (12)$$

$$Accuracy = \frac{TP + TN}{TP + FP + FN + TN} \quad (13)$$

$$F1 - Score = \frac{TP}{TP + \frac{1}{2}(FP + FN)} \quad (14)$$

$$Precision = \frac{TP}{TP + FP} \quad (15)$$

$$MCC = \frac{TP \times TN - FP \times FN}{\sqrt{(FP + TP) \times (FP + TN) \times (FN + TP) \times (FN + TN)}} \quad (16)$$


درجایی که TN تعداد موارد منفی واقعی را نشان می‌دهد، تعداد موارد مثبت واقعی با TP، تعداد موارد مثبت کاذب با FP و تعداد موارد منفی کاذب با FN نشان داده می‌شود.

۴-۲- تجزیه و تحلیل عملکرد روش‌های پیشنهادی

روش‌های پیشنهادی بر روی ۶ نوع مدولاسیون PRI که به‌صورت شبیه‌سازی با لحاظ نمودن کلیه اثرات مخرب بیان شده در بخش ۲، صورت گرفت. برای هر نوع مدولاسیون تعداد ۱۰۰۰۰ تصویر نمونه انتخاب گردیدند که از این تصاویر ۷۰٪ برای آموزش هر شبکه و ۳۰٪ برای ارزیابی هر شبکه استفاده گردیدند. نتایج طبقه‌بندی هر شبکه به‌صورت جدول و شکل‌های زیر می‌باشند. نتایج عملکرد طبقه‌بندی LeNet5-ELM در جدول (۵) و شکل (۷) نشان داده شده است.

جدول (۵) نتایج طبقه‌بندی LeNet5-ELM

اجرا	ضریب همبستگی (%)	صحت (%)	امتیاز F1 (%)	دقت (%)	حساسیت (%)	تشخیص پذیری (%)
یک	۸۰/۳۷	۹۳/۶۴	۹۳/۶۴	۹۳/۶۴	۹۳/۶۴	۹۳/۶۴
دو	۵۱/۴۲	۸۵/۴۰	۸۲/۲۶	۸۳/۹۲	۷۹/۳۵	۸۳/۵۹
سه	۴۸/۹۹	۹۱/۷۹	۸۱/۸۸	۸۳/۹۳	۷۲/۲۱	۹۳/۶۴
چهار	۴۵/۰۳	۱۰۰	۷۹/۰۴	۸۳/۹۲	۶۵/۰۷	۹۹/۹۹
پنج	۶۸/۳۰	۹۳/۱۹	۸۹/۶۷	۹۰/۰۷	۸۶/۵۹	۹۳/۶۴
میانگین	۵۹/۷۹	۹۳/۹۲	۸۵/۱۸	۸۶/۵۹	۷۹/۳۵	۹۳/۶۴



شکل (۷) نتایج طبقه‌بندی LeNet5-ELM

نتایج عملکرد طبقه‌بندی GoogleNet-ELM در جدول (۶) و شکل (۸) نشان داده شده است.


جدول (۶) نتایج طبقه‌بندی GoogleNet-ELM

اجرا	ضریب همبستگی (%)	صحت (%)	امتیاز F1 (%)	دقت (%)	حساسیت (%)	تشخیص پذیری (%)
یک	۶۸/۳۹	۹۳/۱۹	۸۹/۶۷	۹۰/۰۷	۸۶/۵۹	۹۳/۶۴
دو	۵۴/۰۲	۹۹/۹۹	۸۴/۱۱	۸۶/۵۹	۷۲/۲۱	۹۹/۹۹
سه	۶۴/۰۸	۹۹/۹۹	۸۹/۸۸	۹۰/۰۷	۷۹/۳۵	۹۹/۹۹
چهار	۷۴/۰۱	۹۹/۹۹	۹۳/۱۰	۹۳/۶۴	۸۶/۵۹	۹۹/۹۹
پنج	۴۸/۸۹	۹۱/۷۹	۸۱/۸۸	۸۳/۹۲	۷۲/۲۱	۹۳/۶۴
میانگین	۶۱/۶۳	۹۷/۴۲	۸۷/۳۹	۸۸/۶۴	۷۹/۳۵	۹۸/۹۲

نتیجه گرفت که روش AlexNet-ELM از دو روش دیگر بهتر عمل نموده است.

در جدول (۹) مقایسه عملکرد روش‌های پیشنهادی

روش	ضرب همبستگی (%)	صحت امتیاز F1 (%)	دقت حساسیت تشخیص پذیری (%)	میانگین معیارهای سنجش (%)	
LeNet-ELM	۵۶/۷۹	۹۱/۰۳	۸۳/۲۹	۸۴/۶۰	۹۱/۷۵
GoogLeNet-ELM	۶۱/۶۳	۹۷/۴۲	۸۷/۳۹	۸۸/۶۴	۷۹/۳۵
AlexNet-ELM	۸۰/۷۴	۹۳/۹۱	۹۳/۶۳	۹۳/۶۳	۹۳/۷۵




شکل (۸) نتایج طبقه‌بندی GoogleNet-ELM

نتایج عملکرد طبقه‌بندی AlexNet-ELM در جدول (۷) و شکل (۹) نشان داده شده است.


جدول (۸) نتایج طبقه‌بندی AlexNet-ELM

اجرا	ضرب همبستگی (%)	صحت امتیاز F1 (%)	دقت حساسیت تشخیص پذیری (%)	میانگین معیارهای سنجش (%)
یک	۷۴/۹۳	۸۷/۴۵	۹۰/۰۷	۸۶/۶۰
دو	۶۸/۳۰	۹۳/۱۹	۹۰/۰۷	۹۳/۷۵
سه	۸۰/۳۷	۹۳/۶۴	۹۳/۶۴	۹۳/۷۵
چهار	۸۷/۲۳	۹۹/۹۹	۹۷/۲۱	۹۳/۶۴
پنج	۹۴/۸۷	۹۴/۱۱	۹۷/۲۱	۹۹/۹۹
میانگین	۸۰/۷۴	۹۳/۹۱	۹۳/۶۳	۹۳/۶۳



شکل (۱۰) مقایسه عملکرد طبقه‌بندی هر ۳ روش پیشنهادی


روش	LeNet-ELM	GoogLeNet-ELM	AlexNet-ELM
میانگین معیارهای سنجش (%)	۸۰/۸۲	۸۵/۵۵	۹۱/۵۵



شکل (۱۱) مقایسه میانگین معیارهای ارزیابی عملکرد روش‌های پیشنهادی

۵- نتیجه‌گیری

در این مقاله، ۳ روش مبتنی بر شبکه‌های عصبی کانولوشنی عمیق بهبودیافته بهبودیافته با ماشین یادگیری افراطی (LeNet-ELM) (ELM) برای تشخیص و طبقه‌بندی ۶ نوع مدولاسیون PRI متداول پیشنهاد گردید. روش‌های پیشنهادی بر روی مجموعه داده‌های شبیه‌سازی شده متناسب با



شکل (۹) نتایج طبقه‌بندی AlexNet-ELM

مقایسه نتایج عملکرد طبقه‌بندی هر ۳ روش پیشنهادی در جدول (۹) و شکل‌های (۱۰) و (۱۱) نشان داده شده است. نتایج بیانگر عملکرد بهتر روش GoogLeNet-ELM در معیارهای تشخیص پذیری و صحت و عملکرد بهتر AlexNet-ELM در ۴ معیار حساسیت، دقت، امتیاز $F1$ و ضرب همبستگی متیو می‌باشد. روش AlexNet-ELM در معیار حساسیت نسبت به ۲ روش دیگر با تفاوت چشمگیری بهتر عمل نموده است؛ و در نهایت به توجه به جدول (۱۰) و شکل (۱۱) می‌توان

international conference on artificial intelligence and statistics. 2010. JMLR Workshop and Conference Proceedings.

- [16] Sahiner, B., et al., Classification of mass and normal breast tissue: a convolution neural network classifier with spatial domain and texture images. IEEE transactions on Medical Imaging, 1996. 15(5): p. 598-610.
- [17] 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.
- [18] Hekrdla, M. and A. Heřmánek. Deep Convolutional Neural Network Classifier of Pulse Repetition Interval Modulations. in 2019 International Radar Conference (RADAR). 2019. IEEE.
- [19] 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.
- [20] 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.
- [21] Zhou, W., H. Wang, and Z. Wan, Ore image classification based on improved CNN. Computers and Electrical Engineering, 2022. 99: p. 107819.
- [22] 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.
- [23] 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.
- [24] 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.
- [25] Li, X., et al., Toward convolutional neural networks on pulse repetition interval modulation recognition. IEEE Communications Letters, 2018. 22(11): p. 2286-2289.
- [26] Zheng, S., et al., Fusion methods for CNN-based automatic modulation classification. IEEE Access, 2019. 7: p. 66496-66504.
- [27] Wang, C., et al., Deep learning-based UAV detection in pulse-Doppler radar. IEEE Transactions on Geoscience and Remote Sensing, 2021. 60: p. 1-12.
- [28] Meng, F., et al., Automatic modulation classification: A deep learning enabled approach. IEEE Transactions on Vehicular Technology, 2018. 67(11): p. 10760-10772.
- [29] Chen, X., et al. Lfm signal detection and estimation based on deep convolutional neural network. in 2019 Asia-Pacific Signal and Information Processing Association Annual Summit and Conference (APSIPA ASC). 2019. IEEE.
- [30] Zhang, H., et al., A deep learning based algorithm with multi-level feature extraction for automatic modulation recognition. Wireless Networks, 2021. 27(7): p. 4665-4676.
- [31] Li, X., Z. Liu, and Z. Huang, Attention-based radar PRI modulation recognition with recurrent neural networks. IEEE Access, 2020. 8: p. 57426-57436.
- [32] 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.
- [33] Kauppi, J.-P. and K. Martikainen. An efficient set of features for pulse repetition interval modulation

داده‌های واقعی با لحاظ نمودن کلیه اثرات مخرب محک زده شد. نتایج توسط یک مطالعه مقایسه‌ای با مدل‌های پیشنهادی مورد ارزیابی قرار گرفت. نتایج نشان داد که *AlexNet-ELM* دارای عملکرد بهتری نسبت به ۲ روش دیگر در تشخیص و طبقه‌بندی انواع مدولاسیون PRI دارد. به‌عنوان موضوعات برای تحقیقات آینده می‌توان به موضوعاتی مانند شناسایی و طبقه‌بندی اهداف زیرآبی در سونارهای فعال و غیرفعال پیشنهاد و معرفی کرد.

مراجع

- [1] Wiley, R., ELINT: The interception and analysis of radar signals. 2006: Artech.
- [2] Ahmadi, M. and K. Mohamedpour. A new method for recognizing pulse repetition interval modulation. in 2009 International Conference on Signal Processing Systems. 2009. IEEE.
- [3] 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.
- [4] 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.
- [5] Zhang, D., et al. Distributed Radar PRI Sequence Classification using K-medoids Algorithm and Feedforward Neural Networks. in 2021 IEEE 5th Information Technology, Networking, Electronic and Automation Control Conference (ITNEC). 2021. IEEE.
- [6] Nguyen, H.P., H.Q. Nguyen, and D.T. Ngo. Deep Learning for Pulse Repetition Interval Classification. in ICPGRAM. 2019.
- [7] Hu, G. and Y. Liu. An efficient method of pulse repetition interval modulation recognition. in 2010 International Conference on Communications and Mobile Computing. 2010. IEEE.
- [8] Shi, Z., et al. Feature extraction for complicated radar PRI modulation modes based on auto-correlation function. in 2016 IEEE Advanced Information Management, Communicates, Electronic and Automation Control Conference (IMCEC). 2016. IEEE.
- [9] 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.
- [10] 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.
- [11] LeCun, Y., Y. Bengio, and G. Hinton, Deep learning. nature, 2015. 521(7553): p. 436-444.
- [12] Goodfellow, I., Y. Bengio, and A. Courville, Deep learning. 2016: MIT press.
- [13] Chen, X., et al., 3d object proposals for accurate object class detection. Advances in neural information processing systems, 2015. 28.
- [14] Hinton, G.E., S. Osindero, and Y.-W. Teh, A fast learning algorithm for deep belief nets. Neural computation, 2006. 18(7): p. 1527-1554.
- [15] Salakhutdinov, R. and H. Larochelle. Efficient learning of deep Boltzmann machines. in Proceedings of the thirteenth

- [43] Lu, S., S.-H. Wang, and Y.-D. Zhang, Detection of abnormal brain in MRI via improved AlexNet and ELM optimized by chaotic bat algorithm. *Neural Computing and Applications*, 2021. 33: p. 10799-10811.
- [44] Aslan, M., CNN based efficient approach for emotion recognition. *Journal of King Saud University-Computer and Information Sciences*, 2022. 34(9): p. 7335-7346.
- [45] Chen, H., et al., Multi-sensor data driven with PARAFAC-IPSO-PNN for identification of mechanical nonstationary multi-fault mode. *Machines*, 2022. 10(2): p. 155.
- [46] Kaur, R., R.K. Roul, and S. Batra, A hybrid deep learning CNN-ELM approach for parking space detection in Smart Cities. *Neural Computing and Applications*, 2023. 35(18): p. 13665-13683.
- [47] Khellal, A., H. Ma, and Q. Fei. Convolutional neural network features comparison between back-propagation and extreme learning machine. in 2018 37th Chinese Control Conference (CCC). 2018. IEEE.
- [48] Kannoja, S.P. and G. Jaiswal. Ensemble of hybrid CNN-ELM model for image classification. in 2018 5th international conference on signal processing and integrated networks (SPIN). 2018. IEEE.
- [49] Chen, H. and S. Li, Multi-sensor fusion by CWT-PARAFAC-IPSO-SVM for intelligent mechanical fault diagnosis. *Sensors*, 2022. 22(10): p. 3647.
- [50] 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.
- [51] Xie, X., et al., A simple Monte Carlo method for estimating the chance of a cyclone impact. *Natural Hazards*, 2021. 107: p. 2573-2582.
- [52] Wang, J., et al., Control of time delay force feedback teleoperation system with finite time convergence. *Frontiers in Neurorobotics*, 2022. 16.
- [53] Jia, D., et al., Lubrication-enhanced mechanisms of titanium alloy grinding using lecithin biolubricant. *Tribology International*, 2022. 169: p. 107461.
- recognition. in 2007 IET International Conference on Radar Systems. 2007. IET.
- [34] 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.
- [35] 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.
- [36] 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.
- [37] Liu, J., H. Meng, and X. Wang. A new pulse deinterleaving algorithm based on multiple hypothesis tracking. in 2009 International Radar Conference" Surveillance for a Safer World"(RADAR 2009). 2009. IEEE.
- [38] Gilanie, G., et al., Coronavirus (COVID-19) detection from chest radiology images using convolutional neural networks. *Biomedical Signal Processing and Control*, 2021. 66: p. 102490.
- [39] Li, B.-H., et al., A survey on blocking technology of entity resolution. *Journal of Computer Science and Technology*, 2020. 35: p. 769-793.
- [40] LeCun, Y., LeNet-5, convolutional neural networks. URL: <http://yann.lecun.com/exdb/lenet>, 2015. 20(5): p. 14.
- [41] Krizhevsky, A., I. Sutskever, and G.E. Hinton, Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 2012. 25.
- [42] Szegedy, C., et al. Going deeper with convolutions. in *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2015.