Scientific Journal of Radar
Vol. 12, No. 1, Spring and Summer2024, Serial No. 31, pp. 143- 159
ISSN: 2322-4347, E-ISSN: 2980-8979

A Hybrid Wavelet-Cumulant and Deep Learning Approach for Blind Separation of Radar and Communication Signals

P. Alizade, M. Shafiee*
*Assistant Professor, Malek Ashtar University of Technology (MUT), Tehran, Iran

(Received: 2024/05/01, Revised: 2024/07/31, Accepted: 2024/08/24, Published: 2024/10/01)

DOR: https://dor.isc.ac/dor/20.1001.1.23454024.1403.12.1.11.4

ABSTRACT

The increasing diversity of wireless systems and the proliferation of radar and communication signals have made accurate identification of signal type and modulation a fundamental requirement for intelligent sig-nal processing systems. Under such conditions, conventional approaches based on handcrafted classical features do not provide satisfactory performance when facing nonstationary signals in high-noise environ-ments. In this study, a hybrid framework that combines classical features with deep learning is proposed for blind discrimination and classification of radar and communication signals. In the proposed structure, a preprocessing stage based on the continuous wavelet transform (CWT) and the extraction of fourth- and sixth-order statistical measures is first performed to obtain an informative time-frequency representation and noise- robust statistical features. To enable a more thorough evaluation and analysis, the proposed framework is examined under three different scenarios using the extracted data and features to train two deep architectures, namely an improved LSTM model and a proposed ResNet model. In the first scenario, the networks are trained solely on the communication dataset RadioML. A to assess performance on communication signals; the improved LSTM model achieves an average accuracy of. %, and the Res-Net model achieves. %. In the second scenario, the networks are trained on the radar dataset DeepRadar to evaluate performance on radar signals; the average accuracy reaches. % for the improved LSTM model and. % for the proposed ResNet. In the third scenario, a combination of the radar and communication datasets is used, which causes a performance drop for the LSTM model, where-as the ResNet model maintains stable performance and attains an accuracy of . % at SNR = dB. Over-all, the results indicate that combining CWT-based time-frequency analysis with higher-order statistical features and deep architectures such as ResNet can provide an accurate and reliable framework for blind classification of radar and communication signals in noisy environments.

Keywords: Deep Learning, Blind Signal Classification, LSTM Network, ResNet Network, Continuous Wavelet Transform (CWT).

Cite this article: Alizade, P. & Shafiee Neyestanak, M., "A Hybrid Wavelet-Cumulant and Deep Learning Approach for Blind Separation of Radar and Communication Signals." *Radar*, vol. 12, no. 1, pp. 143- 159. 2024.

DOR: https://dor.isc.ac/dor/20.1001.1.23454024.1403.12.1.11.4

© The Author(s). retain the copyright and full publishing rights

Publisher: Imam Hossein University

Corresponding Author Email: Mshafiee@yahoo.com

"رادار"
سال دوازدهم، شماره 1، بهار و تابستان 1403، ص 143- 159
شاپا الکترونیکی: 4024 -2345 شاپا چاپی: 4032 -2345
علمی – پژوهشی

تفکیک کور سیگنال‌های راداری و مخابراتی با رویکرد ترکیبی موجک– کومولانت و یادگیری عمیق

پژمان علی‌زاده[1]، مرتضی شفیعی نیستانک[2*]

1– دانشجوی دکتری 2– استادیار، گروه مهندسی برق – مخابرات سیستم، دانشکده برق و رایانه، دانشگاه صنعتی مالک‌اشتر، تهران، ایران

(دریافت: 1403/02/11، بازنگری: 1403/04/13، پذیرش: 1403/05/10، انتشار: 1403/06/01)

DOR: https://dor.isc.ac/dor/20.1001.1.23454024.1403.12.1.11.4

چکیده

افزایش تنوع سامانه‌های بی‌سیم و گسترش سیگنال‌های راداری و مخابراتی، تشخیص دقیق نوع سیگنال و مدولاسیون آن را به یکی از نیازهای اساسی سامانه‌های پردازش سیگنال هوشمند تبدیل کرده است. در چنین شرایطی، روش‌های متداول مبتنی بر ویژگی‌های کلاسیک در مواجهه با سیگنال‌های غیرایستا با نویز زیاد عملکرد قابل‌قبولی ندارند. در این پژوهش، یک چارچوب ترکیبی مبتنی بر ویژگی‌های کلاسیک و یادگیری عمیق برای تفکیک و طبقه‌بندی کور سیگنال‌های راداری و مخابراتی ارائه شده است. در ساختار پیشنهادی، ابتدا مرحله‌ای از پیش‌پردازش مبتنی بر تبدیل موجک پیوسته (CWT) و استخراج آماره‌های آماری مرتبه‌ی چهارم و ششم انجام می‌شود تا نمایش زمان - فرکانس دقیق و ویژگی‌های آماری مقاوم در برابر نویز حاصل گردد. برای تحلیل دقیق‌تر نتایج، این پژوهش در سه سناریوی مختلف از داده‌ها و ویژگی‌های استخراج‌شده به‌منظور آموزش شبکه‌های پیشنهادی یعنی دو معماری LSTM بهبودیافته و ResNet پیشنهادی استفاده می‌کند. در سناریوی اول، شبکه‌ها صرفاً بر اساس مجموعه‌داده‌ی مخابراتی RadioML2018.01A آموزش دیدند تا عملکرد آن‌ها برای داده‌های مخابراتی مورد ارزیابی قرار گیرد که در نهایت مدل مبتنی بر LSTM بهبودیافته به میانگین دقت 79/39 درصد و مدل ResNet به 81/33 درصد دست یافتند. در سناریوی دوم، شبکه‌ها بر اساس مجموعه‌داده‌ی راداری DeepRadar2022 آموزش دیدند تا بتوان عملکرد مدل‌ها بر روی داده‌های راداری نیز ارزیابی گردد که نهایتاً میانگین دقت برای مدل مبتنی بر LSTM بهبودیافته 79/23 درصد و برای مدل ResNet پیشنهادی 83/05 درصد به دست آمد. در سناریوی سوم، ترکیبی از داده‌های مجموعه‌داده راداری و مخابراتی مورداستفاده قرار گرفت که این استفاده باعث شد که مدل LSTM دچار افت عملکرد شود؛ درحالی‌که مدل ResNet توانست با حفظ پایداری، در SNR = 2 dB به‌دقت 98/2 درصد برسد. به‌طورکلی، نتایج بیانگر آن است که ترکیب تحلیل زمان - فرکانس مبتنی بر CWT با ویژگی‌های آماری مرتبه بالا و معماری‌های عمیق مانند ResNet، می‌تواند چارچوبی دقیق و قابل‌اتکا برای طبقه‌بندی کور سیگنال‌های راداری و مخابراتی در محیط‌های نویزی فراهم آورد.

کلیدواژه‌ها: یادگیری عمیق، طبقه‌بندی کور سیگنال، شبکه‌ی LSTM، شبکه‌ی ResNet، تبدیل موجک پیوسته (CWT)

استناد: علی‌زاده، پژمان و شفیعی نیستانک، مرتضی، "تفکیک کور سیگنال‌های راداری و مخابراتی با رویکرد ترکیبی موجک - کمولانت و یادگیری عمیق." *رادار*، 12(1)، 143- 159، 1403.

DOR: https://dor.isc.ac/dor/20.1001.1.23454024.1403.12.1.11.4

© نویسنده(گان) حق نشر و حقوق کامل انتشار را برای خود محفوظ می‌دارند.

ناشر: دانشگاه جامع امام حسین(ع).

رایانامه نویسنده مسئول: Mshafiee@yahoo.com

1. مقدمه

در سال‌های اخیر، رشد هم‌زمان سامانه‌های مخابراتی و راداری و افزایش تنوع کاربردهای آن‌ها باعث شده است که الگوهای سیگنال در پهنای باندهای مختلف پیچیده‌تر و متنوع‌تر شوند. در چنین شرایطی، تشخیص نوع سیگنال و طبقه‌بندی دقیق آن (به‌ویژه در حضور نویز و تغییرات کانالی) به یکی از نیازهای کلیدی در پایش طیف و گیرنده‌های هوشمند تبدیل شده است.

بخش قابل‌توجهی از پژوهش‌های موجود، مسئله را در یک حوزه‌ی منفرد دنبال می‌کنند؛ برای مثال، یا تنها بر طبقه‌بندی مدولاسیون‌های مخابراتی تمرکز دارند یا صرفاً به شناسایی الگوهای راداری می‌پردازند. بااین‌حال، در بسیاری از سناریوهای عملی، گیرنده با مجموعه‌ای ناهمگون از سیگنال‌ها مواجه است و نمی‌توان از ابتدا فرض کرد که نوع سیگنال (راداری/مخابراتی) معلوم است؛ بنابراین، وجود یک چارچوب واحد که بتواند بدون پیش‌فرض‌های پیچیده، سیگنال‌های هر دو حوزه را در یک فضای تصمیم مشترک تحلیل و تفکیک کند، اهمیت ویژه‌ای دارد. از طرفی، رویکردهای کلاسیک نظیر تحلیل مؤلفه‌های مستقل[1] (ICA) و فاکتورگیری ماتریس غیرمنفی[2] (NMF) در مواجهه با سیگنال‌های غیرایستا (از جمله پالس‌های راداری) معمولاً دچار افت کارایی می‌شوند.

در سال‌های اخیر، یادگیری ماشین و یادگیری عمیق توجه بسیاری از پژوهشگران را به خود جلب کرده و نتایج قابل‌توجهی در حوزه‌ی شناسایی مدولاسیون و طبقه‌بندی سیگنال‌ها ارائه داده‌اند. بااین‌وجود، بخش عمده‌ای از تحقیقات موجود یا صرفاً متکی بر ویژگی‌های آماری طراحی‌شده‌ی دستی هستند و یا کاملاً بر شبکه‌های عصبی عمیق تکیه دارند. این اتکا، در عمل منجر به محدودیت در تعمیم‌پذیری و کاهش پایداری در سناریوهای واقعی می‌شود.

برای غلبه بر این محدودیت‌ها، این پژوهش یک چارچوب ترکیبی معرفی می‌کند که در آن، تبدیل موجک پیوسته[3] (CWT) و کومولانت‌های مرتبه بالا با دو شبکه‌ی حافظه طولانی کوتاه‌مدت[4] (LSTM) و شبکه‌ی باقیمانده[5] (ResNet) تلفیق می‌شوند تا تفکیک و طبقه‌بندی مقاوم سیگنال‌های راداری و مخابراتی میسر گردد. نوآوری اصلی این کار در ادغام توصیف‌گرهای آماری کلاسیک با مدل‌های نوین یادگیری نهفته است؛ بدین ترتیب که هم پیوند با ویژگی‌های کلاسیک حفظ می‌شود و هم در شرایط نویزی و به‌ویژه در نسبت سیگنال به نویز[6] (SNR) پایین عملکرد بالاتری حاصل می‌شود.

برای ارزیابی عملی این ایده، دو ساختار شبکه‌ی عمیق شامل مدل LSTM بهبودیافته و معماری ResNet پیشنهادی، طراحی شده‌اند و عملکرد آن‌ها در سه سناریوی مستقل بررسی می‌شود: در ابتدا طبقه‌بندی سیگنال‌های مخابراتی، سپس طبقه‌بندی سیگنال‌های راداری و در نهایت سناریوی ترکیبی که در آن هر سیگنال (چه راداری و چه مخابراتی) به‌صورت منفرد به مدل داده می‌شود و هدف، سنجش توانایی مدل در تشخیص صحیح کلاس در یک مجموعه‌ی بزرگ‌تر و متنوع‌تر است. این طراحی آزمایش، امکان بررسی تعمیم‌پذیری مدل در برابر افزایش تنوع کلاس‌ها و ناهمگونی داده را فراهم می‌سازد.

برای‌آنکه مسیر پژوهش از بیان مسئله تا تحلیل نتایج برای خواننده روشن، پیوسته و منسجم باشد، ساختار مقاله به این صورت تنظیم شده است که ابتدا در بخش دوم، مفاهیم، پیش‌نیازهای لازم و مبانی نظری شامل ویژگی‌های سیگنال‌های راداری و مخابراتی، اصول کومولانت‌ها و ویژگی‌های CWT مرور می‌شود. در بخش سوم، چارچوب پیشنهادی شامل مراحل پیش‌پردازش، استخراج ویژگی و طراحی دو مدل عمیق تشریح می‌گردد. بخش چهارم به معرفی سناریوهای آزمون و مجموعه‌داده‌های مورداستفاده اختصاص دارد. سپس در بخش پنجم نتایج شبیه‌سازی و مقایسه عملکرد روش پیشنهادی در سه محیط مستقل ارائه می‌شود. در نهایت، بخش ششم جمع‌بندی یافته‌ها و چشم‌اندازهای پژوهشی آینده را مطرح می‌کند. این پیوستگی در ارائه، امکان درک یکپارچه از روند توسعه روش پیشنهادی و ظرفیت آن در محیط هم‌زیستی طیفی را فراهم می‌سازد.

2. کارهای مرتبط

در سال‌های اخیر، ادبیات‌پژوهشی شاهد رشد چشمگیری در به‌کارگیری رویکردهای ترکیبی و مبتنی بر یادگیری برای طبقه‌بندی سیگنال‌ها و تشخیص مدولاسیون بوده است؛ جریانی که مرز میان مدل‌سازی آماری کلاسیک و معماری‌های یادگیری مدرن را به‌تدریج کم‌رنگ کرده است. از طرفی، پژوهش‌های جدید نشان می‌دهد که عملکرد مناسب در نویز پایین تنها با افزایش عمق شبکه تضمین نمی‌شود و انتخاب بازنمایی سیگنال و راهبرد استخراج ویژگی، نقش تعیین‌کننده‌ای دارد [30]. در همین راستا، برخی کارهای جدید از ترکیب تحلیل موجک و شبکه‌های کانولوشنی برای افزایش پایداری در برابر شرایط چالش‌برانگیز (نویز، فیدینگ و حتی دوپلر) استفاده کرده‌اند [31]. ازسوی‌دیگر، در حوزه‌ی سیگنال‌های راداری نیز

[1] Independent Component Analysis
[2] Non-negative Matrix Factorization
[3] Continuous Wavelet Transform
[4] Long Short Term Memory
[5] Residual Network
[6] Signal to Noise Ratio

چارچوب‌های نوین مبتنی بر تولید نگاشت زمان - فرکانس و معماری‌های باقیمانده و ترنسفورمری[7] برای بهبود دقت در SNRهای پایین پیشنهاد شده‌اند [32].

• Tian و همکاران، یک مقاله‌ی مروری جامع درباره‌ی طبقه‌بندی خودکار مدولاسیون مبتنی بر یادگیری عمیق ارائه کردند که در آن، سه محور اصلی «بازنمایی داده»، «ساختار مدل» و «تکنیک‌های منظم‌سازی و آموزش» به‌صورت نظام‌مند بررسی شده است. این مرور نشان می‌دهد که استفاده از شبکه‌های عمیق‌تر، الزاماً به عملکرد بهتر منجر نمی‌شود و در بسیاری از سناریوها، نوع نمایش سیگنال) مانند نمونه‌های I/Q، طیف یا نمایش‌های زمان - فرکانس (و چگونگی ادغام دانش پردازش سیگنال با مدل یادگیرنده نقش کلیدی دارد. همچنین محدودیت‌هایی مانند تعمیم‌پذیری، کارایی استنتاج و پیچیدگی مدل به‌عنوان چالش‌های پررنگ مطرح شده‌اند. مزیت این مرجع، جمع‌بندی ساخت‌یافته و ارائه‌ی نقشه‌ی روشن از روندهای اخیر است که به طور مستقیم از ایده‌ی مقاله‌ی حاضر (تأکید بر کیفیت بازنمایی CWT و ترکیب ویژگی‌های آماری مکمل) پشتیبانی می‌کند [30].

• Wu و همکاران، یک روش طبقه‌بندی مدولاسیون مخابراتی را با اتکا بر تحلیل موجک و شبکه‌ی کانولوشنی پیشنهاد داده‌اند که در آن، پیش‌پردازش موجکی (از جمله آستانه‌گذاری موجکی و تبدیل موجک پیوسته) برای تولید یک نگاشت دوبعدی فشرده به کار گرفته می‌شود و سپس این نگاشت به شبکه‌ی CNN داده می‌شود. تمرکز اصلی آن‌ها افزایش پایداری طبقه‌بندی در شرایط سخت مانند نویز، محوشدگی و حتی اثر دوپلر است. مزیت این کار، نشان‌دادن ارزش عملی «بازنمایی زمان - فرکانس موجکی» به‌عنوان ورودی شبکه است. بااین‌حال، این مرجع عمدتاً در حوزه‌ی سیگنال‌های مخابراتی بحث می‌کند [31].

• Tang و همکاران، به مسئله‌ی شناخت سیگنال‌های راداری «چندمولفه‌ای» در SNRهای پایین پرداخته‌اند و یک چارچوب انتها به انتها معرفی کرده‌اند که در آن، ماژول تولید نگاشت زمان - فرکانس به‌صورت یادگرفتنی طراحی می‌شود و سپس یک شبکه‌ی باقیمانده مبتنی بر ترنسفورمر برای استخراج ویژگی‌های محلی و سراسری از نگاشت حاصل به کار می‌رود. گزارش نتایج نشان می‌دهد روش آن‌ها در SNRهای پایین نیز به دقت‌های بالا نزدیک می‌شود و نسبت به چند الگوریتم مرجع برتری دارد. مزیت این مرجع، برجسته‌کردن نقش ادغام «بازنمایی زمان - فرکانس» با معماری‌های عمیق جدید در حوزه‌ی رادار است [32].

• Zhou و همکاران، با ترکیب مجموعه‌ای از ویژگی‌های آماری چند دامنه و یک چارچوب یادگیری جمعی، مدلی برای شناسایی مدولاسیون سیگنال‌های راداری و جمینگ ارائه کردند. این روش با استفاده از ویژگی‌هایی مانند آنتروپی، عامل‌های Hjorth و ابعاد فراکتالی، توانست عملکرد پایداری در شرایط نویزی نشان دهد. داده‌های مورداستفاده شامل مجموعه‌ای از 7 نوع سیگنال راداری/اختلال بودند. نقطه‌ی قوت پژوهش، بهره‌گیری از ترکیب ویژگی‌ها برای بهبود دقت بود، اما مدل تنها برای سیگنال‌های راداری طراحی شده و فاقد قابلیت تفکیک و شناسایی سیگنال‌های راداری و مخابراتی در محیط‌های هم‌زیست بود [1].

• Lakhanpal و همکاران، طی یک مطالعه‌ی مروری، به بررسی جامع کاربردهای یادگیری ماشین در پردازش سیگنال‌های راداری پرداختند. آن‌ها روش‌های گوناگون مانند ماشین‌های بردار پشتیبان[8] (SVM)، شبکه‌های عصبی و یادگیری عمیق را در وظایف آشکارسازی هدف، طبقه‌بندی مدولاسیون و تخمین عامل‌ها تحلیل کردند. داده‌های بررسی‌شده عمدتاً راداری بودند و هدف، ارائه‌ی نقشه‌ای از روند پژوهش در این حوزه بود [2].

• Lesieur و همکاران، مروری بر رویکردهای یادگیری ماشین در تفکیک پالس‌های راداری ارائه کردند. در این مقاله، الگوریتم‌هایی بررسی شده‌اند که با استخراج ویژگی‌های آماری و موجکی و ادغام آن‌ها با روش‌های یادگیری مانند خوشه‌بندی، شبکه‌های عصبی و یادگیری بدون نظارت، به جداسازی منابع راداری با مقادیر مختلف فاصله تکرار پالس[9] (PRI) می‌پردازند. داده‌ها صرفاً از حوزه‌ی راداری بودند. مزیت کار، تدوین یک طبقه‌بندی جامع از رویکردهای موجود بود [3].

• Ansari و همکاران، طی مقاله‌ای مروری، رویکردهای مبتنی بر هوش مصنوعی را برای جداسازی کور منابع بررسی کردند. پژوهش آن‌ها طیفی از روش‌های مبتنی بر ICA، NMF و مدل‌های یادگیری عمیق را بر اساس نوع داده و معماری مرور کرد. نوع سیگنال‌ها عمدتاً مخابراتی بوده و فقط در یک مورد مقاله‌ای با موضوعیت سیگنال‌های راداری را بررسی نموده است. مزیت مقاله، تبیین نقش یادگیری عمیق در رفع محدودیت‌های روش‌های سنتی و مقایسه‌ی دقیق روش‌های کلاسیک و نوین است [4].

• Clerico و همکاران، چارچوبی مبتنی بر شبکه‌ی بازگشتی LSTM برای طبقه‌بندی سیگنال‌های راداری و مخابراتی ارائه کردند. این مدل با تحلیل توالی داده‌های I/Q توانست وابستگی‌های زمانی میان الگوهای طیفی را به‌خوبی مدل کند و

[7] Transformer architecture

[8] Support Vector Machine
[9] Pulse Repetition Interval

برای آموزش از دو مجموعه‌داده معتبر DeepRadar2022 و RadioML2018.01A استفاده کرده است. به‌طورکلی این مدل دقت بالایی داشت؛ اما در آن هیچ استفاده‌ای از ویژگی‌های کلاسیک آماری و مخابراتی نشده که از نقاط ضعف آن بوده و تحلیل نتایج را دشوار می‌کند [5].

• Aref و همکاران، استفاده از رادیوهای شناختی عریض باند[10] (WACR) را برای شناسایی و طبقه‌بندی سیگنال‌های راداری و مخابراتی ارائه کرد. این سیستم با بهره‌گیری از ویژگی‌های طیفی و آماری ایستان‌چرخشی، قادر به تشخیص 10 نوع مدولاسیون دیجیتال و پالس‌های راداری است. مزیت اصلی روش، امکان تطبیق‌پذیری با شرایط طیفی متغیر بود، اما مدل در برابر تداخل‌های شدید و هم‌پوشانی‌های فرکانسی دچار افت عملکرد می‌شود [6].

• Zhang و همکاران، چارچوبی مبتنی بر یادگیری عمیق برای جداسازی کور سیگنال‌های همپوشان راداری و مخابراتی معرفی کردند. در این مدل، شبکه‌های عصبی کانولوشنی[11] (CNN) چند شاخه برای استخراج ویژگی‌های محلی در حوزه‌ی زمان و فرکانس به کار گرفته شد. داده‌ها شامل سیگنال‌های ترکیبی با ۱۲ نوع مدولاسیون مختلف از هر دو حوزه بودند. مدل توانست جداسازی موفقی در SNRهای پایین ارائه دهد، اما تفسیرپذیری و گسترش‌پذیری آن محدود بود [7].

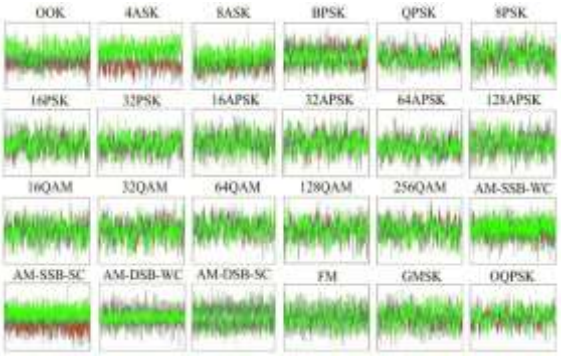
• Chen و همکاران، از شبکه‌های CNN عمیق برای شناسایی مدولاسیون سیگنال‌های همپوشان راداری و مخابراتی بهره بردند. داده‌های مورداستفاده شامل ترکیب ۱۰ نوع مدولاسیون مخابراتی و ۶ نوع سیگنال راداری بود. مدل آن‌ها با نمایش زمان - فرکانس آموزش دید و در نویز بالا عملکرد مطلوبی داشت، ولی از ویژگی‌های آماری مرتبه بالا بهره نمی‌برد و تفسیر نتایج مدل دشوار بود [8].

• L. Wang و همکاران، روشی ترکیبی مبتنی بر بسته‌های موجک و شبکه‌های عصبی عمیق برای طبقه‌بندی سیگنال‌ها در شرایط SNR پایین ارائه کردند. در این روش، نمایش‌های موجکی به‌عنوان ورودی به شبکه عصبی عمیق[12] (DNN) داده شدند تا ویژگی‌های مؤثر در نویز پایین استخراج شوند. داده‌های آزمایشی شامل ۸ نوع مدولاسیون دیجیتال مخابراتی بودند. نتایج دقت بالایی را در سطوح نویز بالا نشان داد، اما پیچیدگی محاسباتی زیاد و حساسیت به عامل‌های موجک از نقاط ضعف آن بود [9].

از مرور این پژوهش‌ها، می‌توان دریافت که بخش عمده‌ای از رویکردها یا صرفاً بر ویژگی‌های آماری متکی‌اند، یا کاملاً به مدل‌های یادگیری وابسته‌اند، ازاین‌رو فاقد ترکیبی هم‌افزا میان دو رویکرد هستند؛ ازاین‌رو این خلأ بنیادین به طور محسوس مشاهده می‌شود. از طرف دیگر، بیشتر مطالعات پیشین تنها یکی از دو حوزه‌ی راداری یا مخابراتی را مورد بررسی قرار داده‌اند و بدین ترتیب، نبود رویکردی جامع برای پوشش هم‌زمان هر دو زمینه به‌وضوح احساس می‌شود. بر همین اساس، این پژوهش درصدد است با معرفی یک چارچوب ترکیبی نوآورانه، شکاف‌های یادشده را پر کند. در این ساختار، سعی شده تجزیه زمان - فرکانس، ویژگی‌های آماری مرتبه بالا و مدل‌های یادگیری عمیق به‌گونه‌ای هم‌افزا تلفیق شوند، تا فرایند تفکیک و طبقه‌بندی کور سیگنال‌های راداری و مخابراتی، با پایداری و دقتی مناسب محقق گردد.

3. تفکیک کور سیگنال‌های راداری و مخابراتی

تفکیک و طبقه‌بندی سیگنال‌های راداری و مخابراتی صرفاً بر پایه‌ی مؤلفه‌های زمانی درون فاز و تربیعی[13] (I/Q) همواره از دشوارترین مسائل در حوزه‌ی پردازش سیگنال‌های هوشمند محسوب می‌شود. شباهت شدید در ساختارهای زمانی، تغییرپذیری زیاد در شکل موج‌ها و حضور نویز و تداخل باعث می‌شود تشخیص بصری یا تحلیل در یک مقیاس منفرد، قادر به تمایز دقیق میان این دو نوع سیگنال نباشد.



شکل (1). نمای زمان - دامنه‌ی ۲۴ نوع سیگنال مخابراتی

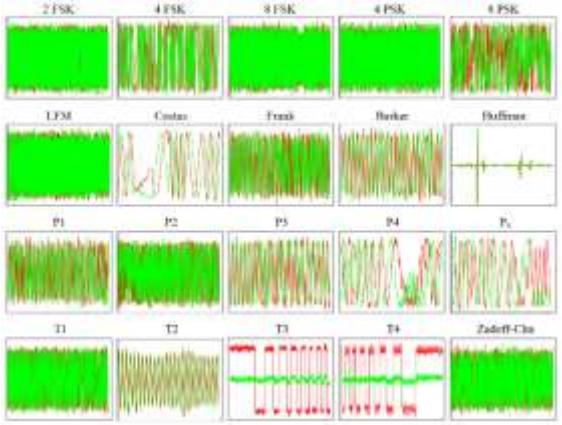
در شکل (1) نمای زمان - دامنه‌ی مؤلفه‌های درون فاز و تربیعی سیگنال‌های مجموعه‌داده عمومی RadioML2018.01A[14] در نسبت سیگنال به نویز dB ۰ نمایش‌داده‌شده است.

در شکل (2) نمای زمان - دامنه‌ی مؤلفه‌های درون فاز و تربیعی سیگنال‌های موجود در مجموعه‌داده عمومی DeepRadar2022[15] در نسبت سیگنال به نویز dB 20 نمایش‌داده‌شده است. همان‌گونه که در شکل‌های ارائه‌شده مشاهده می‌شود، الگوهای

[10] Wideband Autonomous Cognitive Radios
[11] Convolutional Neural Network
[12] Deep Neural Networks

[13] In-phase/Quadrature
[14] https://www.kaggle.com/datasets/pinxau1000/radioml2018/data
[15] https://www.kaggle.com/datasets/khilian/deepradar

زمانی سیگنال‌های راداری و مخابراتی به‌قدری مشابه‌اند که تمایز بین برخی از آن‌ها حتی در SNRهای بالا نیز تنها بر اساس ویژگی‌های ساده یا تک مقیاسی تقریباً ناممکن است.



شکل (2). نمای زمان - دامنه‌ی ۲0 نوع سیگنال راداری

بنابراین، چنانچه شبکه‌ی یادگیری پیشنهادی بتواند ویژگی‌های چند مقیاسی را از سیگنال استخراج کرده و آن‌ها را در سطوح مختلف با یکدیگر تلفیق نماید، در کنار بهره‌گیری از آماره‌های آماری مناسب برای افزایش قابلیت تفکیک، می‌تواند الگوهای متمایزکننده‌ی میان سیگنال‌های راداری و مخابراتی را بادقت بسیار بالاتری بیاموزد. چنین رویکردی نه‌تنها در نسبت‌های پایین سیگنال به نویز موجب بهبود فرایند استخراج ویژگی‌ها می‌شود، بلکه به طور چشمگیری عملکرد نهایی شبکه را در طبقه‌بندی دقیق سیگنال‌ها ارتقا می‌دهد. چارچوب ارائه‌شده در این مقاله با نگاهی نظام‌مند و لایه به لایه طراحی شده است تا بتواند فرایند تفکیک و طبقه‌بندی کور سیگنال‌های راداری و مخابراتی را با دقتی بالا محقق سازد.

4. مدل سیگنال و مجموعه‌داده

در این بخش ابتدا مدل سیگنال‌های مورداستفاده بیان می‌گردد و پس از آن دو مجموعه‌داده عمومی مورداستفاده به‌منظور اعتبارسنجی مدل‌های پیشنهادی با تمام ریز مشخصات آن‌ها معرفی می‌شوند.

4-1. مدل سیگنال

برای ارزیابی عملکرد چارچوب ترکیبی پیشنهادی، از مجموعه‌ای شامل سیگنال‌های مخابراتی و راداری استفاده شده است. مدل عمومی سیگنال دریافتی به‌صورت رابطه زیر تعریف می‌گردد [20]:

$$x(t) = A.s(t) + n(t), n(t) \sim N\left(0, \sigma^2\right) \qquad \text{رابطه (1)}$$

در این مدل، s(t) یک سیگنال نرمال‌سازی شده با توان واحد است، A ضریب مقیاس توان سیگنال را نشان می‌دهد و n(t) نویز افزوده‌ی گاوسی مختلط با میانگین صفر و واریانس σ^2 است؛ بنابراین توان سیگنال از رابطه‌ی زیر محاسبه می‌گردد [20]:

$$SNR(dB) = 10\log_{10}\left(\frac{A^2}{\sigma^2}\right) \qquad \text{رابطه (2)}$$

تمامی سیگنال‌ها دارای ابعاد 2×1024 هستند که به ترتیب مؤلفه‌های درونی و متعامد را نمایش می‌دهند. ازآنجاکه اکثر شبکه‌ها نیازمند ورودی‌هایی با اندازه‌ی ثابت هستند، از مجموعه‌داده‌های RadioML2018.01A و DeepRadar2022 تمامی توالی‌ها با طول یکسان نمونه‌برداری شده و استفاده می‌شوند تا قابلیت پردازش مؤثر فراهم گردد.

4-2 مجموعه‌داده‌ها

برای اعتبارسنجی مدل، از دو مجموعه‌داده‌ی عمومی شامل RadioML2018.01A و DeepRadar2022 استفاده شده است. در ادامه مشخصات هر یک تشریح می‌شود.

4-2-1. مجموعه‌داده‌ی DeepRadar2022

جدول (1). عامل‌های مجموعه‌داده‌ی DeepRadar2022 [5]

نوع مدولاسیون	عامل‌ها	مقدار
مشترک	f_S اندازه ورودی SNR f_C	100 MHz 1024 sample -12:2:20 dB U(-f_S/4, f_S/4)
NM	-	-
LFM	BW	U(f_S/20, f_S/4)
PSK	Order V_S	{2, 4, 8} {2, 5, 10, 15, 20}
Barker	L_C V_S	{5, 7, 11, 13} {2, 5, 10, 15, 20}
Frank, P1, Px	M V_S	{16, 25, 36, 49, 64} {7, 10, 15, 20}
P2	M V_S	{16, 26, 64} {7, 10, 15, 20}
P3, P4	M V_S	{16, 25, 36, 49, 64} {7, 10, 15, 20}
Zadoff-Chu	M r V_S	{16, 25, 36, 49, 64} {11, 13} {7,10,15,20}
Huffman	M V_S S	{16, 25, 36, 49, 64} {7, 10, 15, 20} {-63, -60, -56} dB
T1, T2	N_g PW PS	{4, 5, 6} U(256, 1024) samples 2
T3, T4	BW PW PS	U(f/20, f/4) U(256, 1024) samples 2
FSK	Order V_S Δf	{2, 4, 8} {1, 2, 5, 10, 15} V_S
Costas	M V_S Δf	(3, 4, 5, 6} {1, 2, 5, 10, 15} V_S
Noise	δ	1

مجموعه‌داده‌ی DeepRadar2022 شامل توالی‌های زمانی سیگنال‌های راداری با ۲۳ نوع مدولاسیون مختلف است که مشخصات آن‌ها در جدول ۱ ارائه شده است.

عامل‌های کلیدی جدول عبارت‌اند از: فرکانس نمونه‌برداری (f_s)، فرکانس حامل (f)، پهنای پالس (PW)، پهنای باند (BW)، نرخ سمبل (V_S) برحسب $Msymb/s$، طول کد (M)، دامنه‌ی لوب‌های فرعی (S)، تعداد قطعات (N_g) و حالت‌های فازی (PS). همچنین نماد $U(\cdot)$ نشان‌دهنده توزیع یکنواخت است. برای حفظ سازگاری در ورودی شبکه، تمامی توالی‌ها به طول ثابت ۱۰۲۴ نمونه، بازنمونه‌برداری شدند. ۴۶۹۲۰۰ سیگنال برای آموزش، ۱۵۶۴۰۰ سیگنال برای آزمون و ۱۵۶۴۰۰ سیگنال اعتبارسنجی تولید گردید که در مجموع ۷۸۲۰۰۰ سیگنال را شامل می‌شود.

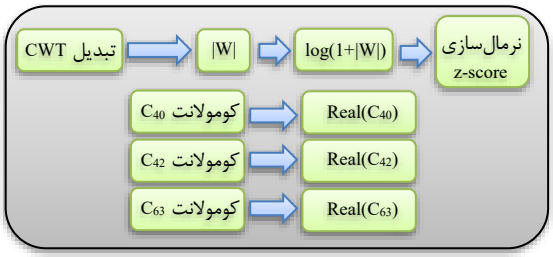
4-2-2 مجموعه‌داده‌ی RadioML2018.01A

این مجموعه‌داده شامل 2555904 نمونه سیگنال با دامنه‌ی SNR از 20- dB تا 30+ dB است. داده‌ها با استفاده از نرم‌افزار گنو - رادیو[16] تولید شده و شامل هر دو نوع سیگنال مصنوعی و واقعی (OTA) است و متشکل از ۲۴ نوع مدولاسیون مختلف دیجیتال و آنالوگ است، از جمله: OOK، ASK(4-8)، 2-)PSK(32، APSK(16-128)، QAM(16-256)، AM-SSB، AM-DSB، FM، GMSK و OQPSK.

محدودیت اصلی این مجموعه‌داده در آن است که نوع مبدأ هر سیگنال (شبیه‌سازی یا ذخیره عملی) به‌صورت مشخص جدا نشده است که در ارزیابی‌های یادگیری ترکیبی باید موردتوجه قرار گیرد. ازآنجاکه برچسب مبدأ نمونه‌ها در RadioML2018.01A ارائه نشده است، امکان تفکیک صریح داده‌ها به دو زیرمجموعه‌ی «شبیه‌سازی‌شده» و «OTA» در مرحله‌ی آموزش وجود ندارد؛ بنابراین، در سناریوهای یادگیری ترکیبی، داده‌های این مجموعه‌داده بدون تفکیک مبدأ و صرفاً بر اساس کلاس مدولاسیون و سطح SNR به‌صورت توزیع یکنواخت بین مجموعه‌های آموزش، اعتبارسنجی و آزمون تقسیم شده‌اند تا هر سه بخش، به طور ضمنی شامل ترکیبی از نمونه‌های با مبدأهای مختلف باشند. براین‌اساس، نتایج گزارش‌شده برای یادگیری ترکیبی، عملکرد مدل را در یک وضعیت واقع‌گرایانه‌ی ناهمگن (با تغییرات ناشی از تفاوت مبدأ) منعکس می‌کند و تفسیر نتایج نیز با همین ملاحظه انجام شده است.

5. پیش‌پردازش پیشنهادی

در نخستین گام از فرایند تحلیل، داده‌های مجموعه‌داده وارد بخش پیش‌پردازش می‌شوند. همان‌طور که در شکل ۳ به‌صورت شماتیک نشان‌داده‌شده است، مرحله‌ی پیش‌پردازش شامل دو بخش اصلی است. بخش اول مسئول محاسبه‌ی تبدیل موجک سیگنال ورودی است و بخش دوم به استخراج ویژگی‌های آماری سیگنال اختصاص دارد.



شکل (3). شماتیک پیش‌پردازش پیشنهادی مبتنی بر تبدیل موجک و کومولانت‌های C_{40}، C_{42} و C_{63}

ورودی این قسمت‌ها، سیگنال‌های خام مختلط هستند که هر یک دارای ابعاد 2×1024 هستند، به‌عبارت‌دیگر، هر سیگنال شامل دو مؤلفه حقیقی و موهومی با ۱۰۲۴ نمونه در طول زمان است. به‌منظور بررسی رفتار زمانی و طیفی این سیگنال‌ها، از تبدیل موجک پیوسته (CWT) با موجک مادر CMOR و تعداد ۱۲۸ مقیاس و برای بررسی رفتار آماری سیگنال‌ها از کومولانت‌های مرتبه چهارم و مرتبه ششم استفاده می‌کنیم.

پس از اعمال تبدیل موجک بر روی داده‌های I/Q ورودی با ابعاد 2×1024، ابعاد داده‌ها به 128×2×1024 تغییر می‌کند؛ به این معنا که برای هر یک از ۱۲۸ مقیاس، ۱۰۲۴ ضریب مختلط تحت تبدیل موجک، تولید می‌شود.

در ادامه، برای کاهش ابعاد ابتدا مقدار شدت انرژی هر سیگنال محاسبه شده و به‌منظور افزایش پایداری آماری و کاهش تغییرات ناگهانی در ضرایب موجک، می‌توان از تبدیل لگاریتمی و نرمال‌سازی Z-Score استفاده شده است تا بدین صورت، نگاشت زمان - فرکانس آماده استفاده به‌عنوان ورودی شبکه یادگیری گردد.

5-1. استخراج ویژگی‌ها

سیگنال‌های دریافتی به‌منظور آشکارسازی ساختارهای آماری، زمانی و طیفی‌شان مورد تحلیل چندبعدی قرار می‌گیرند.

تبدیل موجک پیوسته (CWT): سیگنال‌های راداری و مخابراتی معمولاً نا ایستا هستند. ازآنجاکه FFT تنها یک نمای کلی از فرکانس‌ها بدون درنظرگرفتن عامل زمان را نمایش می‌دهد، برای برآورده‌سازی اهداف پژوهش مناسب به نظر نمی‌رسد، اما تبدیلاتی همچون CWT توانایی نمایش زمان فعال‌شدن فرکانس

[16] GNU_Radio

و تناوب‌های آن را دارا بوده و کارایی کافی برای رسیدن به اهداف این پژوهش را برای ما ایجاد می‌کند. این فرایند، سیگنال‌های راداری و مخابراتی را به نگاشتی در حوزه‌ی زمان - فرکانس تبدیل می‌کند تا ویژگی‌های گذرا مانند پالس‌های راداری و همچنین ساختارهای تکرارشونده‌ی طیفی به‌وضوح نمایان گردند. در این پردازش، به‌منظور استخراج هم‌زمان اطلاعات دامنه و فاز، از تابع موجک مادر CMOR استفاده می‌شود. فرمول عمومی تبدیل موجک پیوسته برای سیگنال x(t) به‌صورت زیر تعریف می‌شود [21]:

$$W(s,t)=\int_{-\infty}^{+\infty} x(\tau)\psi^{*}\left(\frac{\tau-t}{s}\right)d\tau \qquad \text{رابطه (3)}$$

دراین‌رابطه، s بیانگر میزان مقیاس موردنظر، t نشان‌دهنده زمان و $\psi(\cdot)$ موجک مادر مورداستفاده است که می‌توان رابطه آن را در زیر مشاهده نمود [22]:

$$\psi(t)=\frac{1}{\sqrt[4]{\pi}}e^{j2\pi f_0 t}e^{-t^2/2} \qquad \text{رابطه (4)}$$

$|W(s,t)|$ مقدار شدت انرژی سیگنال را در مقیاس s و زمان t نشان می‌دهد و از رابطه زیر به دست می‌آید [22]:

$$|W(s,t)|=\sqrt{(R\{W(s,t)\})^2+(I\{W(s,t)\})^2} \qquad \text{رابطه (5)}$$

که در آن $R\{.\}$ بخش حقیقی و $I\{.\}$ بخش موهومی سیگنال را نشان می‌دهد. همچنین تبدیل لگاریتمی و نرمال‌سازی Z-Score طبق رابطه زیر برای ضرایب اعمال می‌گردد [23]:

$$X(s,t)=\text{Z-Score}\left(\log(1+|W(s,t)|)\right) \qquad \text{رابطه (6)}$$

کومولانت‌های مرتبه بالا (HOCs): افزون بر ویژگی‌های مبتنی بر موجک، به‌منظور توصیف رفتار آماری و غیرگاوسی سیگنال‌ها، سه کومولانت آماری مرتبه بالا نیز محاسبه می‌گردند. استفاده از آماره‌های مرتبه بالا نظیر کومولانت‌های مرتبه چهارم (C_{40} و C_{42}) و مرتبه ششم (C_{63}) به دلیل حساسیت بالای آن‌ها به ساختار آماری سیگنال، نقش مؤثری در تمایز میان سیگنال‌های راداری و مخابراتی دارند. این ویژگی‌ها نسبت به نویز گاوسی نا وابسته‌اند و قادرند اطلاعاتی درباره‌ی غیرگاوسی بودن، همبستگی مرتبه بالا و الگوهای درونی سیگنال را آشکار سازند؛ عواملی که در سیگنال‌های راداری و مخابراتی تفاوت‌های بنیادینی دارند. به‌ویژه، C_{40} و C_{42} در تشخیص نوع مدولاسیون و شناسایی ساختار طیفی مفید هستند، درحالی‌که C_{63} توانایی تفکیک دقیق‌تر در شرایط نویز بالا و شباهت ساختاری برخی کلاس‌ها را فراهم می‌کند. در نتیجه، ترکیب این کومولانت‌ها مجموعه‌ای مقاوم و غنی از ویژگی‌ها را برای آموزش شبکه‌های عمیق فراهم می‌آورد. این کومولانت‌ها به ترتیب طبق روابط زیر محاسبه می‌شوند [18] و [24]:

$$C_{40}=E\{x^4[n]\}-3\left(E\{x^2[n]\}\right)^2 \qquad \text{رابطه (7)}$$

$$C_{42}=E\{|x[n]|^4\}-\left|E\{x^2[n]\}\right|^2-2\left(E\{|x[n]|^2\}\right)^2 \qquad \text{رابطه (8)}$$

$$C_{63}=E\{x^6[n]\}-15E\{x^4[n]\}E\{x^2[n]\}+30\left(E\{x^2[n]\}\right)^3 \qquad \text{رابطه (9)}$$

در این روابط، $E\{\cdot\}$ نشان‌دهنده امید ریاضی است و $|x[n]|^2$ نیز از رابطه زیر به دست می‌آید [24]:

$$|x[n]|^2=x[n]\cdot x^{*}[n] \qquad \text{رابطه (10)}$$

به‌طورکلی، کومولانت‌های مرتبه بالا برای فرایندهای گاوسی در مراتب بالاتر از دوم به مقدار صفر میل می‌کنند؛ ازاین‌رو این ویژگی‌ها عمدتاً حامل مؤلفه‌های غیرگاوسی و همبستگی‌های مرتبه بالای سیگنال بوده و می‌توانند به‌عنوان شاخص‌های مقاوم‌تری در برابر نویزهای گاوسی و اغتشاشات عمل کنند و در کنار نمایش زمان - فرکانس مبتنی بر تبدیل موجک، اطلاعات مکملی از ساختار آماری سیگنال در اختیار مدل قرار دهند. باوجود آن که به‌کارگیری مراتب بسیار بالا، می‌تواند با افزایش واریانس و مقدار عددی کومولانت، ایجاد خطاهای شدید کند، در این پژوهش صرفاً از کومولانت‌های مرتبه چهارم و ششم استفاده شده است. همچنین با نرمال‌سازی توان سیگنال ورودی، رشد مقادیر ناشی از مرتبه کاهش‌یافته و مقایسه‌پذیری ویژگی‌ها بین نمونه‌ها حفظ می‌شود. در نهایت، بخش حقیقی هر سه کومولانت استخراج‌شده، به‌صورت ویژگی‌های عددی مکمل در کنار داده‌های مبتنی بر CWT به‌عنوان ورودی شبکه‌ی یادگیری عمیق به کار گرفته می‌شوند.

5-2. ترکیب ویژگی‌ها

در مرحله‌ی بعد، ویژگی‌های استخراج‌شده از دو حوزه‌ی زمانی - فرکانسی و آماری را با یکدیگر ترکیب می‌کنیم تا نمایی کامل‌تر از ساختار و رفتار سیگنال‌ها ایجاد شود.

به دلیل استفاده از دو معماری یادگیری عمیق LSTM و ResNet در مدل‌های پیشنهادی، ادغام ویژگی‌ها متناسب با ساختار هر شبکه انجام می‌گیرد؛ بدین صورت که در مدل LSTM، کومولانت‌ها به‌عنوان ویژگی‌های آماری مستقیماً به خروجی شبکه متصل می‌شوند، درحالی‌که در مدل ResNet این ویژگی‌ها ابتدا توسط یک پرسپترون چندلایه ساده نگاشت‌یافته و سپس با بردار ویژگی‌های استخراج‌شده از بخش کانولوشنی ترکیب می‌گردند.

بدین ترتیب این پیش‌پردازش، امکان بهره‌گیری هم‌زمان از وضوح زمانی و فرکانسی بالا و ویژگی‌های آماری مناسب را فراهم می‌کند، بدان معنا که برخلاف روش‌هایی همچون تبدیل فوریه که صرفاً اطلاعات فرکانسی سیگنال را بدون در نظرداشتن زمان وقوع هر فرکانس به ما می‌دهند؛ در این روش به کمک تبدیل موجک، اطلاعات مربوط به زمان وقوع هر فرکانس و شدت آن را مورداستفاده قرار می‌دهیم. البته شایان‌ذکر است که روش‌های دیگری همچون تبدیل فوریه زمان کوتاه[17] (STFT) نیز به همین منظور می‌تواند مورداستفاده قرار گیرد. در نهایت، داده‌ها پس از پیش‌پردازش و ادغام ویژگی‌ها، وارد شبکه‌های پیشنهادی می‌شوند تا فرایند یادگیری برای تفکیک و طبقه‌بندی سیگنال‌های راداری و مخابراتی انجام گیرد.

معماری‌های طراحی‌شده باهدف رفع محدودیت‌های روش‌های سنتی مانند ICA و NMF ارائه شده‌اند و انتظار می‌رود چارچوب‌های پیشنهادی در دقت طبقه‌بندی در سطوح مختلف SNR عملکردی فراتر از مدل‌های کلاسیک ارائه دهند؛ درعین‌حال تلاش شد چارچوب پیشنهادی از منظر پیچیدگی محاسباتی و قابلیت پیاده‌سازی عملی کارآمد باقی بماند و برای کاربردهای برخط و یا نزدیک به بلادرنگ، تاحدامکان سبک و قابل‌اجرا باشد.

ازسوی‌دیگر، ازآنجاکه زمان اجرا در بسیاری از روش‌های مرجع به‌صورت استاندارد و قابل بازتولید گزارش نشده و دسترسی به مقادیر یکسان برای همه‌ی روش‌ها فراهم نیست، در این پژوهش به‌منظور ارزیابی و مقایسه‌ی منصفانه، به‌جای اتکا به زمان اجرا، از تحلیل پیچیدگی محاسباتی به‌عنوان معیار جایگزین استفاده شده است. براین‌اساس، شاخص‌هایی نظیر تعداد عامل‌های قابل‌آموزش شبکه به‌عنوان تقریب مناسبی از بار محاسباتی در نظر گرفته شده‌اند.

6. شبکه پیشنهادی

در این مقاله دو مدل شبکه متفاوت جهت یادگیری پیشنهاد داده‌ایم. مدل اول، شبکه‌ای بازگشتی مبتنی بر LSTM است که ایده اصلی آن از شبکه استفاده شده در مرجع [5] الهام گرفته‌شده؛ با این تفاوت که ورودی شبکه در مدل پیشنهادی، پیش‌پردازشی متفاوت جهت بهبود عملکرد مدل دارد. مدل پیشنهادی دوم نیز شبکه‌ای مبتنی بر ResNet با ۶ پشته باقیمانده و ۳۲ لایه یادگیرنده است.

هر دو مدل پیشنهادی باهدف استخراج بازنمایی‌های متمایزکننده از سیگنال و افزایش پایداری تصمیم‌گیری در حضور نویز طراحی شده‌اند. در این چارچوب، پیش‌پردازش و استخراج ویژگی به‌گونه‌ای انجام می‌شود که هم اطلاعات زمان - فرکانس و هم ویژگی‌های آماری مکمل در اختیار شبکه قرار گیرد و وابستگی مدل صرفاً به یک نوع ویژگی کاهش یابد. ایده‌ی اصلی این رویکرد، ترکیب هدفمند دانش پردازش سیگنال با توان یادگیری شبکه‌های عمیق است تا تفکیک‌پذیری کلاس‌ها در سناریوهای چالش‌برانگیز تقویت شود. همچنین طراحی دو ساختار متفاوت امکان مقایسه‌ی رفتار مدل‌ها را در مواجهه با تنوع سیگنال‌ها و شرایط مختلف داده فراهم می‌کند.

6-1. مدل پیشنهادی مبتنی بر LSTM بهبودیافته

شبکه‌های بازگشتی RNN از جمله مدل‌های پرکاربرد در پردازش داده‌های ترتیبی هستند، اما در توالی‌های زمانی بلند با مشکل محوشدن گرادیان مواجه می‌شوند و در نتیجه توانایی حفظ وابستگی‌های بلندمدت را از دست می‌دهند. در واقع این مشکل زمانی رخ می‌دهد که گرادیان‌هایی که از لایه‌های انتهایی به سمت لایه‌های ابتدایی می‌آیند در اثر ضرب‌های متوالی رفته‌رفته کوچک شده و آن‌قدر ادامه می‌یابد که فرایند آموزش مختل شده و عملاً متوقف می‌گردد، زیرا مقادیر گرادیان‌ها آن‌قدر ناچیز شده که تأثیری در وزن‌های شبکه صورت نمی‌دهند. برای غلبه بر این محدودیت، شبکه‌های حافظه‌دار بلندمدت معرفی شدند. ساختار درونی LSTM شامل چند دروازه‌ی کنترلی است که جریان اطلاعات را در طول زمان تنظیم می‌کند. این دروازه‌ها عبارت‌اند از: دروازه‌ی فراموشی که مسئول حذف اطلاعات غیرضروری از حالت قبلی است، دروازه‌ی ورودی یا به‌روزرسانی که اطلاعات جدید را وارد سلول حافظه می‌کند، دروازه‌ی خروجی که میزان تأثیر حافظه بر خروجی فعلی را کنترل می‌نماید، و نهایتاً سلول حافظه که اطلاعات بلندمدت را ذخیره کرده و در گذر زمان منتقل می‌کند.

عملکرد هر سلول LSTM با روابط زیر توصیف می‌شود [5] و [25]:

$$\tilde{c}^{\langle t\rangle} = \tanh\left(W_c \cdot \left[a^{\langle t-1\rangle}, x^{\langle t\rangle}\right] + b_c\right) \quad \text{رابطه (11)}$$

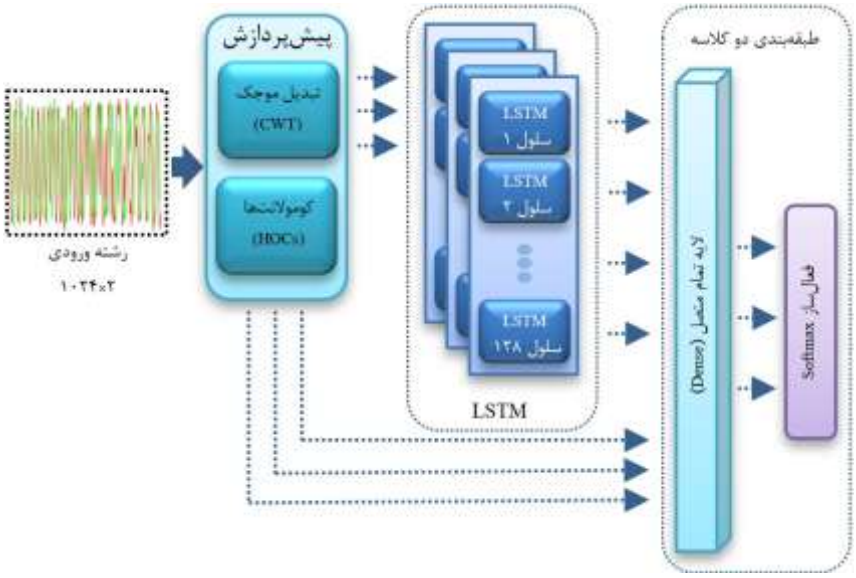
$$f^{\langle t\rangle} = \sigma\left(W_f \cdot \left[a^{\langle t-1\rangle}, x^{\langle t\rangle}\right] + b_f\right) \quad \text{رابطه (12)}$$

$$i^{\langle t\rangle} = \sigma\left(W_i \cdot \left[a^{\langle t-1\rangle}, x^{\langle t\rangle}\right] + b_i\right) \quad \text{رابطه (13)}$$

$$o^{\langle t\rangle} = \sigma\left(W_o \cdot \left[a^{\langle t-1\rangle}, x^{\langle t\rangle}\right] + b_o\right) \quad \text{رابطه (14)}$$

$$c^{\langle t\rangle} = f^{\langle t\rangle} * \tilde{c}^{\langle t\rangle} + i^{\langle t\rangle} * c^{\langle t-1\rangle} \quad \text{رابطه (15)}$$

[17] Short Time Fourier Transform



شکل (4). شماتیک کلی مدل پیشنهادی مبتنی بر LSTM بهبودیافته شامل پیش‌پردازش، سه‌لایه LSTM و یک‌لایه تمام متصل

رابطه (16)
$$a^{\langle t\rangle} = o^{\langle t\rangle} * \tanh c^{\langle t\rangle}$$

در این روابط $W_{c,f,i,o}$ نشانگر ماتریس‌های عامل و $b_{c,f,i,o}$ برای بایاس‌ها و $a^{<t>}$، $x^{<t>}$ و $c^{<t>}$ به ترتیب برای مقادیر سلول‌های فعال‌سازی، ورودی و حافظه در زمان t هستند.

همان‌طور که در شکل (4) قابل‌مشاهده است، برای طبقه‌بندی سیگنال‌ها، مدلی مبتنی بر سه‌لایه‌ی پیاپی LSTM طراحی شده که هر لایه شامل ۱۲۸ واحد حافظه است. ورودی شبکه، دنباله‌ی نمونه‌های سیگنال به‌صورت (1024×2) (دو مؤلفه‌ی I/Q) است که پس از اعمال پیش‌پردازش پیشنهادی وارد مدل می‌شود؛ در دو لایه‌ی نخست، خروجی به‌صورت دنباله‌ی کامل، (1024×128) به لایه‌ی بعدی منتقل می‌گردد تا شبکه بتواند وابستگی‌های زمانی را در کل پنجره مشاهده، حفظ کند. درحالی‌که لایه‌ی سوم، هر سلول تنها یک مقدار را به لایه‌ی خروجی می‌فرستد تا این بردار ویژگی فشرده مبنای تصمیم‌گیری قرار گیرد. در پیاده‌سازی این شبکه، تابع فعال‌سازی داخلی LSTM از نوع tanh در نظر گرفته شده و برای افزایش پایداری آموزش و بازتولیدپذیری نتایج، وزن‌های لایه‌ها با روش مقداردهی اولیه‌ی He-Normal مقداردهی شده‌اند.

در مرحله‌ی تصمیم‌گیری، 128 خروجی شبکه LSTM به همراه سه کومولانت محاسبه‌شده وارد یک‌لایه‌ی تماماً متصل (Dense) با تابع فعال‌سازی Softmax می‌شوند که وظیفه‌ی تفکیک و تصمیم‌گیری نهایی میان کلاس‌های راداری و مخابراتی را بر عهده دارد. تعداد کل عامل‌های قابل‌آموزش شبکه در حدود ۳۳۰ هزار عامل برآورد شده است؛ همچنین برای جلوگیری از گرفتار شدن در کمینه‌های محلی فرایند آموزش مدل با بهینه‌ساز Adamانجام شد و نرخ یادگیری به‌صورت چرخه‌ای باسیاست مثلثی تنظیم گردید؛ به این معنا که نرخ یادگیری در طول آموزش ثابت نیست و در یک بازه‌ی از پیش تعریف‌شده بین η_{min} و η_{max} به طور دوره‌ای نوسان می‌کند (در این پژوهش η_{max}= 0/001 در نظر گرفته شده است). در ابتدای هر چرخه، نرخ یادگیری از η_{min} شروع می‌شود و در هر تکرار آموزشی به‌صورت خطی افزایش می‌یابد تا در میانه‌ی چرخه به η_{max} برسد؛ سپس در نیمه‌ی دوم همان چرخه، با همان شیب و به‌صورت خطی کاهش داده می‌شود تا دوباره به η_{min} بازگردد. پس از پایان هر چرخه، چرخه‌ی بعدی با همان الگوی افزایش - کاهش تکرار می‌شود. در هر مرحله‌ی به‌روزرسانی عامل‌های شبکه، ابتدا نرخ یادگیری متناظر با موقعیت فعلی در چرخه تعیین می‌گردد و سپس Adam با همان مقدار نرخ یادگیری، گرادیان‌ها را اعمال می‌کند. استفاده از این راهبرد باعث می‌شود مدل در فاز افزایش نرخ یادگیری، از کمینه‌های محلی با سهولت بیشتری عبور کند و در فاز کاهش نرخ یادگیری، به همگرایی پایدارتر نزدیک شود.

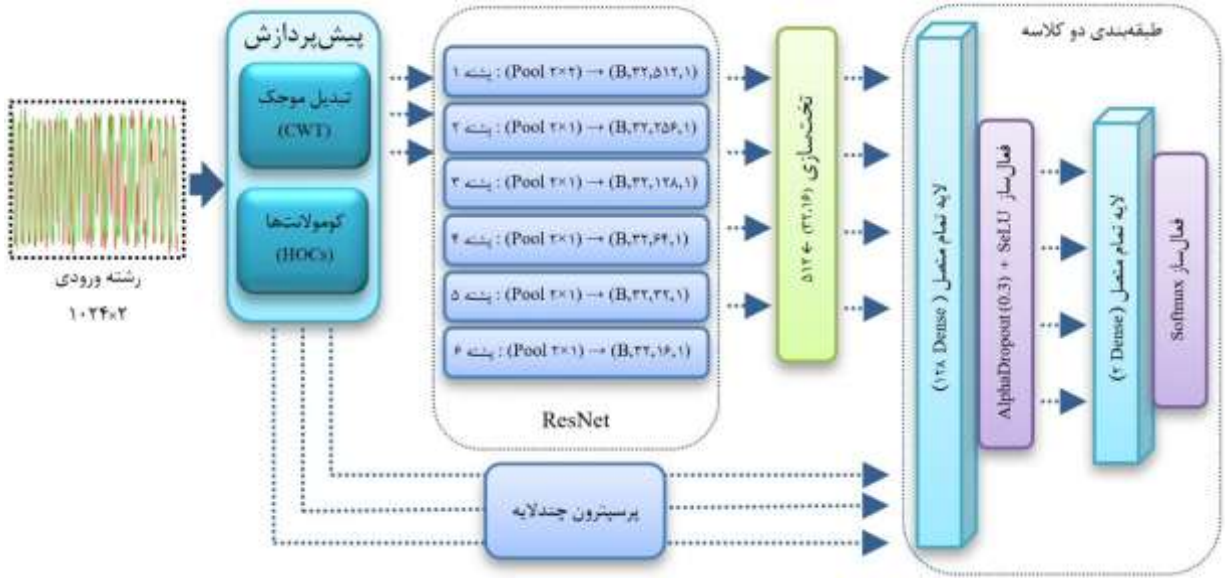
6-2. مدل پیشنهادی مبتنی بر ResNet

شبکه‌های CNN به دلیل توانایی بالای خود در استخراج ویژگی‌های مکانی از داده‌های دوبعدی، در حوزه‌ی تحلیل سیگنال‌های زمان - فرکانس بسیار پرکاربرد هستند. به همین دلیل، در مدل پیشنهادی، باتوجه‌به ماهیت دوبعدی ضرایب حاصل از CWT، از ساختار ResNet به‌عنوان هسته‌ی استخراج ویژگی‌ها استفاده می‌کنیم.

در شبکه‌های کانولوشنی عمیق، افزایش تعداد لایه‌ها معمولاً باعث بهبود دقت می‌شود؛ اما هنگامی که تعداد لایه‌ها زیاد می‌شود یا اصطلاحاً عمق شبکه افزایش می‌یابد، مشکل محوشدن گرادیان

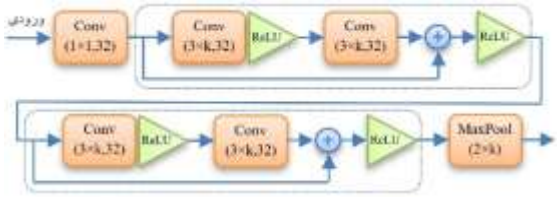
مانع از همگرایی مطلوب مدل می‌گردد. شبکه‌های ResNet با معرفی مسیرهای میان‌بر، این چالش را برطرف کرده‌اند. در این شبکه، به‌جای یادگیری تابع مستقیم بین ورودی و خروجی هر بلوک، مدل تابع باقیمانده را یاد می‌گیرد.

پشته نخست و کرنل 3×1 برای پشته‌های بعدی استفاده می‌کنیم و در پایان برای کاهش تدریجی ابعاد از یک‌لایه‌ی بیشینه‌گیری[18] بهره می‌بریم که می‌توان ساختار آن را در شکل (6) مشاهده نمود. در این ساختار مقدار k برای پشته اول برابر با



شکل (5). شماتیک کلی مدل پیشنهادی مبتنی بر ResNet شامل پیش‌پردازش، 6 پشته باقیمانده، تخت ساز و دولایه تمام متصل

در ادامه مدلی ترکیبی مبتنی بر تبدیل موجک پیوسته و شبکه‌ی ResNet سفارشی پیشنهاد داده‌ایم که در آن، داده‌های خام ابتدا در بخش پیش‌پردازش به حوزه‌ی زمان - فرکانس منتقل شده و سپس در کنار استخراج ویژگی‌های آماری مرتبه بالا (کومولانت‌ها)، به شبکه‌ی یادگیری عمیق وارد می‌شوند. این ترکیب سبب می‌شود که مدل بتواند هم‌زمان اطلاعات زمانی - فرکانسی و ساختار آماری سیگنال را ببیند و در نتیجه، تفکیک کلاس‌ها (به‌ویژه در شرایط نویزی) با اطمینان بیشتری انجام شود.



شکل (6). ساختار یک پشته باقیمانده

برای استخراج الگوهای زمان - فرکانس از سیگنال‌های راداری و مخابراتی، یک شبکه باقی‌مانده سفارشی با ۶ پشته باقیمانده متوالی طراحی کرده‌ایم. هر پشته از سه بخش اصلی تشکیل می‌شود؛ در این بخش‌ها ابتدا با استفاده از یک‌لایه‌ی کانولوشن 1×1 تعداد کانال‌ها را به ۳۲ افزایش می‌دهیم، سپس از دو بلوک باقیمانده شامل لایه‌های کانولوشن با کرنل 3×2 برای

1 و برای پشته 2 تا 6 برابر با 2 است. در هر واحد باقیمانده، دو لایه‌ی کانولوشن با ۳۲ فیلتر اعمال می‌شود و خروجی آن‌ها با مسیر میان‌بر جمع شده و سپس تابع فعال‌سازی ReLU اعمال می‌گردد. در پیاده‌سازی شبکه، مقداردهی اولیه وزن‌ها در لایه‌های کانولوشنی با روش Glorot-Normal انجام شده است. همچنین ورودی شبکه برای سازگاری با لایه‌های کانولوشنی به شکل یک نگاشت دوبعدی با ابعاد (2×1024×1) تغییر شکل داده می‌شود.

خروجی بخش کانولوشنی شبکه پس از عبور از آخرین پشته‌ی باقیمانده، دارای ابعاد (B,32,16,1) است که در آن B اندازه‌ی دسته‌ی آموزشی را نشان می‌دهد. این خروجی پس از عمل تخت‌سازی به یک بردار ۵۱۲ بعدی تبدیل می‌شود. از طرفی سه ویژگی آماری حاصل از کومولانت‌های مرتبه بالا، به‌عنوان ورودی به یک شبکه‌ی پرسپترون چندلایه[19] (MLP) با دو لایه‌ی تمام متصل متوالی (به ترتیب با ۳۲ و ۳۲ نرون) وارد می‌شوند تا روابط غیرخطی میان کومولانت‌ها را مدل کنند؛ در نهایت یک بردار فشرده‌ی ۳۲ بعدی برای ادغام با ویژگی‌های استخراج‌شده توسط ResNet تولید می‌شود و به‌عنوان ورودی بخش طبقه‌بندی نهایی مورداستفاده قرار می‌گیرد.

شماتیک کلی این طرح پیشنهادی را در شکل (5) می‌توان

[18] MaxPooling
[19] Multilayer Perceptron

مشاهده نمود. بخش طبقه‌بندی نهایی شبکه از سه‌لایه‌ی اصلی تشکیل شده است: ابتدا یک‌لایه‌ی تمام متصل با ۱۲۸ نرون و تابع فعال‌سازی SELU برای نگاشت غیرخطی ویژگی‌ها، سپس به‌منظور افزایش پایداری آماری و جلوگیری از بیش برازش از یک‌لایه‌ی AlphaDropout با نرخ 0/3 استفاده شده و در پایان برای برآورد احتمال تعلق نمونه به هر یک از کلاس‌ها، یک‌لایه‌ی تمام متصل با تابع فعال‌سازی Softmax برای تصمیم‌گیری نهایی قرار داده شده است.

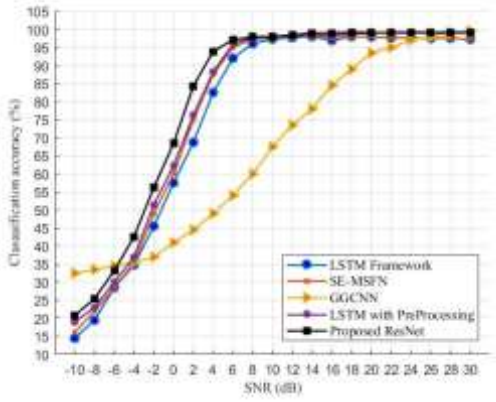
در مجموع، معماری شبکه از ۳۰ لایه‌ی کانولوشنی و ۲ لایه‌ی تمام متصل تشکیل شده است؛ بنابراین تعداد کل لایه‌های یادگیرنده در مدل برابر با ۳۲ لایه است.

7. تحلیل و ارزیابی مدل‌های پیشنهادی

در این پژوهش، سه سناریو آموزشی را مورد بررسی قرار می‌دهیم تا عملکرد دو مدل پیشنهادی شامل مدل مبتنی بر LSTM بهبودیافته و مدل مبتنی بر ResNet را در شرایط مختلف بررسی نموده و با مراجع دیگر مقایسه نماییم. در این بخش معیار اصلی ارزیابی، میانگین دقت طبقه‌بندی در سطوح مختلف نسبت سیگنال به نویز در نظر گرفته شده است.

7-1. سیگنال‌های مخابراتی

در نخستین سناریو، مدل‌ها تنها با استفاده از مجموعه‌داده‌ی RadioML2018.01A شامل ۲۴ نوع مدولاسیون مخابراتی آموزش داده شدند. همان‌طور که در شکل (7) مشاهده می‌شود، برای ارزیابی عملکرد مدل‌های پیشنهادی، میانگین دقت طبقه‌بندی در سطوح مختلف SNR محاسبه و با نتایج حاصل از روش‌های GGCNN [10]، SE-MSFN [11] و LSTM Framework [5] مقایسه گردید. همچنین جدول (۲) مقایسه‌ای از تعداد عامل‌های قابل‌آموزش (پیچیدگی محاسباتی) و میانگین دقت طبقه‌بندی بین مدل‌های ResNet، VGG [12]، MSN [13]، CLDNN و CNN [14] با مدل‌های پیشنهادی این پژوهش را ارائه می‌دهد.



شکل (7). مقایسه میانگین دقت طبقه‌بندی روش‌های پیشنهادی در مقایسه با GGCNN [10]، SE-MSFN [11] و LSTM Framework [5] با استفاده از مجموعه‌داده RadioML2018.01A.

جدول (2). مقایسه دقت طبقه‌بندی و پیچیدگی محاسباتی مدل‌های پیشنهادی با سایر روش‌ها

شبکه	میانگین دقت (٪)		ظرفیت (تعداد عامل‌ها)
	تمام SNRها	SNRهای 0–10 dB	
ResNet [12]	59.62	73.40	205 هزار
VGG [12]	60.48	76.83	283 هزار
MSN [13]	61.60	77.97	143 هزار
CLDNN [14]	63.08	82.68	847 هزار
CNN [14]	58.53	73.02	466 هزار
SE-MSFN [11]	64.50	85.53	332 هزار
LSTM پیشنهادی	79.39	86.42	330 هزار
ResNet پیشنهادی	81.33	89.93	163.3 هزار

افزودن مرحله‌ی پیش‌پردازش در مدل مبتنی بر LSTM بهبودیافته موجب افزایش محسوس دقت طبقه‌بندی، به‌ویژه در SNRهای پایین شده است. این بهبود عملکرد را می‌توان ناشی از کاهش مؤلفه‌های نویزی و افزایش وضوح الگوهای زمان - فرکانسی دانست که در نتیجه‌ی پیش‌پردازش سیگنال حاصل می‌شود. میانگین دقت مدل مبتنی بر LSTM برابر با 79/39 درصد است که حدود 14/89 درصد بیشتر از روش SE-MSFN [11] است، درحالی‌که پیچیدگی محاسباتی آن تقریباً ۳۳۰ هزار عامل بوده و از این نظر با روش یادشده تقریباً برابر است.

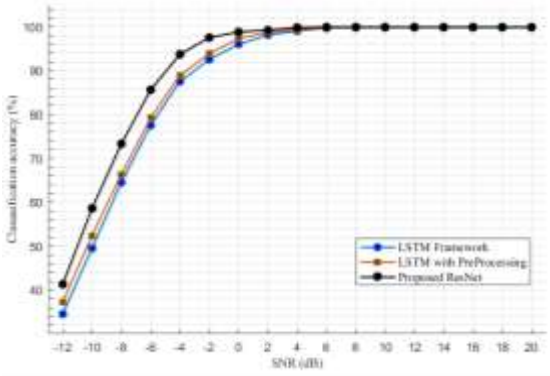
در مقابل، مدل مبتنی بر ResNet در تمامی بازه‌های SNR عملکرد بهتری از خود نشان داده و میانگین دقت 81/33 درصد را به دست آورده است که نسبت به SE-MSFN [11] حدود 16/83 درصد و نسبت به مدل LSTM پیشنهادی حدود ۲ درصد بهبود دقت دارد. این افزایش دقت را می‌توان علاوه بر اثر پیش‌پردازش، به ساختار کانولوشنی و اتصالات باقیمانده شبکه که امکان استخراج مؤثر ویژگی‌های محلی و تکرارشونده از سیگنال را فراهم می‌سازد، نسبت داد. این در حالی است که پیچیدگی محاسباتی آن حدود 163 هزار عامل بوده که تقریباً نصف مدل مبتنی بر LSTM است.

در مجموع، نتایج نشان می‌دهد که پیش‌پردازش سیگنال نقش کلیدی در بهبود پایداری و کارایی مدل‌های مبتنی بر یادگیری عمیق دارد و موجب می‌شود شبکه بتواند در شرایط نویزی نیز الگوهای طیفی را دقیق‌تر شناسایی کند؛ همچنین همان‌طور که انتظار می‌رفت شبکه مبتنی بر ResNet پیشنهادی عملکرد و دقت بهتری نسبت به سایر شبکه‌ها ارائه داد.

7-2. سیگنال‌های راداری

در دومین سناریو، مدل‌ها تنها با استفاده از مجموعه‌داده‌ی DeepRadar2022 شامل 23 نوع مدولاسیون راداری آموزش داده شدند. مطابق شکل (8)، به‌منظور ارزیابی عملکرد مدل‌های پیشنهادی، میانگین دقت طبقه‌بندی در سطوح مختلف SNR محاسبه و با نتایج حاصل از روش LSTM Framework [5] مقایسه گردید. لازم به ذکر است که سایر روش‌های مرجع مقایسه شده در سناریوی مخابراتی (شکل (7))، در مقالات اصلی خود نتایج قابل‌ارجاعی بر روی مجموعه‌داده‌ی DeepRadar2022 گزارش نکرده‌اند؛ ازآنجاکه در مقالات مربوط به سایر روش‌های مرجع، نتیجه‌ای روی مجموعه‌داده‌ی راداری DeepRadar2022 گزارش نشده است، امکان ارائه‌ی یک مقایسه‌ی مستقیم و هم شرایط برای همه‌ی روش‌ها وجود نداشت؛ بنابراین در سناریوی راداری (شکل (8)) مقایسه تنها با روشی انجام شد که به طور مشخص برای داده‌های راداری نیز ارزیابی شده است (LSTM Framework [5]). همان‌طور که انتظار می‌رفت، دقت هر دو مدل پیشنهادی در این سناریو نیز بالاتر از روش LSTM Framework [5] به دست آمد.

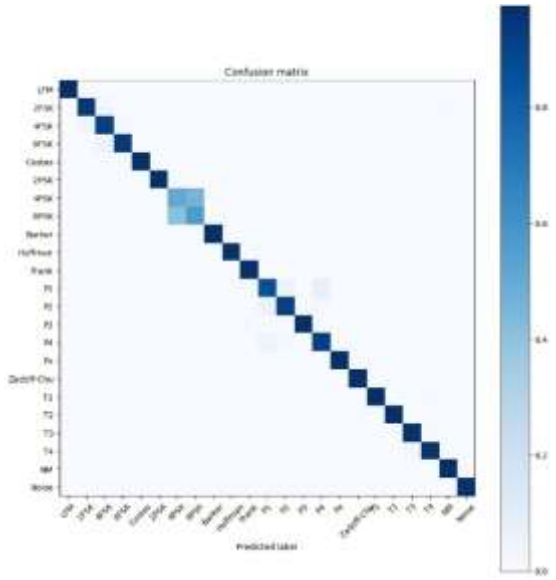
میانگین دقت مدل مبتنی بر LSTM در بازه SNR، 12- تا 4dB (در محدوده‌ای که منحنی‌های عملکرد هنوز به همگرایی کامل نرسیده‌اند) برابر با 79/23 درصد است که حدود 1/55 درصد بیشتر از روش LSTM Framework [5] است. همچنین، مدل مبتنی بر ResNet در تمامی سطوح SNR عملکرد بهتری نشان داده و میانگین دقتی برابر با 83/05 درصد کسب کرده است. این مقدار نسبت به LSTM Framework [5] حدود 5/38 درصد و نسبت به مدل LSTM پیشنهادی حدود 3/82 درصد بهبود را نشان می‌دهد. مقایسه‌ی میانگین دقت روش‌ها در جدول (۳) ارائه شده است.



شکل (8). مقایسه میانگین دقت طبقه‌بندی روش‌های پیشنهادی در مقایسه با LSTM Framework [5] با استفاده از مجموعه‌داده DeepRadar2022.

جدول (3). مقایسه دقت طبقه‌بندی مدل‌های پیشنهادی با روش LSTM Framework [5]

شبکه	میانگین دقت (٪)	
	تمام SNRها	SNRهای 4 dB- تا 12 dB-
LSTM Framework [5]	88/08	77/68
LSTM پیشنهادی	88/95	79/23
ResNet پیشنهادی	90/98	83/06



شکل (9). ماتریس درهم‌ریختگی نرمال‌شده برای مدل LSTM بهبودیافته پیشنهادی

ازآنجاکه سیگنال‌های راداری معمولاً دارای الگوهای موضعی و تکرارشونده در حوزه‌ی زمان - فرکانس هستند، معماری کانولوشنی ResNet قادر است این الگوها را با کارایی بالاتری نسبت به LSTM که ذاتاً متکی به‌توالی و وابستگی‌های زمانی است، استخراج کند. به همین دلیل، مزیت استفاده از مدل مبتنی بر ResNet در این مجموعه‌داده نسبت به حالت قبلی به‌مراتب آشکارتر است.

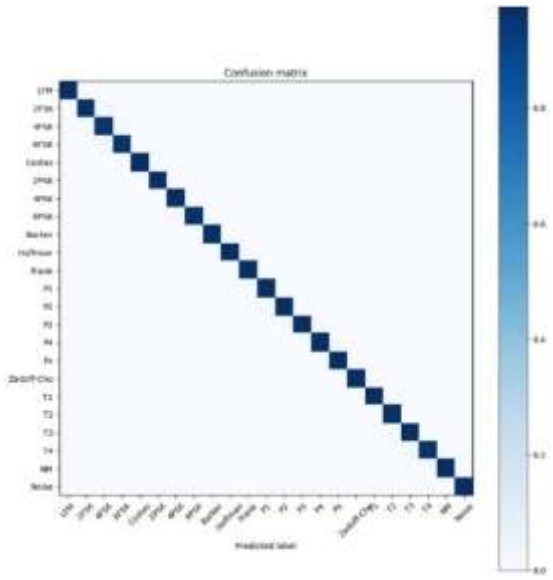
در این پژوهش، معیار اصلی ارزیابی عملکرد مدل‌ها، دقت طبقه‌بندی است که به‌صورت میانگین دقت در بازه‌های مختلف نسبت سیگنال به نویز گزارش شده است؛ زیرا هدف اصلی، نمایش روند تغییر عملکرد مدل‌ها در شرایط نویزی و امکان مقایسه‌ی مستقیم بر حسب نسبت سیگنال به نویز بوده است.

بااین‌حال، برای آن که تحلیل نتایج صرفاً به یک عدد خلاصه نشود و مشخص گردد خطاها دقیقاً در کدام رده‌ها رخ می‌دهند، در سناریوی راداری، ماتریس درهم‌ریختگی نرمال‌شده برای هر دو مدل پیشنهادی نیز در شکل‌های (9) و (10) ارائه می‌شود. این ماتریس‌ها بر اساس نمونه‌های آزمون در بازه‌ی نسبت سیگنال به نویز 2 dB تا 20 dB محاسبه شده‌اند و به‌صورت فشرده نشان می‌دهند، مدل‌ها در تفکیک رده‌های مختلف چه رفتاری دارند و ابهام‌ها عمدتاً میان کدام رده‌های نزدیک به هم رخ می‌دهد. همچنین، ازآنجاکه معیارهایی مانند دقت[20]، بازخوانی[21] و F1-score مستقیماً از شمارش خطاها در ماتریس درهم‌ریختگی قابل استخراج‌اند، این نمایش می‌تواند مبنایی برای تحلیل دقیق‌تر رفتار مدل در سطح رده‌ها باشد. در ادامه‌ی کار، محاسبه و گزارش نظام‌مند این معیارها به‌صورت تابعی از نسبت سیگنال به نویز و نیز مقایسه‌ی هم شرایط آن‌ها با روش‌های دیگر، به‌عنوان مسیر توسعه‌ی پژوهش در کارهای آینده دنبال خواهد شد.

7-3. ادغام سیگنال‌های راداری و مخابراتی

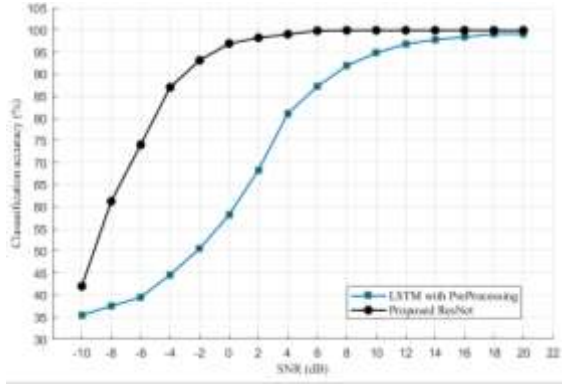
در آخرین سناریو، هر دو مجموعه‌داده‌ی مخابراتی و راداری به طور هم‌زمان برای آموزش شبکه‌ها مورداستفاده قرار گرفتند. در مجموع، داده‌ها شامل ۴۷ نوع مدولاسیون مختلف بودند. مطابق شکل (11)، عملکرد مدل‌های پیشنهادی این آزمایش نسبت به دو سناریوی پیشین رفتار متفاوتی را نشان داد. برخلاف انتظار، مدل LSTM در حضور هر دو نوع داده، افت محسوسی در عملکرد داشت و نتوانست دقت به‌دست‌آمده در مراحل قبل را حفظ کند.

این افت عملکرد را می‌توان به چند عامل نسبت داد. نخست،



شکل (10). ماتریس درهم‌ریختگی نرمال‌شده برای مدل ResNet پیشنهادی

ترکیب داده‌های ناهمگون موجب افزایش پیچیدگی آماری مجموعه‌داده شده است و ظرفیت محدود شبکه‌ی LSTM برای مدل‌سازی هم‌زمان الگوهای متنوع راداری و مخابراتی کافی نبوده است. دوم، هم‌پوشانی برخی ویژگی‌های زمانی - فرکانسی میان این دو نوع سیگنال باعث تداخل در فضای ویژگی و دشوارتر شدن مرزهای تصمیم‌گیری مدل گردیده است.



شکل (11). مقایسه میانگین دقت طبقه‌بندی روش‌های پیشنهادی با هم با استفاده از مجموعه‌داده DeepRadar2022 و RadioML2018.01A.

در مقابل، شبکه‌ی ResNet در همین شرایط عملکردی پایدار و قدرتمند از خود نشان داد. در سطح SNR = 2dB، دقت مدل به حدود 98/2 درصد رسید که نشان‌دهنده‌ی توانایی بالای آن در تعمیم میان‌دامنه‌ای است. ساختار عمیق و وجود اتصالات باقیمانده در ResNet این امکان را فراهم می‌سازد که شبکه به طور هم‌زمان ویژگی‌های محلی و کلی را فراگیرد و نسبت به تغییرات دامنه و فرکانس سیگنال‌ها مقاومت بالاتری داشته باشد.

در این سناریوی ترکیبی، به دلیل آن که برای اغلب

[20] Precision
[21] Recall

روش‌های مراجع مورداستفاده در سناریوی مخابراتی، نتایج استانداردی بر روی مجموعه‌داده‌ی ترکیبی (RadioML+DeepRadar2022) گزارش نشده است، امکان ارائه‌ی مقایسه‌ی مستقیم و هم شرایط برای همه‌ی روش‌ها فراهم نبود؛ بنابراین شکل (11) صرفاً برای نشان‌دادن رفتار دو مدل پیشنهادی ارائه شده است.

8. جمع‌بندی

نتایج سه سناریوی انجام‌شده نشان داد که در SNRهای بالا، عملکرد هر دو مدل پیشنهادی تقریباً به‌دقت کامل نزدیک می‌شود، اما تفاوت‌های اصلی در بازه‌های پایین‌تر SNR نمایان می‌گردد؛ جایی که از دید کاربردی بیشترین اهمیت را دارد. این نتایج همچنین نشان می‌دهد، بهبود عملکرد مدل‌های پیشنهادی صرفاً به بزرگ‌تر شدن شبکه یا افزایش ظرفیت آن محدود نمی‌شود؛ بخش مهمی از این پیشرفت به کیفیت بازنمایی ورودی و شیوه‌ی ترکیب ویژگی‌ها برمی‌گردد.

تبدیل موجک پیوسته با ارائه‌ی یک تصویر زمان - فرکانس منظم، الگوهای گذرا و تغییرات موضعی طیف را برجسته می‌کند؛ الگوهایی که در بسیاری از کلاس‌ها، با نگاه مستقیم به نمونه‌های مؤلفه‌های I/Q یا حتی ویژگی‌های زمانی، به‌راحتی قابل تفکیک نیستند. در کنار این بازنمایی، استفاده از کومولانت‌های مرتبه بالا نقش تکمیلی دارد؛ چون بخشی از ساختار آماری سیگنال را که معمولاً در برابر نویز گاوسی پایدارتر است، آشکار می‌کند. همین ترکیب، در نسبت سیگنال به نویزهای پایین‌تر، باعث می‌شود تصمیم‌گیری مدل کمتر نوسان داشته باشد. بهبود مشاهده‌شده در مدل مبتنی بر LSTM پس از افزودن ویژگی‌های موجکی و آماری نیز دقیقاً تأکیدی بر این نکته است که پیش‌پردازش داده‌های ورودی می‌تواند بخشی از محدودیت‌های یادگیری صرفاً ترتیبی را، جبران کند.

در مقایسه‌ی دو رویکرد پیشنهادی، شبکه‌ی ResNet در اغلب سناریوها عملکرد بهتری از خود نشان داده است. دلیل این برتری را می‌توان در تناسب طبیعی ساختارهای کانولوشنی با الگوهای دوبعدی زمان - فرکانس جست‌وجو کرد؛ جایی که اتصالات باقیمانده، ضمن تسهیل آموزش شبکه‌ی عمیق، امکان یادگیری الگوهای محلی و تکرارشونده را در نگاشت‌های دوبعدی زمان - فرکانس فراهم می‌سازد. از نظر کارایی نیز جدول (2) نشان می‌دهد مدل مبتنی بر ResNet در کنار دقت بالاتر، از منظر تعداد عامل‌های قابل‌آموزش هم وضعیت مطلوبی دارد و بنابراین می‌تواند برای پیاده‌سازی‌های عملی گزینه‌ی مناسب‌تری باشد.

در مجموع، شبکه‌ی ResNet پیشنهادی نسبت به مدل‌های مرجع و شبکه‌ی LSTM بهبودیافته، مقاومت بالاتری در برابر نویز و تغییرات آماری سیگنال از خود نشان داد. همچنین افزودن مرحله‌ی پیش‌پردازش موجب بهبود قابل‌توجه عملکرد LSTM گردید، طوری که میانگین دقت آن به ترتیب در داده‌های مخابراتی و راداری به 79/39 درصد و 88/95 درصد رسید. بااین‌حال، شبکه‌ی ResNet در تمامی سناریوها (از جمله داده‌های مخابراتی، راداری و ترکیبی) دقیق‌ترین عملکرد را ارائه داد؛ به‌نحوی که میانگین دقت آن به ترتیب در داده‌های مخابراتی و راداری به 81/33 درصد و 90/98 درصد رسید و در سناریوی نهایی توانست به‌دقت 98/2 درصد در SNR = 2dB دست یابد. این نتایج نشان می‌دهد ساختار عمیق و سلسله‌مراتبی ResNet، باقابلیت استخراج هم‌زمان ویژگی‌های محلی و کلی، توانایی بیشتری در تعمیم میان‌دامنه‌ای و یادگیری الگوهای مشترک میان داده‌های راداری و مخابراتی دارد.

البته از منظر تحلیلی، بخشی از خطاهای طبقه‌بندی کاملاً قابل‌انتظار است؛ به‌ویژه در کلاس‌هایی که الگوهای زمان - فرکانس به هم نزدیک‌اند یا تفاوت آن‌ها بیشتر در جزئیات ظریف نهفته است. در این وضعیت، وقتی نسبت سیگنال به نویز کاهش پیدا می‌کند، هم‌پوشانی ویژگی‌ها بیشتر شده و مرز تصمیم‌گیری سخت‌تر می‌شود. از طرف دیگر، هرچند تبدیل موجک پیوسته بازنمایی قدرتمندی فراهم می‌کند، اما نسبت به انتخاب موجک و تنظیمات آن حساس است؛ بنابراین برای انتقال روش به داده‌های عملیاتی، لازم است حساسیت مدل در برابر تغییرات نرخ نمونه‌برداری، اثرات کانال و اعوجاج‌های سخت‌افزاری (مانند آفست فرکانس و نوسانات توان) بادقت بررسی شود.

در مقایسه با دستاوردهای مشابه، نتایج سناریوی مخابراتی (مطابق شکل (7) و جدول (2)) نشان می‌دهد رویکرد پیشنهادی در کنار روش‌های مراجع گزارش‌شده عملکرد رقابتی ارائه می‌کند؛ با این تفاوت که در این پژوهش تمرکز اصلی بر ادغام هدفمند بازنمایی زمان - فرکانس با ویژگی‌های آماری مکمل بوده است، نه صرفاً افزایش عمق شبکه. در سناریوی راداری نیز مقایسه با چارچوب‌های مبتنی بر LSTM نشان می‌دهد افزودن بازنمایی زمان - فرکانس و بهره‌گیری از معماری عمیق‌تر می‌تواند قدرت تفکیک را در حضور نویز افزایش دهد.

همچنین تأکید می‌شود سناریوی سوم در این مقاله به معنای هم‌زمانی یا هم‌پوشانی چند سیگنال در یک مشاهده نیست؛ در این سناریو داده‌ها در سطح مجموعه‌داده ادغام شده‌اند و هدف، ارزیابی توانایی مدل در طبقه‌بندی صحیح روی دامنه‌ی بزرگ‌تر و متنوع‌تری از کلاس‌های راداری و مخابراتی بوده است؛ بنابراین دستاورد این بخش بیش از آن که «جداسازی منابع هم‌زمان»

باشد، نشان‌دادن دامنه‌ی پوشش طبقه‌بندی و تقویت شواهد مربوط به تعمیم‌پذیری مدل در برابر تنوع کلاس‌هاست.

از منظر کاربردی، چارچوب پیشنهادی می‌تواند به‌عنوان یک ماژول «شناخت سیگنال» در سامانه‌های پایش طیف و گیرنده‌های هوشمند به کار گرفته شود؛ به این معنا که پس از دریافت یک مشاهده‌ی سیگنالی، نوع سیگنال (راداری یا مخابراتی) و کلاس آن بادقت مناسب برآورد شود و این خروجی، ورودی تصمیم‌سازی لایه‌های بالادستی قرار گیرد. چنین قابلیتی در صنایع هوافضا و سامانه‌های راداری اهمیت ویژه‌ای دارد؛ برای مثال، در سامانه‌های مراقبت هوایی/دریایی و مراکز کنترل ترافیک هوایی، تفکیک سریع سیگنال‌های راداری از سیگنال‌های مخابراتی موجود در محیط می‌تواند به پایش سالم‌بودن باند، تشخیص رخدادهای تداخلی و انتخاب مسیر پردازشی صحیح کمک کند. در سامانه‌های راداری نصب‌شده روی هواگردها (مانند رادار هواشناسی، ناوبری یا رادارهای نظارتی)، شناسایی قابل‌اتکا در نسبت‌های سیگنال به نویز پایین می‌تواند برای تشخیص حضور تداخل‌ها و ارزیابی کیفیت دریافت در شرایط عملیاتی مفید باشد؛ به‌ویژه زمانی که محیط طیفی شلوغ است و سیگنال‌های ناهمگون به طور هم‌زمان در پهنای باند حضور دارند.

در حوزه‌ی مخابرات و شبکه‌های صنعتی نیز، این رویکرد می‌تواند در گیرنده‌های نرم‌افزاری (SDR) برای برچسب‌گذاری خودکار سیگنال‌های مشاهده‌شده، پایش پیوسته‌ی باندهای پرتراکم، و شناسایی سیگنال‌های ناخواسته/مداخله‌گر به کار رود. همچنین در سناریوهای هم‌زیستی طیفی بین سامانه‌های مختلف، خروجی طبقه‌بندی می‌تواند مبنای اتخاذ راهبردهای سازگارکننده مانند تغییر کانال، تنظیم توان، تغییر پهنای باند یا زمان‌بندی ارسال باشد. به‌طورکلی، نتایج این پژوهش نشان می‌دهد می‌توان با ترکیب بازنمایی زمان - فرکانس و ویژگی‌های آماری مکمل، یک ماژول تشخیص/طبقه‌بندی نسبتاً پایدار در محیط‌های نویزی ارائه کرد که قابلیت ادغام در زنجیره‌ی پردازش سامانه‌های عملی را دارد.

برای ادامه‌ی کار، می‌توان از مدل‌های ترکیبی (CNN–LSTM)، آموزش آگاه از سطح نسبت سیگنال به نویز و داده‌های واقعی‌تر همراه با تداخلات متنوع و هم‌پوشانی طیفی استفاده کرد تا قابلیت تعمیم مدل‌ها در شرایط عملی افزایش یابد. افزون بر این، طراحی نسخه‌های سبک‌تر برای کاربردهای بلادرنگ و پیاده‌سازی روی سخت‌افزارهای تعبیه‌شده، و نیز گسترش ارزیابی‌ها با معیارهای تکمیلی مانند دقت، بازخوانی و F1-score به‌صورت تابعی از نسبت سیگنال به نویز و مقایسه‌ی هم شرایط آن‌ها با روش‌های مراجع، می‌تواند تکمیل طبیعی این مسیر پژوهشی باشد. باوجود این، بر اساس نتایج به‌دست‌آمده، شبکه‌ی ResNet پیشنهادی می‌تواند به‌عنوان گزینه‌ای اصلی و قابل‌اعتماد برای طبقه‌بندی مشترک سیگنال‌های راداری و مخابراتی در محیط‌های نویزی پیشنهاد شود.

5. مراجع

[1] Y. Zhou, R. Cao, A. Zhang, and P. Li, “Radio Signal Modulation Recognition Method Based on Hybrid Feature and Ensemble Learning: For Radar and Jamming Signals,” Sensors, vol. 24, issue 15, 2024. https://doi.org/10.3390/s24154804

[2] S. Lakhanpal, S. Aswini, R. Chandrashekar, G. K. Pandey, A. Albawi and R. Kalra, "The Role of Machine Learning in Optimizing Radar Signal Analysis," 2024 IEEE 13th International Conference on Communication Systems and Network Technologies (CSNT), 2024. https://doi.org/10.1109/CSNT60213.2024.10546095

[3] L. Lesieur, J.M. Le Caillec, A. Khenchaf, V. Guardia, and A. Toumi, “An Overview and Classification of Machine Learning Approaches for Radar Signal Deinterleaving,” IEEE Access, vol. 13, pp. 28008-28028, 2025. https://doi.org/10.1109/ACCESS.2025.3539589

S. Ansari, A. S. Alatrany, K. A. Alnajjar, T. Khater, S. Mahmoud, and D. Al-Jumeily, “A Survey of Artificial Intelligence Approaches in Blind Source Separation,” Neurocomputing, vol. 561, 2023.https://doi.org/10.1016/j.neucom.2023.126895

[4] V. Clerico, A. De Maio, and L. Pallotta, “LSTM Framework for Classification of Radar and Communications Signals” 2023 IEEE Radar Conference (RadarConf23), 2023. https://doi.org/10.1109/RadarConf2359393.2023.10139864

[5] M. A. Aref, “Classification of Radar and Communications Signals Using Wideband Autonomous Cognitive Radios,” IEEE Global Communications Conference (GLOBECOM), 2018. https://doi.org/10.1109/GLOCOM.2018.8647693

[6] H. Zhang, F. Wang, and J. Liu, “Deep Learning-Based Blind Source Separation for Overlapped Radar–Communication Signals,” IEEE Transactions on Aerospace and Electronic Systems, vol. 59, no. 1, pp. 125–139, 2023. https://doi.org/10.1109/TAES.2022.3189421

S. Chen, H. Li, and T. Chen, “Deep Convolutional Neural Networks for Modulation Recognition of Overlapped Radar and Communication Signals,” IEEE Sensors Journal, vol. 22, no. 2, pp. 1775–1788, 2022.https://doi.org/10.1109/JSEN.2021.3115140

[7] L. Wang, Z. Li, and P. Zhu, “Wavelet Packet and Deep Neural Network-Based Hybrid Approach for Low-SNR Signal Classification,” IEEE Transactions on Instrumentation and Measurement, vol. 72, pp. 1–12, 2023. https://doi.org/10.1109/TIM.2023.3260147

[8] P. Ghasemzadeh, M. Hempel, H. Wang, and H. Sharif, "GGCNN: An Efficiency-Maximizing Gated Graph Convolutional Neural Network Architecture for Automatic Modulation Identification," IEEE Transactions on Wireless Communications, vol. 22, no. 9, pp. 6033-6047, 2023. https://doi.org/10.1109/TWC.2023.3239311

[9] X. Wu, S. Wei, and Y. Zhou, "Deep Multi-Scale Representation Learning with Attention for Automatic Modulation Classification," 2022 International Joint Conference on Neural Networks (IJCNN), 2022. https://doi.org/10.1109/IJCNN55064.2022.9892813

[10] T. J. O'Shea, T. Roy, and T. C. Clancy, "Over-the-Air Deep Learning Based Radio Signal Classification," IEEE Journal of Selected Topics in Signal Processing, vol. 12, no. 1, pp. 168-179, 2018.

https://doi.org/10.1109/JSTSP.2018.2797022

[11] H. Chen, L. Guo, C. Dong, F. Cong, and X. Mu, "Automatic Modulation Classification Using Multi-Scale Convolutional Neural Network," 2020 IEEE 31st Annual International Symposium on Personal, Indoor and Mobile Radio Communications, 2020.

https://doi.org/10.1109/PIMRC48278.2020.9217305

[12] K. Pijackova and T. Gotthans, "Radio Modulation Classification Using Deep Learning Architectures," 2021 31st International Conference Radioelektronika (RADIOELEKTRONIKA), 2021.

https://doi.org/10.1109/RADIOELEKTRONIKA52220.2021.9420195

Y. Guo and X. Zhang, "Radar signal classification based on cascade of STFT, PCA and naïve Bayes," 7th International Conference on Intelligent Systems, Modelling and Simulation (ISMS), 2016. https://doi.org/10.1109/ISMS.2016.17

[13] C. Wang et al., "Automatic radar waveform recognition based on time–frequency analysis and convolutional neural network," IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), 2017. https://doi.org/10.1109/ICASSP.2017.7952532

[14] R. K. Chilukuri, H. K. Kakarla, and K. S. Rao, "Radar signal recognition based on multilayer perceptron neural network," International Journal of Electrical and Computer Engineering Systems, vol. 14, no. 1, pp. 29-36, 2023. https://doi.org/10.32985/ijeces.14.1.4

[15] A. Swami and B. M. Sadler, "Hierarchical digital modulation classification using cumulants," IEEE Transactions on Communications, vol. 48, no. 3, pp. 416-429, 2000. https://doi.org/10.1109/26.837036

[16] O. A. Dobre, Y. Bar-Ness, and W. Su, "Higher-order cyclic cumulants for high-order modulation classification," IEEE Military Communications Conference (MILCOM), 2003. https://doi.org/10.1109/MILCOM.2003.1290083

[17] S. M. Kay, "Fundamentals of Statistical Signal Processing: Detection Theory," Prentice Hall, Upper Saddle River, NJ, USA, 1998.

[18] S. Mallat, "A Wavelet Tour of Signal Processing," Academic Press, San Diego, CA, USA, 1999.

[19] C. Torrence and G. P. Compo, "A practical guide to wavelet analysis," Bulletin of the American Meteorological Society, vol. 79, no. 1, pp. 61–78, 1998. https://doi.org/10.1175/1520-0477(1998)079<0061:APGTWA>2.0.CO;2

[20] M. Müller, "Fundamentals of Music Processing: Audio, Analysis, Algorithms, Applications," Springer, Cham, Switzerland, 2015.

C. L. Nikias and J. M. Mendel, "Signal processing with higher order spectra," IEEE Signal Processing Magazine, vol. 10 no. 3 pp. 10–37, 1993.https://doi.org/10.1109/79.221324

[21] F. A. Gers, J. Schmidhuber, and F. Cummins, "Learning to Forget: Continual Prediction with LSTM," Neural Computation, vol. 12, no. 10, pp. 2451–2471, 2000.

https://doi.org/10.1162/089976600300015015

[22] Y. Norouzi, G. Ghadimi, R. Baiderkhani, and M. M. Nayebi, "Using LeNet-5 and AlexNet Architectures in Deep Learning Approach to Detect and Classify LPI Radar Signals," Radar, vol. 7 no. 1 pp. 117–128, 2019 (In Persian).

https://doi.org/10.1001.1.23454024.1398.7.1.10.8

[23] M. J. Ghalandary, S. M. Hosseini Andargoli, N. Zarei, and M. Molazadeh Golmahaleh, "Multi-mode radars discrimination based on similarity criteria in interleaved pulses," Radar, vol. 10 no. 1 pp. 25–37, 2022 (In Persian). https://doi.org/10.1001.1.23454024.1401.10.1.8.7

[24] S. Talati, M. Akbari Sani, and M. R. Hasani Ahangar, "Identifying Radar Targets using the GMDH Deep Neural Network," Radar, vol. 8 no. 1 pp. 65–74, 2020 (In Persian). https://doi.org/10.1001.1.23454024.1399.8.1.7.2

[25] M. Esfandiyari, M. Beighash, and A. Sheikhi, "Fast Separation of Interleaved Radar Pulse Trains Using Frequency Domain Analysis," Radar, vol. 3 no. 4 pp. 33–42, 2015 (In Persian).

[26] X. Tian, Q. Zheng, B. Li, D. Qiao, K. Yu, Z. Wei, B. Li, H. Jiang, X. Li, Y. Lin, and G. Gui, "A survey on deep learning enabled automatic modulation classification methods: Data representations, model structures, and regularization techniques," Signal Processing, vol. 242 Art. no. 110444, 2026. https://doi.org/10.1016/j.sigpro.2025.110444

[27] M. Wu, Z. Zou, W. Zhang, G. Liu, and J. Zou, "Automatic modulation classification based on wavelet analysis and convolution neural network," Electronics, vol. 14 no. 19 Art. no. 3801, 2025. https://doi.org/10.3390/electronics14193801

[28] Z. Tang, H. Shen, and C.-T. Lam, "Automatic recognition of dual-component radar signals based

on deep learning," Sensors, vol. 25 no. 6 Art. no. 1809, 2025. https://doi.org/10.3390/s25061809