



Generalized Automatic Modulation Classification for Cognitive Radio Networks

Pouria Etezadifar

Assistant Professor, Department of Telecommunications, School of Electrical and Computer Engineering, Imam Hossein Comprehensive University, Tehran, Iran (Corresponding Author)

Email: petezadifar@ihu.ac.ir

Mahdi Ghasemi

Master's Student, Telecommunication Systems, School of Computer, Network, and Communications, Imam Hossein Comprehensive University, Tehran, Iran

Email: mahdi_ghasemi_98@ihu.ac.ir

Mahdi Azizi

Assistant Professor, Department of Communications and Networking, School of Computer, Network, and Communications, Imam Hossein Comprehensive University, Tehran, Iran

Email: mahdiazizi@ihu.ac.ir

Abstract

Automatic Modulation Classification (AMC) plays a fundamental role in defense and military communication systems, particularly in scenarios where adaptability, flexibility, and reliability are critical. In cognitive radio networks, AMC enables real-time identification of modulation schemes, which is essential for effective spectrum monitoring, interference mitigation, and secure communications in dynamic and competitive environments. In this study, we propose a model for more accurate and robust classification of radio signal modulations by developing a Signal Quality Adaptive Convolutional Neural Network (SQACNN). The primary goal is to create a model that adapts to the quality of input signals and mitigates the impact of noise. To this end, an adaptive loss function is employed to combine cross-entropy loss with regularization factors, including signal dispersion coefficient, feature compression coefficient, and SNR adjustment factor. Using a benchmark dataset, the model's classification accuracy was evaluated across different SNR levels, demonstrating that the proposed SQACNN model achieves significant improvements in classification accuracy, with an overall accuracy of 71.03%, while maintaining satisfactory performance particularly under low SNR conditions. This study highlights the effectiveness of incorporating signal quality metrics into the learning process, rendering it a valuable tool for real-world signal processing applications.

Keywords: Automatic Modulation Classification, Deep Learning, Convolutional Neural Network, Cognitive Radio





سال هشتم، شماره سوم (پیاپی ۲۷)، پاییز ۱۴۰۴، صص. ۱۱-۴۲
تاریخ دریافت: ۱۴۰۳/۰۷/۲۱ - تاریخ پذیرش: ۱۴۰۳/۰۹/۲۵

مقاله پژوهشی

تشخیص مدولاسیون خودکار تعمیم یافته برای شبکه های رادیویی شناختی

پوریا اعتضادی فر

استادیار گروه مخابرات، دانشکده برق و کامپیوتر، دانشگاه جامع امام حسین (ع)، تهران، ایران (نویسنده مسئول)
Email: petezadifar@ihu.ac.ir

مهدی قاسمی

دانشجوی کارشناسی ارشد مخابرات سیستم، دانشکده رایانه، شبکه و ارتباطات، دانشگاه جامع امام حسین (ع)، تهران، ایران
Email: mahdi_ghasemi_98@ihu.ac.ir

مهدی عزیزی

استادیار گروه ارتباطات و شبکه، دانشکده رایانه، شبکه و ارتباطات، دانشگاه جامع امام حسین (ع)، تهران، ایران
Email: mahdiazizi@ihu.ac.ir

چکیده

دسته بندی مدولاسیون خودکار (AMC) نقشی اساسی در سیستم های ارتباطی دفاعی و نظامی ایفا می کند، به ویژه در سناریوهایی که سازگاری، انعطاف پذیری و قابلیت اطمینان، حیاتی هستند. در شبکه های رادیویی شناختی، AMC شناسایی فوری طرح های مدولاسیون را امکان پذیر می سازد که برای نظارت مؤثر طیف، کاهش تداخل و ارتباطات امن در محیط های پویا و رقابتی ضروری است. این مطالعه با توسعه یک شبکه عصبی کانولوشنال تطبیقی با کیفیت سیگنال (SQACNN)، مدلی برای دسته بندی دقیق تر و مقاوم تر مدولاسیون های سیگنال رادیویی ارائه داده است. هدف اصلی، ایجاد مدلی است که با کیفیت سیگنال های ورودی هماهنگ شود و تأثیر نویز را کاهش دهد. بدین منظور، از تابع زیان تطبیقی استفاده شده تا زیان آنتروپی متقاطع را با عوامل منظم سازی، شامل ضریب پخش شدگی سیگنال، ضریب فشردگی ویژگی و ضریب تنظیم SNR ترکیب کند. با استفاده از مجموعه داده ارزیابی، دقت دسته بندی مدل در طول SNR های مختلف مورد ارزیابی قرار گرفت که مشاهده گردید، مدل پیشنهادی SQACNN دارای پیشرفت های چشمگیری در دقت دسته بندی با دقت کلی ۷۱/۰۳ درصد و همچنین با حفظ دقت مطلوب به خصوص در شرایط SNR پایین، استحکام و پایداری مدل مورد تأیید می گیرد. این تحقیق نشان دهنده اثربخشی ترکیب معیارهای کیفیت سیگنال در فرایند یادگیری است و آن را به ابزاری مفید برای کاربردهای پردازش سیگنال در دنیای واقعی تبدیل می کند.

کلیدواژه ها: تشخیص مدولاسیون خودکار، یادگیری عمیق، شبکه عصبی کانولوشنال، رادیو شناختی

دانشگاه عالی دفاع ملی ♦ پژوهشکده آماد، فناوری دفاعی و عرصه های نوپدید / فصلنامه آماد و فناوری دفاعی



20.1001.1.28212606.1404.8.3.1.0

<https://amfad.sndu.ac.ir/> E-ISSN: 2980-8073



صحت مطالب بر عهده نویسنده مقاله است و بیانگر دیدگاه دانشگاه عالی دفاع ملی نیست.



مقدمه

پیشرفت سریع در استانداردها و فناوری‌های متنوع ارتباطات بی‌سیم، درک دقیق از طیف رادیویی را ضروری می‌سازد که برای مواردی چون جنگ الکترونیک، تحلیل تهدیدات نظامی و دسترسی به طیف پویا و شناسایی تداخل در محیط‌های غیرنظامی حیاتی است. با این وجود، استفاده گسترده از طیف در شبکه‌های متراکم متصل، برای پشتیبانی از حجم بالای ترافیک در سیستم‌های بی‌سیم، به مشکلاتی مانند تداخل کانال‌های مشترک و تحریف سیگنال منجر می‌شود. علاوه بر این، سیستم‌های ارتباطی پیشرفته معمولاً از پیکربندی‌های غیرهمکاری برای مدیریت هوشمندانه طیف استفاده می‌کنند که در آن سیگنال‌های رادیویی با استفاده از انواع شکل‌های مدولاسیون بر اساس نیازهای سیستم و شرایط کانال کدگذاری می‌شوند. شناسایی خودکار نوع مدولاسیون سیگنال‌های دریافتی برای گیرنده‌ها ضروری است تا بتواند سیگنال را به درستی دریافت کنند و توسعه الگوریتم‌های کارآمد شناسایی مدولاسیون را به یک اولویت در ارتباطات رادیویی تعریف شده توسط نرم‌افزار تبدیل می‌کند.

دسته‌بندی مدولاسیون خودکار^۱ (AMC) که پیش از مدولاسیون سیگنال در لایه فیزیکی قرار دارد، در حال حاضر مورد توجه فزاینده‌ای در جامعه پردازش سیگنال و ارتباطات قرار گرفته است. هدف اصلی AMC، دسته‌بندی نوع مدولاسیون سیگنال‌های دریافتی در گیرنده است که در واقع این عملیات یک فرایند تصمیم‌گیری چند کلاس در زمینه هوش مصنوعی محسوب می‌شود. ویژگی‌های سیگنال رادیویی، از جمله اطلاعات مدولاسیون، می‌توانند از طریق روش‌های مهندسی ویژگی‌های رایج مانند استخراج و انتخاب ویژگی، برای آموزش مدل‌های دسته‌بندی از طریق یادگیری ماشین نظارت شده یا بدون نظارت شناسایی شوند (Pham et al., 2021).

چالش اصلی، دسته‌بندی دقیق سیگنال‌ها در شرایط متفاوت و غالباً نامساعد، مانند نسبت سیگنال به نویز پایین^۲ (SNR) و تداخلات است که روش‌های مرسوم اغلب در مدیریت آن‌ها ناموفق می‌مانند. این مطالعه به دنبال توسعه مدلی قدرتمند در حوزه یادگیری عمیق است که

1. Automatic Modulation Classification

2. Signal to Noise Ratio



بتواند به‌طور مؤثر مدولاسیون‌های سیگنال‌های رادیویی را در طیف وسیعی از سطوح SNR دسته‌بندی کند و در نتیجه، کارایی و اطمینان سیستم‌های ارتباطی بی‌سیم را به‌خصوص در شبکه‌های رادیویی شناختی بهبود بخشد.

اهمیت دسته‌بندی مدولاسیون دقیق را نمی‌توان نادیده گرفت. این امر نقشی حیاتی در تضمین استفاده بهینه از طیف، کاهش تداخل، افزایش امنیت و بهبود کارایی کلی سیستم‌های ارتباطی دارد. به‌عنوان مثال، در شبکه‌های رادیویی شناختی، دسته‌بندی خودکار مدولاسیون، دسترسی مطمئن به طیف پویا را فراهم می‌آورد که برای رفع کمبود طیف حیاتی است. همچنین در کاربردهای نظامی، دسته‌بندی مدولاسیون دقیق می‌تواند به شناسایی و رهگیری انتقال داده‌های غیرمجاز کمک کند.

کاربرد دفاعی برجسته AMC در «جنگ الکترونیک»^۱ نهفته است. با تشخیص سریع مدولاسیون سیگنال‌های رهگیری شده، AMC به سیستم‌های نظامی اجازه می‌دهد تا تهدیدات بالقوه مانند تلاش‌های پارازیت یا جعل را شناسایی و مقابله کنند. علاوه بر این، AMC از عملیات اطلاعاتی، نظارتی و شناسایی^۲ (ISR) با ارائه بینش در مورد الگوهای ارتباطی متخاصم و پروتکل‌های زیربنایی آن‌ها پشتیبانی می‌کند.

علاوه بر این، AMC عملکرد شبکه‌های ارتباطی میدان نبرد را با امکان اشتراک‌گذاری و مدیریت یکپارچه طیف افزایش می‌دهد. این امر به‌ویژه در سناریوهایی که طیف الکترومغناطیسی به‌شدت شلوغ است بسیار مهم است؛ زیرا AMC امکان مدولاسیون تطبیقی و استراتژی‌های کدگذاری را فراهم می‌کند و استفاده کارآمد از طیف را در عین حفظ قابلیت اطمینان ارتباطات تضمین می‌کند. این برنامه‌ها بر اهمیت استراتژیک AMC در سیستم‌های دفاعی مدرن تأکید می‌کنند و آن را به یک فناوری اساسی برای شبکه‌های رادیویی شناختی در حوزه‌های نظامی و امنیتی تبدیل می‌کنند.

1. Electronic Warfare

2. intelligence, surveillance and reconnaissance

۱. پیشینه پژوهش

دسته‌بندی مدولاسیون دارای تاریخچه‌ای غنی است که ریشه در رویکردهای مبتنی بر نظریه‌های احتمال، مدل‌های فرضیه و روش‌های پردازش سیگنال رایج در دهه ۱۹۹۰ دارد. یکی از اولین روش‌ها، رویکردی بود که بر پایه ویژگی‌های چرخه‌ای استوار بود و در سال ۱۹۹۴ توسط «گاردنر»^۱ معرفی شد که از تناوب‌های ذاتی سیگنال‌های مدوله استفاده می‌کرد (Gardner, 1994). این روش، با وجود نوآوری، نیازمند طراحی ویژگی‌های پیچیده‌ای بود و نسبت به نویز و تغییرات شرایط سیگنال حساسیت داشت.

با پیدایش یادگیری ماشین، محققان به بررسی الگوریتم‌هایی نظیر ماشین‌های بردار پشتیبان^۲ (SVM) و K-نزدیک‌ترین همسایگان^۳ (KNN) پرداختند. به عنوان نمونه، «دوبره»^۴ و همکارانش در سال ۲۰۰۷، مروری جامع بر روش‌های یادگیری ماشینی که در AMC به کار رفته‌اند، ارائه دادند و بر استفاده از آمارگان مرتبه بالا و تجمع‌دهنده‌ها به عنوان ویژگی‌های کلیدی تأکید کردند (Dobre et al., 2007). با این وجود، این روش‌ها هنوز به طور گسترده‌ای به ویژگی‌های استخراج شده به صورت دستی وابسته بودند و در شرایط دارای اختلال با چالش‌هایی روبه‌رو شدند.

ظهور «یادگیری عمیق»^۵ (DL) تحول قابل توجهی را در AMC به ارمغان آورد. «شبکه‌های عصبی کانولوشنال»^۶ (CNN) به دلیل توانایی خود در استخراج خودکار ویژگی‌های مهم از داده‌های سیگنال خام محبوبیت پیدا کردند. در سال ۲۰۱۶، اُشی و همکاران (O'Shea et al., 2016) یک رویکرد مبتنی بر CNN ارائه کردند که از روش‌های متداول رایج در طبقه‌بندی ۱۱ نوع مدولاسیون مختلف بهتر عمل کرد؛ کار آن‌ها توانایی یادگیری عمیق را برای مدیریت پیچیدگی و تنوع سیگنال‌های دنیای واقعی نشان داد.

در سال ۲۰۱۸ ژانگ و سابونکو (Zhang & Sabuncu, 2018) یک روش جدید هم‌جوشی مدل

1. Gardner

2. Support Vector Machines

3. K-Nearest Neighbors

4. Dobre

5. Deep Learning

6. Convolutional Neural Networks



عمیق ناهمگن^۱ (HDMF) ابداع کردند که نقاط قوت CNN و «حافظه بلندمدت»^۲ (LSTM) را برای افزایش استخراج ویژگی در داده های سری زمانی ادغام می کند. هوانگ و همکاران (Huang et al., 2020) در سال ۲۰۲۰ بر روی روش های تقویت داده ها برای افزایش تعمیم و استحکام مدل با تولید نمونه های مصنوعی که تغییرات دنیای واقعی را شبیه سازی می کنند، تمرکز کردند. در سال ۲۰۲۱ نیز لو و همکاران (Lu et al., 2021) مدل شبکه عصبی عمیق و باقی مانده کوتاه مدت کانولوشنال^۳ (CLDR) را برای دسته بندی مدولاسیون معرفی کردند. با ترکیب شبکه های عصبی کانولوشن و «شبکه های باقی مانده»^۴، CLDR به مناسبی در محیط های پراختلال دست می یابد. قابل ذکر است، یک روش نرخ یادگیری چرخه ای تطبیقی، کارایی آموزش را افزایش می دهد. مطالعات اخیر برای پیشرفت این رشته ادامه داشته است. برای مثال در سال ۲۰۲۳ وانگ و همکاران (Wang et al., 2023) یک رویکرد مبتنی بر «شبکه عصبی گراف»^۵ (GNN) برای دسته بندی مدولاسیون، با استفاده از ساختار نمودار ذاتی داده های سیگنال پیشنهاد کردند. روش آن ها به طور مؤثر روابط پیچیده درون داده ها را ثبت کرد که منجر به دقت دسته بندی و استحکام بالاتر در برابر نویز شد.

با وجود این پیشرفت ها، چالش دسته بندی دقیق مدولاسیون ها در محیط های پُر اختلال همچنان ادامه دارد. مدل های موجود اغلب نرخ های دسته بندی اشتباه قابل توجهی را تحت سطوح مختلف SNR نشان می دهند.

۲. مدل سیستم

۲-۱. رادیو شناختی

«رادیو شناختی»^۶ یک فناوری ارتباطات بی سیم پیشرفته است که برای افزایش استفاده از طیف فرکانس رادیویی طراحی شده است. در سیستم های رادیویی شناختی، تخصیص طیف

1. Heterogeneous Deep Model Fusion
2. Long-Short Term Memory
3. Convolutional Long Short-Term Deep Neural and Residual Network
4. Residual Networks
5. Graph neural network
6. Cognitive Radio

به صورت پویا و هوشمندانه انجام می شود. به عبارت دیگر، این سیستم ها به کاربران بدون مجوز (کاربران ثانویه) اجازه می دهند تا از باندهای کم استفاده شده بدون تداخل با کاربران دارای مجوز (کاربران اصلی) استفاده کنند. این تطبیق پویا با استفاده از درک محیط، تحلیل پارامترهای انتقال و یادگیری از محیط انجام می شود (Ding et al., 2017).

از جمله کاربردهای رادیو شناختی می توان به موارد زیر اشاره کرد (Ding et al., 2017) :

❖ دسترسی به طیف پویا: امکان دسترسی کاربران به باندهای طیفی کم استفاده یا بی استفاده بدون تداخل که کارایی طیف را بهبود می بخشد و از خدمات ارتباطی بی سیم پشتیبانی می کند؛

❖ امنیت عمومی و شبکه های اضطراری: فراهم کردن کانال های ارتباطی قوی و انعطاف پذیر برای امدادگران در شرایط بحرانی با استفاده از طیف های موجود؛

❖ شبکه های حسگر بی سیم: افزایش کارایی و قابلیت اطمینان این شبکه ها از طریق تطبیق پویا با شرایط طیف، مفید برای سیستم های نظارت و کنترل محیطی و صنعتی؛

❖ اینترنت اشیا و شبکه های هوشمند: پشتیبانی از اتصال تعداد زیادی دستگاه متصل به هم در «اینترنت اشیا»^۱ و شبکه های هوشمند با ارتباط تطبیقی و کارآمد.

AMC یک جزء حیاتی در سیستم های رادیویی شناختی است. AMC فرایند شناسایی طرح مدولاسیون سیگنال دریافتی بدون اطلاع قبلی از پارامترهای سیگنال ارسالی است. نقش AMC در رادیو شناختی را می توان به شرح زیر بیان کرد (Ding et al., 2017) :

❖ سنجش و شناسایی طیف: شناسایی طرح مدولاسیون سیگنال ها برای تشخیص کاربران اولیه و ارزیابی اشغال طیف، جلوگیری از تداخل و تصمیم گیری هوشمندانه در دسترسی به طیف؛

❖ سازگاری و پیکربندی مجدد: تطبیق پارامترهای انتقال رادیوهای شناختی با تغییرات مدولاسیون کاربران اصلی برای حفظ ارتباط کارآمد؛

❖ افزایش قابلیت اطمینان ارتباطات: بهبود تفسیر سیگنال ها و ارتباطات قوی تر و بدون



خطا با دسته بندی دقیق مدولاسیون؛

❖ بهره وری طیف: انتخاب مناسب ترین کانال ها و پارامترهای انتقال با شناسایی دقیق


مدولاسیون ها برای استفاده کارآمد از طیف؛

❖ کاهش تداخل: شناسایی و کاهش منابع تداخل با استفاده از دسته بندی مدولاسیون.

رادیو شناختی نشان دهنده پیشرفت قابل توجهی در فناوری ارتباطات بی سیم است که امکان استفاده کارآمدتر و هوشمندانه تر از طیف فرکانس رادیویی را فراهم می کند. AMC نقش مهمی در بهبود سنجش طیف، سازگاری، قابلیت اطمینان، کارایی و کاهش تداخل در رادیوهای شناختی دارد و به کارکرد مستقل و انعطاف پذیر این سیستم ها در محیط های پویا و متنوع کمک می کند.

۲-۲. مدل سیستم

سیستم ارتباطی بی سیم مبتنی بر AMC همان طور که در شکل (۱)، مشخص شده است متشکل از فرستنده سیگنال، کانال ارسالی و گیرنده سیگنال است.



شکل ۱: سیستم ارتباطی بی سیم بر اساس پیشنهادی AMC

رابطه سیگنال دریافتی $r(t)$ در گیرنده سیگنال به صورت زیر خواهد بود:

$$r(t) = g[s(t)] * h(t) + n(t) \quad (1)$$

سیگنال ورودی $s(t)$ ابتدا توسط تابع مدولاسیون $g[\cdot]$ به سیگنال مدوله $g[s(t)]$ تبدیل شده و پس از آن از طریق کانال ارتباطی $h(t)$ به گیرنده منتقل می شود. $n(t)$ نیز «نویز جمع شونده سفید گوسی»^۱ است که با سیگنال ارسالی از کانال جمع می شود و در نهایت

1. Additive White Gaussian Noise

سیگنال دریافتی $r(t)$ تشکیل می‌شود.

کانال ارتباطی $h(t)$ نیز، یک کانال با محوشدگی چندمسیره انتخابی رایسین خواهد بود که به مشخصه زیر است:

$$h(t) = \sqrt{K} \cdot e^{j\phi} \cdot \delta(t - \tau_{LOS}) + \sum_{i=1}^L \alpha_i \cdot e^{j\phi_i} \cdot p(t - \tau_i) \quad (2)$$

در این معادله، K عامل K ام رایسین (نسبت «توان دید مستقیم»^۱ به توان پراکنده)، ϕ فاز مؤلفه، τ_{LOS} تأخیر مؤلفه، α_i بهره مختلط مؤلفه چند مسیره (i) ام، ϕ_i فاز مؤلفه چند مسیری (i) ام و $p(t)$ شکل پالس اجزای چند مسیری را نشان می‌دهند.

برای سیگنال رادیویی دریافتی $r(t)$ ، AMC به‌عنوان یک فرایند میانی بین تشخیص و دمدولاسیون در گیرنده عمل می‌کند. هدف پیش‌بینی الگوی مدولاسیون سیگنال‌های دریافتی، یعنی تابع $g[\cdot]$ و سپس ارائه اطلاعات مدولاسیون برای بازیابی سیگنال دمدوله شده $\hat{s}(t)$ از سیگنال دریافتی $r(t)$ است. به بیان دیگر وظیفه AMC را می‌توان به‌عنوان یک مسئله دسته‌بندی در یادگیری ماشین تلقی کرد؛ جایی که ورودی‌ها، توالی‌های زمانی پیچیده باند پایه سیگنال‌های رادیویی دریافتی و خروجی‌ها، الگوهای مدولاسیون مربوط به آن‌ها هستند.

۲-۳. مجموعه داده مورد استفاده

مجموعه داده استفاده‌شده، مجموعه داده RadioML2016.10a است (Shea & West, 2016). این مجموعه داده یک مجموعه‌ای از سیگنال‌های ارتباطی است که با استفاده از «رادیو گنو»^۲ با دقت ساخته شده‌اند. مشخصات این مجموعه داده در ادامه و در جدول (۱)، مشخص است.

جدول ۱: مشخصات مجموعه داده RadioML2016.10a

۱۱	تعداد مدولاسیون‌ها
BPSK, QPSK, 8-PSK, 16QAM, 64QAM, 4PAM, GFSK, CPFSK, WBFM, AM-SSB, AM-DSB	شکل‌های مدولاسیون
۱۲۸ نمونه مختلط	طول سیگنال

1. Line Of Sight
2. GNU Radio



محدوده SNR	-۲۰:۲۰ dB
تعداد کل سیگنال ها	۱۶۵۰۰۰
مشخصات کانال ارسالی	محوشدگی چند مسیری انتخابی ^۱ انحراف نرخ نمونه ^۲ انحراف فرکانس مرکزی ^۳ نویز جمع شونده سفید گوسی

سیگنال ها در این مجموعه داده به طول ۱۲۸ نمونه و به صورت IQ هستند. به طوری که هر سیگنال دارای ابعاد (۱۲۸ و ۲) است. فرم نمایشی X_n سیگنال n ام در مجموعه داده، به صورت زیر خواهد بود:

$$X_n = \begin{bmatrix} X_{I,0} & X_{I,1} & \dots & X_{I,S-1} \\ X_{Q,0} & X_{Q,1} & \dots & X_{Q,S-1} \end{bmatrix} \quad (۳)$$

در این رابطه، S نشان دهنده تعداد نمونه ها است. همچنین نوع مدولاسیون های هر یک از سیگنال ها نیز در یک آرایه به ابعاد (۱۶۵۰۰۰ و ۱) مشخص شده اند:

$$Y = [y_0^1 \quad y_1^2 \quad \dots \quad y_{N-1}^C] \quad (۴)$$

در این رابطه، C تعداد کل مدولاسیون های موجود در مجموعه داده را نشان می دهد و N نیز تعداد کل سیگنال های موجود را مشخص می کند. از کل تعداد سیگنال های موجود در مجموعه داده، ۷۰٪ برای آموزش، ۱۵٪ برای اعتبارسنجی و ۱۵٪ نیز برای ارزیابی استفاده شده اند.

۳. مدل پیشنهادی

۳-۱. شبکه عصبی کانولوشنال

شبکه های عصبی، الهام گرفته از مغز انسان، مدل های محاسباتی برای تشخیص الگوها و حل مسائل پیچیده هستند. شبکه های عصبی کانولوشنال، نوعی تخصصی از این شبکه ها برای

1. Selective Multipath Rician Fading
2. Sample Rate Offset
3. Center Frequency Offset

پردازش داده‌های ساختاریافته، مانند تصاویر و سیگنال‌ها، هستند. ساختار CNN شامل سه عنصر کلیدی کانولوشن، تابع فعال‌سازی غیرخطی و ادغام (نمونه‌برداری کاهشی) است. مزیت‌های CNN عبارتند از (Pham et al., 2021):

- ❖ تعاملات پراکنده: استفاده از هسته‌های کوچک‌تر از ورودی برای افزایش کارایی ذخیره‌سازی و عملکرد آماری؛
 - ❖ اشتراک‌گذاری پارامتر: اعمال هسته بر کل ورودی برای تولید نقشه ویژگی؛
 - ❖ تغییرناپذیری نسبت به ترجمه‌های ورودی: عملیات کانولوشن و ادغام، CNN ها را به این ویژگی می‌رساند؛
 - ❖ استخراج خودکار ویژگی‌های سطح بالا: برای استخراج اطلاعات ضروری.
- در طول فرایند آموزش، شبکه‌های عصبی کانولوشنی از تابع زیان برای سنجش اختلاف بین پیش‌بینی‌های خود و برچسب‌های صحیح استفاده می‌کنند. تابع زیان رایج برای مسائل دسته‌بندی، «آنتروپی متقاطع»^۱ است که رابطه آن به شرح زیر است (Ian Goodfellow, 2016):

$$\text{Categorical CrossEntropy} = - \sum_{i=1}^N y_i \log(\hat{y}_i) \quad (5)$$

که در آن y_i برابر با برچسب‌های صحیح و $\hat{y}_i$ نیز پیش‌بینی‌های مدل است.

۲-۳. ساختار مدل پیشنهادی

مدل پیشنهادی «SQACNN»^۲ با چندین لایه کانولوشنی ساخته شده است که هر یک برای استخراج ویژگی‌های مهم از سیگنال‌های ورودی طراحی شده‌اند. این معماری در جدول (۲)، قابل مشاهده است. لایه‌های استفاده شده در این مدل عبارتند از: «لایه‌های کانولوشن یک‌بعدی»، «لایه‌های ادغام یک‌بعدی»، «لایه‌های نرمال‌سازی دسته‌ای»، «لایه‌های کاملاً متصل» و «لایه حذف تصادفی».

1. Cross-Entropy

2. Signal Quality-Adaptive Convolutional Neural Network



در این مدل از لایه‌های کانولوشن یک‌بُعدی (Conv1D) استفاده شده که اغلب در مدل‌های یادگیری عمیق برای داده‌های توالی مانند سری‌های زمانی، سیگنال‌های صوتی و متون به کار می‌روند (Ian Goodfellow, 2016).

لایه‌های ادغام، اجزای حیاتی در معماری شبکه‌های عصبی کانولوشنی هستند. آن‌ها به کاهش ابعاد فضایی کمک می‌کنند، ضمن اینکه ویژگی‌های مهم داده‌های ورودی را حفظ می‌نمایند (Ian Goodfellow, 2016).

استفاده از لایه‌های نرمال‌سازی دسته‌ای برای آموزش پایدار و کارآمد حیاتی است. این فرایند شامل مقیاس‌بندی ویژگی‌ها برای رسیدن به میانگین صفر و واریانس واحد است. نرمال‌سازی به جلوگیری از مشکلات ناپدید شدن یا انفجار گرادیان‌ها کمک می‌کند که می‌تواند مانع از همگرایی در طول آموزش شود (Ioffe & Szegedy, 2015).

لایه کاملاً متصل، هر نورون (واحد) را از لایه قبلی به هر نورون در لایه فعلی متصل می‌کند. این ساده‌ترین نوع لایه است که در آن هر ویژگی ورودی به هر ویژگی خروجی کمک می‌کند.

جدول ۲: ساختار معماری مدل پیشنهادی


پارامترها	اندازه خروجی	لایه‌ها
-	2×128	ورودی
۱۹۲	$2 \times 125 \times 64$	کانولوشن یک‌بُعدی ۱
-	-	نرمال‌ساز دسته‌ای
۱۹۲	$2 \times 124 \times 64$	کانولوشن یک‌بُعدی ۲
-	-	نرمال‌ساز دسته‌ای
-	$2 \times 62 \times 64$	ادغام حداکثری یک‌بُعدی ۱
۷۳۸۵۶	$2 \times 61 \times 128$	کانولوشن یک‌بُعدی ۳
-	-	نرمال‌ساز دسته‌ای
۷۳۸۵۶	$1 \times 60 \times 128$	کانولوشن یک‌بُعدی ۴
-	-	نرمال‌ساز دسته‌ای
-	$1 \times 30 \times 128$	ادغام حداکثری یک‌بُعدی ۲
۲۹۵۱۶۸	$1 \times 29 \times 256$	کانولوشن یک‌بُعدی ۵

پارامترها	اندازه خروجی	لایه‌ها
-	-	نرمال‌ساز دسته‌ای
۲۹۵۱۶۸	$1 \times 28 \times 256$	کانولوشن یک‌بعدی ۶
-	-	نرمال‌ساز دسته‌ای
-	$1 \times 14 \times 256$	ادغام حداکثری یک‌بعدی ۳
۱۱۸۰۱۷۰	$1 \times 13 \times 512$	کانولوشن یک‌بعدی ۷
-	-	نرمال‌ساز دسته‌ای
-	1×512	ادغام میانگین سراسری یک‌بعدی
-	-	حذف تصادفی (۰/۴)
۱۳۱۳۲۸	1×256	کاملاً متصل ۱
۳۲۸۹۶	1×128	کاملاً متصل ۲
۸۲۵۶	1×64	کاملاً متصل ۳
۷۱۵	1×11	خروجی
۱۸۱۹۳۶۳	-	تعداد کل مقادیر

لایه‌های «حذف تصادفی»^۱ نیز به عنوان یک نوع منظم‌سازی عمل می‌کند که از بیش برآزش جلوگیری می‌کند. در طول آموزش، حذف تصادفی به صورت تصادفی بخشی از خروجی‌های نوروها را صفر می‌کند (آن‌ها را حذف می‌کند) (Srivastava et al., 2014).

۳-۳. آموزش مدل پیشنهادی

سیگنال‌های موجود در مجموعه داده پس از آماده‌سازی و انجام عملیات پیش‌پردازشی لازم همانند نرمال‌سازی، بُر زدن^۲، قرار دادن در دسته‌های ۶۴ تایی آماده ورود به مدل برای آموزش خواهند بود. طرح کلی آموزش مدل در شکل (۲)، نمایان است.



شکل ۲: فرایند آموزش مدل پیشنهادی

1. Dropout
2. Shuffle



برای دستیابی به تابع زیان (ضرر) تطبیقی مورد نظر، لازم است که سه تابع برای محاسبه «ضرایب پخش سیگنال»^۱، «فشردگی ویژگی»^۲ و «تنظیم SNR»^۳ و کارایی آن ها و نحوه به کارگیری شان در تابع زیان پرداخته می شود. در این بخش، برای نوشتن توابع از مرجع (Zheng et al., 2023) الهام گرفته شده است.

۳-۳-۱. ضریب تنظیم SNR

در مجموعه داده $D: \{(x_n, y_n)\}_{n=1}^N$ ، فرض می کنیم به تعداد N_+ نمونه با نرخ SNR بزرگ تر از آستانه γ به عبارتی $s_n > \gamma$ و نیز به تعداد N_- نمونه با نرخ SNR کم تر از آستانه γ به عبارتی $s_n < \gamma$ داریم که مجموع این دو برابر با N است. آستانه را می توان به عنوان میانگین انحراف SNR تمام نمونه ها تعریف کرد که محاسبه آن به شکل زیر است (Zheng et al., 2023):

$$\gamma = \frac{1}{N} \sum_{n=1}^N s_n + \epsilon \quad (۶)$$

که در آن ϵ یک ضریب برای انحراف آستانه است که می توان به صورت دستی آن را تنظیم کرد.

به طور مشابه، تعداد نمونه های مثبت و منفی در یک دسته کوچک به صورت M_+ و M_- فرض می شود که مجموع آن ها برابر M است. در این صورت تابع زیان وزن دهی شده در D_t ، دسته t ام مجموعه داده، برابر است با (Zheng et al., 2023):

$$\tilde{L}(x, y) = \eta_f(L(x, y)) \quad (۷)$$

که $L(x, y)$ تابع زیان آنتروپی متقاطع ذکر شده در معادله (۳-۷) و η_f ضریب تنظیم SNR، به شرح زیر است (Zheng et al., 2023):

-
1. Signal Spreading Factor
 2. Feature Compression Factor
 3. SNR-Adjustment Factor

$$\eta_f = \begin{cases} 1 + \sqrt{\frac{M_-}{M_+}} \cdot \text{SNR} > \gamma \\ 1 + \sqrt{\frac{M_+}{M_-}} \cdot \text{SNR} \leq \gamma \end{cases} \quad (۸)$$

با فرض اینکه سیگنال‌های دریافتی مستقل از یکدیگر هستند، ضریب تنظیم SNR، در D_t یک متغیر دوگانه است که توزیع زیر را برآورده می‌کند (Zheng et al., 2023):

$$\eta_f \sim \begin{cases} 1 + \sqrt{\frac{M_-}{M_+}} \cdot \text{Prob} = \frac{M_+}{M} \\ 1 + \sqrt{\frac{M_+}{M_-}} \cdot \text{Prob} = \frac{M_-}{M} \end{cases} \quad (۹)$$

می‌توان نتیجه گرفت که زمانی که نمونه‌ها در یک دسته کوچک دارای SNR های متفاوت هستند، ضریب تنظیم SNR برای نمونه‌های مثبت بیش از یک است و در نتیجه تابع زیان و جهت گرادیان آن‌ها تقویت می‌شود. در مقابل، ضریب تنظیم SNR برای نمونه‌های منفی کمتر از یک است و تابع زیان و جهت گرادیان آن‌ها تضعیف می‌شود. این امر باعث می‌شود تا فاصله بین کلاسی برای سیگنال‌های با SNR های مختلف افزایش یابد و به تصمیم‌گیری تطبیقی و تعمیم‌پذیری بیشتری منجر شود. همچنین با ایجاد نمونه‌های فشرده‌تر درون کلاسی به افزایش فاصله بین کلاسی کمک می‌کنند که این امر به کاهش محدودیت‌ها در تشکیل مرزهای تصمیم‌گیری در مدل‌های یادگیری عمیق منجر می‌شود.

۳-۲-۳. ضریب پخش سیگنال

تابع ضریب پخش سیگنال، تغییرات نمونه‌ها را در یک دسته بر اساس میانگین آن‌ها محاسبه می‌کند. این برای فهمیدن میزان گسترش یا پراکندگی کلی داده‌ها در یک دسته به کار می‌رود. رابطه آن به شکل زیر خواهد بود:

$$F_s = \mathbb{E} \left[\left(\sqrt{\sum_{i=1}^M (X_i - \mu)^2} - \mathbb{E} \left[\sqrt{\sum_{i=1}^M (X_i - \mu)^2} \right] \right)^2 \right] \quad (۱۰)$$



که در آن X_i بیانگر نمونه i -ام در دسته و μ نیز بیانگر میانگین دسته است. رابطه μ به شرح زیر خواهد بود:

$$\mu = \frac{1}{N} \sum_{i=1}^N X_i \quad (11)$$

ضریب پخش سیگنال، معیاری برای اندازه‌گیری پراکندگی داده‌ها از میانگین است. این می‌تواند برای فهمیدن تنوع کلی در یک مجموعه داده مهم باشد که می‌تواند به نوبه خود بر فرایند یادگیری تأثیر بگذارد. واگرایی بالاتر، نشان‌دهنده مجموعه داده‌ای با تنوع بیشتر است که می‌تواند به تعمیم بهتر مدل کمک کند.

۳-۳-۳. ضریب فشردگی و ویژگی

تابع ضریب فشردگی و ویژگی، هنجار ماتریس کوواریانس انحرافات نمونه‌ها از میانگینشان را محاسبه می‌کند. این اطلاعات بینشی درباره ساختار داخلی و روابط میان ابعاد داده‌ها فراهم می‌آورد؛ رابطه آن برابر است با (Zheng et al., 2023):

$$F_c = \|\psi\| \quad (12)$$

که ψ ماتریس کوواریانس انحرافات نمونه‌ها به رابطه زیر است (Zheng et al., 2023):

$$\psi = \frac{1}{M} \sum_{i=1}^M (X_i - \mu)(X_i - \mu)^T \quad (13)$$

و $\|\cdot\|$ نیز بیانگر «نرم فروبنیوس»^۱ به رابطه زیر است (Zheng et al., 2023):

$$F_c = \|\psi\| = \sqrt{\sum_{i=1}^S \sum_{j=1}^2 [\psi(i,j)]^2} \quad (14)$$

ضریب فشردگی و ویژگی، کوواریانس یا همبستگی متقابل بین ابعاد مختلف داده‌ها را می‌سنجد. این امر به فهم همبستگی داخلی میان داده‌ها کمک می‌کند که می‌تواند در بهبود عملکرد مدل‌ها از طریق اطمینان از ضبط مؤثر ساختارهای زیرین داده‌ها، حیاتی است.

1. Frobenius Norm

این سه تابع در قالب یک تابع زیان سفارشی به کار می‌روند که برای تنوع و کیفیت داده‌ها، به بهبود فرایند یادگیری کمک می‌کنند. ضرایب پخش سیگنال و فشردگی ویژگی به فهم بهتر گسترش داده‌ها و ساختار درونی آن‌ها کمک می‌کند، درحالی‌که ضریب تنظیم SNR به صورت پویا بر اساس کیفیت سیگنال تنظیم می‌شود. این اجزا در کنار هم اطمینان می‌دهند که مدل به شکلی متوازن یادگیری کند و هم دقت و هم توانایی تعمیم آن را افزایش می‌دهند.

۳-۳-۴. تابع زیان تطبیقی

برای اعمال ضرایب پخش سیگنال و فشردگی در هر دسته کوچک در طول فرایند آموزش، برای تقویت اطلاعات متمایز، از متغیر تنظیمی زیر استفاده می‌شود:

$$r = \tau_1 \frac{1 - e^{-\tau_2 \frac{F_c}{F_s}}}{1 + e^{-\tau_2 \frac{F_c}{F_s}}} \quad (15)$$

که در آن τ_1 نشان دهنده ضریب تنظیم پیشینی است که به ویژگی‌ها و توزیع نمونه‌ها در هر دسته کوچک بستگی دارد. τ_1 و τ_2 به ترتیب ضرایب خطی و نمایی هستند که به صورت دستی تنظیم می‌شوند.

در نهایت تابع زیان تطبیقی، به شرح زیر خواهد بود:

$$\hat{L} = r \cdot \tilde{L}(x, y) = r \cdot \eta_f \cdot (L(x, y)) = \varphi \cdot L(x, y) \quad (16)$$


که در آن φ همان ضریب تطبیقی است که در نهایت به یک تابع زیان رایج و غیرسفارشی شده اضافه می‌شود تا بتوان به نتایج حاصله رسید.

هنگامی که نسبت نمونه‌های مثبت به منفی در یک دسته کوچک ۱ به ۲ است، رابطه بین ضریب تطبیقی، نسبت واگرایی $\frac{F_c}{F_s}$ و دو ضریب τ_1 و τ_2 در شکل شماره ۳ نشان داده شده است. τ_1 کنترل‌کننده تأثیر اطلاعات متمایز بر شیب‌ها است، درحالی‌که τ_2 آستانه اشباع اطلاعات متمایز را تعیین می‌کند. یک τ_1 خیلی بزرگ منجر به شیب بیش‌ازحد می‌شود، به‌طوری که شبکه را نمی‌توان به‌طور پایدار آموزش داد. یک τ_2 خیلی کوچک نیز باعث می‌شود که گرادیان به شدت کاهش یابد و در نتیجه بر سرعت آموزش مدل تأثیر بگذارد.



هنگامی که τ_2 از عدد ۷ تجاوز می کند، تغییرات آن به ندرت بر عامل تنظیم پیشینی تأثیر می گذارد.

تابع زیان تطبیقی، تابع زیان دسته بندی استاندارد را با شرایط اضافی ترکیب می کند که در آن تابع، پراکندگی داده ها، ساختار داخلی و کیفیت سیگنال را در نظر می گیرد. این به فرایند یادگیری متعادل تر و قوی تری منجر خواهد شد و دقت و توانایی تعمیم مدل را افزایش می دهد.



شکل ۳: رابطه بین ضریب تطبیقی، نسبت واگرایی و ضرایب خطی و نمایی

۴. ارزیابی مدل پیشنهادی

برای طی فرایند آموزش مدل، در ابتدا لازم است تا مقادیر «هایپرپارامتر»^۱ مشخص شوند که در جدول (۳)، معلوم هستند.

جدول ۳: مقادیر هایپرپارامترها در طول فرایند آموزش

۰/۰۱	نرخ یادگیری اولیه α_0
۶۴	اندازه دسته M
۰/۰۰۰۵	نرخ تنزل وزن ^۲

1. Hyperparameter
2. Weight Decay Rate

۲	ضریب انحراف آستانه ϵ
۰/۹	ضریب خطی τ_1
۶	ضریب نمایی τ_2

پس از مقداردهی‌های اولیه، مدل با مشخصات ذکر شده در حلقه مد نظر ابتدا به اصطلاح پیش‌خور می‌شود و سپس با محاسبه خروجی و مقدار زیان با استفاده از تابع زیان تطبیقی، از وزن‌های قابل یادگیری در شبکه، مشتق زنجیره‌ای گرفته و با توجه به روش بهینه‌ساز، تغییرات در وزن‌ها اعمال می‌گردد. هرچند که فرایند کلی پیچیده به نظر می‌رسد؛ اما این توابع با تغییر دادن تابع زیان، به راحتی در فرایند آموزش شبکه قابل اجرا است.

جدول ۴: الگوریتم فرایند آموزشی مدل با استفاده از تابع زیان تطبیقی


Input: training set $D: \{(x_n, y_n)\}_{n=1}^N$.
Initialization: parameters θ_0 , learning rate α_0 , batch size M , SNR threshold γ , linear and exponential coefficients τ_1, τ_2 .
Training Loop:
 1: **for** each epoch:
 2: update the learning rate in Eq. (1-5);
 3: **for** each mini-batch of training data $D_t = \{x_1, x_2, \dots, x_M\} \subseteq D$:
 4: compute F_s in Eq. (10);
 5: compute F_c in Eq. (14);
 6: perform forward-propagation through the model;
 7: compute $\hat{L}$ in Eq. (16-4);
 8: compute gradients;
 9: update model weights θ_{t+1} ;
Output: the trained deep learning model (M).

سخت‌افزار مورد استفاده برای آموزش و آزمایش این مدل متشکل از دستگاه‌های i7 2.9 GHz CPU، 32 GB RAM و NVIDIA GeForce RTX 3090 GPU هستند. در ادامه نتایج به‌دست‌آمده مورد بررسی قرار خواهند گرفت.



۴-۱. عملکرد دسته‌بندی مدولاسیون

همان‌طور که شکل (۴)، نشان می‌دهد، ابتدا به ارائه منحنی‌های بهینه‌سازی برای مدل CNN با استفاده از تابع زیان تطبیقی و بدون استفاده از تابع زیان تطبیقی، که در حقیقت از تابع زیان استاندارد آنتروپی متقاطع استفاده شده است، پرداخته شده است. ملاحظه می‌شود که تابع زیان تطبیقی تأثیر زیادی بر سرعت همگرایی مدل دارد. علاوه بر این، مشاهده می‌شود که مدل به حالت پایدار همگرایی می‌یابد، با وجود اینکه مجموعه داده‌ها شامل سیگنال‌هایی با دامنه‌های متفاوت SNR هستند.




شکل ۴: منحنی‌های بهینه‌سازی مدل CNN با/بدون تابع زیان تطبیقی
برای دو مجموعه داده آموزش و اعتبارسنجی

در جدول (۵)، تلفات AMC و دقت مدل در مراحل آموزش، اعتبارسنجی و تست گزارش شده است. مشاهده می‌شود که دقت دسته‌بندی با استفاده از تابع زیان تطبیقی در مدل پیشنهادی برابر با $70/83$ درصد شده است که به میزان $2/12$ درصد بیشتر از دقت دسته‌بندی در مدل CNN با استفاده از تابع زیان استاندارد $68/71$ درصد است. همچنین شکاف دقت بین مجموعه‌های اعتبارسنجی و آزمایش نیز کاهش یافته که به کاهش خطاهای تعمیم منجر می‌شود.

جدول ۵: مقایسه تلفات و دقت برای مجموعه داده‌های مختلف برای هر دو مدل

مدل	تلفات			دقت دسته‌بندی بر حسب درصد		
	مجموعه آموزشی	مجموعه اعتبارسنجی	مجموعه ارزیابی	مجموعه آموزشی	مجموعه اعتبارسنجی	مجموعه ارزیابی
CNN با تابع زیان تطبیقی (SQACNN)	۰/۴۹۴۰	۰/۸۳۸۷	۰/۸۴۱۲	۷۹/۳۰	۷۰/۹۹	۷۱/۰۳
CNN بدون تابع زیان تطبیقی	۰/۶۷۴۱	۰/۹۰۴۹	۰/۹۰۳۷	۷۴/۲۷	۶۹/۰۲	۶۸/۷۱

در شکل (۵)، نیز دقت دسته‌بندی دو مدل CNN با تابع زیان تطبیقی (SQACNN) و CNN بدون تابع زیان تطبیقی (Standard CNN) در طول SNR های مختلف نمایش داده شده‌اند. همان‌طور که مشخص است مدل SQACNN توانسته است تا موجب بهبود چشمگیری در دقت دسته‌بندی، به‌خصوص در محیط‌هایی با SNR های پایین شود. به‌طوری‌که در کمترین SNR ممکن برابر با (۲۰ dB-)، بهبود ۱۳/۶۸ درصد شده است.




شکل ۵:

مقایسه دقت دسته‌بندی برای هر دو مدل SQANN و Standard CNN در طول SNR های مختلف

با در نظر گرفتن چندین SNR مختلف (۱۸، ۰، -۱۰ و -۲۰)، ماتریس درهم‌ریختگی مدل پیشنهادی را برای بررسی دقت دسته‌بندی طرح‌های مدولاسیون مختلف در شکل (۶)، نشان می‌دهیم. در SNR برابر با ۲۰ dB-، این مدل در دسته‌بندی بسیاری از انواع مدولاسیون با خطا مواجه است. عملکرد آن در سطوح پایین SNR ضعیف است، که این امر دشواری‌های



تشخیص انواع مدولاسیون در شرایط پراختلال را نشان می دهد؛ هرچند که در مدولاسیون AM-SSB توانسته به تشخیص بالای ۵۰٪ برسد. مشخص است که مدل با استفاده از تابع زیان تطبیقی می تواند در برابر تأثیرات نویز در مقاومت کند. با افزایش SNR به ۱۰dB- عملکرد بهبود چشمگیری می یابد و دقت ۲۵/۲۰ درصد افزایش یافته است. هرچند همچنان سردرگمی بین انواع مدولاسیون مشابه مشاهده می شود؛ اما افزایش SNR به کاهش نویز کمک کرده و در نتیجه به دسته بندی دقیق تر منجر می شود. در SNR برابر با ۰ dB دقت به طور قابل توجهی افزایش یافته و از ۸۶٪ عبور کرده است و مدل عملکرد بسیار خوبی از خود نشان می دهد. اکثر انواع مدولاسیون به جز چند مورد دسته بندی اشتباه به درستی تشخیص داده می شوند. با افزایش SNR، دقت دسته بندی به تدریج به حدود ۹۰٪ می رسد.



شکل ۶: ماتریس درهم ریختگی مدل پیشنهادی SQANN

در SNR بالاتر، برخی از مدولاسیون‌ها مانند 16QAM و 64QAM^۱ و WBFM^۱ و AM-DSB^۲ هنوز به اشتباه دسته‌بندی می‌شوند. چراکه نقاط صورت فلکی 16QAM توسط 64QAM پوشانده می‌شود، تشخیص 64QAM که حاوی بیت‌های خاصی از 16QAM است، دشوار است. درباره دسته‌بندی WBFM و AM-DSB هم می‌توان گفت که سیگنال‌های صوتی آنالوگ که دوره‌های خاموشی دارند و تنها با زنگ‌های حامل هستند، شناسایی آن‌ها دشوار است. البته تعداد کم نقاط نمونه‌برداری (۱۲۸ نقطه) سیگنال‌های دریافتی منجر به از دست رفتن اطلاعات شده و ایجاد رابطه بین سیگنال و طرح مدولاسیون را برای مدل چالش‌برانگیز کرده است.

۲-۴. مقایسه با دیگر روش‌های پیشرفته AMC

برای اثبات برتری مدل پیشنهادی، جدول (۶)، مقایسه‌ای با دیگر روش‌های پیشرفته در مجموعه داده RadioML2016.10a ارائه می‌کند. این مقایسه شامل روش‌های زیر می‌شود LSTM+priori regularization (Zheng et al., 2023)، SCNN (Zeng et al., 2019)، ساده^۳ (Sang & Li, 2018)، ترکیبی^۴ (Wu et al., 2018)، LSTM-IQFOC (Zhang &)، CM-CNN (Sabuncu, 2018b)، CM-CNN (Yashashwi et al., 2018)، SVM (Yang et al., 2016)، همچنین DNN (Xie et al., 2019)، که از «ویژگی‌های تجمعی مرتبه بالا»^۵ استفاده می‌کنند. بر اساس منحنی دقت دسته‌بندی مدل که در مقاله‌های اصلی تحت SNRهای مختلف ارائه شده است، دقت دسته‌بندی برآورد شده روش‌های مقایسه‌ای در این جدول خلاصه گردیده است.

نتایج مقایسه نشان می‌دهد که مدل پیشنهادی دقت بالایی در دسته‌بندی در اغلب SNRها به‌خصوص در شرایط SNR پایین را دارا است که این نشان‌دهنده استحکام آن در محیط‌های پُراختلال است. با افزایش SNR، عملکرد همه مدل‌ها بهبود می‌یابد؛ اما SQACNN به‌طور

-
1. Wide Band Frequency Modulation
 2. Amplitude Modulation Double Side Band
 3. Naive LSTM
 4. Hybrid LSTM
 5. High-Order Cumulant Feature



مداوم دقت بالاتری را حفظ می کند؛ این نشان می دهد که SQACNN می تواند به طور مؤثر از اطلاعات اضافی سیگنال، موجود در SNR های بالاتر استفاده کند.

جدول ۶: مقایسه دقت دسته بندی مدولاسیون در روش های مختلف

روش های AMC	دقت دسته‌بندی در طول SNR های مختلف بر حسب درصد										
	-۲۰ dB	-۱۶ dB	-۱۲ dB	-۸ dB	-۴ dB	۰ dB	۴ dB	۸ dB	۱۲ dB	۱۶ dB	میانگین
SCNN	~۱۰	~۱۰	~۲۰	~۳۶	~۶۰	~۸۰	~۸۲	~۹۲	~۹۰	~۸۸	۵۶/۸
Naive LSTM	~۱۰	~۱۰	~۱۴	~۳۶	~۷۴	~۸۷	~۹۰	~۹۱	~۹۱	~۹۰	۵۹/۳
Hybrid LSTM	~۱۰	~۱۰	~۱۴	~۳۰	~۶۴	~۸۰	~۸۳	~۸۲	~۸۲	~۸۲	۵۳/۷
LSTM-IQFOC	~۱۲	~۱۲	~۲۰	~۴۲	~۷۱	~۸۴	~۸۵	~۸۶	~۸۶	~۸۷	۵۸/۶
CM-CNN	~۹	~۱۰	~۱۸	~۳۸	~۶۴	~۸۶	~۸۸	~۸۹	~۹۰	~۸۸	۵۸/۰
SVM	~۹	~۱۰	~۱۴	~۳۲	~۶۲	~۷۸	~۸۱	~۸۳	~۸۳	~۸۲	۵۳/۴
DNN-cumulant	~۱۰	~۱۱	~۱۵	~۳۴	~۶۵	~۷۶	~۸۲	~۸۳	~۸۶	~۸۷	۵۵/۰
CNN-LSTM+priori regularization	~۱۵	~۱۶	~۲۴	~۴۷	~۷۸	~۸۹	~۹۲	~۹۳	~۹۴	~۹۴	۶۴/۲
SQACNN	۳۳/۶۶	۳۷/۱۸	۴۴/۶۷	۶۲/۵۱	۷۸/۱۱	۸۶/۸۲	۸۷/۷۸	۸۹/۲۳	۸۹/۰۱	۸۸/۴۲	۷۱/۰۳

در میان آن ها، SQACNN که با استفاده از تابع زیان تطبیقی آموزش دیده، میانگین دقت را تقریباً ۷ درصد افزایش داده و بالاترین میانگین دقت دسته بندی را با ۷۱/۰۳ درصد کسب کرده است. این نشان می دهد که به طور متوسط، SQACNN برترین عملکرد دسته بندی را در سطوح مختلف نویز ارائه می دهد. همچنین SQACNN برخلاف برخی از مدل های دیگر که نوسانات قابل توجهی در عملکرد نشان می دهند، بهبود عملکرد ثابتی را در تمام سطوح SNR نشان می دهد.

جدول به وضوح نشان می دهد که مدل SQACNN در مقایسه با سایر مدل های AMC، در طیف وسیعی از سطوح SNR عملکرد بهتری دارد. مقاومت آن در شرایط پایین SNR و


عملکرد قوی در محیط‌های با SNR بالا، اثربخشی و اعتمادپذیری آن را برای دسته‌بندی مدولاسیون خودکار متمایز می‌کند. دقت متوسط بالاتر، برتری مدل SQACNN را تقویت کرده و آن را به گزینه‌ای مطلوب‌تر برای انجام وظایف AMC در شرایط مختلف سیگنال تبدیل می‌کند.

با وجود ترکیب مدل‌های متعددی مانند CM و CNN برای بهبود برازش داده‌ها، افزایش تعداد پارامترها همیشه به بهبود دقت دسته‌بندی منجر نمی‌شود. روش‌های مبتنی بر ترکیب استخراج ویژگی و دسته‌بندی‌کننده کمترین دقت دسته‌بندی را دارند، مثلاً ۵۳/۴ درصد (SVM) و ۵۵/۰ درصد (DNN). ویژگی‌های رایج به‌سادگی تحت تأثیر عواملی مثل محوشدگی چند مسیری و اثر سایه قرار می‌گیرند که توصیف دقیق الگوی مدولاسیون سیگنال‌های دریافتی را دشوار می‌کند. ویژگی‌های دستی معمولاً سقف عملکرد دسته‌بندی‌کننده را تعیین می‌کنند؛ درحالی‌که مدل‌های یادگیری عمیق با استفاده از تابع زیان تطبیقی می‌توانند اطلاعات سیگنال‌ها را به‌طور کامل استخراج کنند.

۳-۴. ارزیابی مدل با داده‌های نویز اضافه‌شده

فرض گرفته می‌شود که در دنیای واقعی، سیگنال‌ها به همراه یک رشته نویز دریافت می‌شوند. از این رو سعی می‌شود تا یک رشته نویز بر روی سیگنال‌های موجود در مجموعه داده تست اضافه شود تا بتوان عملکرد مدل آموزش دیده را بر روی این داده‌ها نیز امتحان شود.

برای این امر، یک سیگنال نویز با توان نویز ثابت AWGN با میانگین صفر و واریانس صفر و به طول ۲۵٪ و ۴۰٪ از سیگنال اصلی که ۱۲۸ نمونه دارد، ایجاد می‌شود که به معنی ایجاد سیگنال‌های نویز به طول ۲۵ و ۵۰ نمونه است. در نهایت طول سیگنال نهایی به ترتیب ۱۵۳ و ۱۷۸ نمونه خواهد بود. این سیگنال‌های نویز در سه مکان ابتدا، انتها و به‌صورت تصادفی در بین سیگنال قرار داده می‌شوند. شکل (۷)، یک سیگنال در فرمت IQ با مدولاسیون 16QAM و SNR برابر با ۶ dB و به طول ۱۲۸ نمونه و سیگنال نویز به طول ۲۵ را که به‌طور تصادفی درون سیگنال جای داده شده است، نشان می‌دهد.



شکل ۷: نمایش سیگنال با مدولاسیون 16QAM بدون و به همراه نویز اضافه شده


مدلی که آموزش داده شده است، برای داده‌های ورودی به اندازه (۱۲۸ و ۲) کار می‌کند. اما این سیگنال‌ها دارای طول‌های بزرگ‌تر از نیاز هستند. به این منظور باید تغییراتی در سیگنال‌های جدید انجام داده شود، به طوری که اندازه آن‌ها مورد قبول مدل شود. دو رویکرد را می‌توان دنبال کرد؛ رویکرد اول این است که طول سیگنال‌ها را تغییر داد تا به اندازه مدنظر برسند که می‌توان سیگنال‌ها برش داده شوند که برای این کار نیز از سیستم رأی‌گیری اکثریت استفاده می‌شود.

رأی‌گیری اکثریت یک روش ساده، اما قدرتمند است که در یادگیری جمعی، ترکیب تصمیمات یا تشخیص الگو برای اتخاذ یک تصمیم نهایی بر اساس اکثریت آرای فردی استفاده می‌شود.

در این روش سیگنال به همراه نویز اضافه شده که دارای طولی بزرگ‌تر از اندازه ورودی به مدل است، به سه سیگنال جداگانه تقسیم می‌شود. به این صورت که اگر سیگنال به همراه نویز ۲۵ نمونه باشد، طول سیگنال ۱۵۳ خواهد بود. از این سیگنال به طول ۱۵۳، سه سیگنال اولی از ابتدا سیگنال و به طول ۱۲۸، دومی از انتها سیگنال و به طول ۱۲۸ و در نهایت سومی از وسط سیگنال و به طول ۱۲۸ گرفته شده و این سیگنال‌ها به مدل داده می‌شوند تا مدل نوع مدولاسیون را پیش‌بینی کند. پس برای هر سیگنال به طول بیشتر از اندازه ورودی مدل سه پیش‌بینی به دست می‌آید. از این سه پیش‌بینی، هر کدام که در اکثریت قرار بگیرد، به عنوان

پیش‌بینی نهایی سیگنال در نظر گرفته می‌شود و در صورتی که هر سه پیش‌بینی‌ها دارای آرای جداگانه بودند، هرکدام یک که درجه اطمینان بیش‌تری در نظر خود داشته باشد، به‌عنوان نظر نهایی در نظر گرفته می‌شود. در شکل (۸)، ارزیابی مدل بر روی مجموعه داده‌های به همراه نویز با استفاده از روش رأی‌گیری اکثریت نمایش داده شده است.

مشاهده می‌شود که بیشترین تأثیر نویز هنگام اضافه شدن آن در وسط سیگنال اتفاق می‌افتد و معلوم است که طول بزرگ‌تر نویز باعث تأثیر بیشتر بر روی دقت می‌شود. روش رأی اکثریت بخش‌های متعددی از سیگنال را تحت تأثیر قرار می‌دهد و تأثیر نویز را بر هر بخش کاهش می‌دهد؛ هرچند که باز تأثیر این نویز اضافه شده بر روی نمودار مشخص است. همچنین روش رأی اکثریت در برابر نویز قوی‌تر و مقاوم‌تر است؛ زیرا پیش‌بینی‌های چند بخش را ترکیب می‌کند. حتی اگر یک بخش دارای نویز باشد، بخش‌های دیگر می‌توانند به تصحیح پیش‌بینی نهایی کمک کنند و حتی اگر هر سه پیش‌بینی متفاوت باشند، پیش‌بینی با بالاترین اطمینان انتخاب می‌شود و لایه‌ای از قابلیت اطمینان به این روش اضافه می‌شود.



شکل ۸:

ارزیابی مدل بر روی مجموعه داده‌های به همراه نویز با استفاده از روش رأی‌گیری اکثریت



نتیجه گیری و پیشنهاد

این تحقیق باهدف بررسی ارتقای روش های مورد استفاده در دسته بندی مدولاسیون خودکار انجام شده است. در این مطالعه، کاربرد یک مدل ترکیبی CNN برای دسته بندی سیگنال در شبکه های رادیویی شناختی بررسی شد. تمرکز اولیه بر بهبود دقت دسته بندی تحت شرایط مختلف SNR بوده است. یافته های این تحقیق را به شرح زیر می توان خلاصه کرد:

- ❖ عملکرد مدل: مدل ترکیبی CNN که دارای یک تابع تلفات تطبیقی است، بهبود قابل توجهی را در دقت دسته بندی در سطوح مختلف SNR در مقایسه با مدل های رایج نشان داد. به طور خاص، متوسط دقت دسته بندی به دست آمده ۷۰/۹۶ درصد بود که نسبت به مدل های دیگر افزایش قابل توجهی است.
- ❖ تابع زیان تطبیقی: معرفی تابع زیان تطبیقی به نرخ همگرایی سریع تر و افزایش استحکام مدل کمک کرد. این رویکرد به مدل اجازه داد تا به صورت پویا پارامترهای یادگیری خود را بر اساس سطوح SNR تنظیم کند و در نتیجه عملکرد را تحت شرایط نویز متفاوت بهینه کند و مدل را قادر سازد تا عملکرد بالا را حتی در شرایط نویز چالش برانگیز حفظ کند و استحکام و قابلیت اطمینان آن را به نمایش بگذارد.
- ❖ پیشرفت های روش شناختی: این مطالعه همچنین اهمیت پیشرفت های روش شناختی مانند انتخاب فرایامترهای مناسب و ادغام روش های آموزشی پیشرفته را برجسته کرد؛ این بهبودها نقش مهمی در دستیابی به دستاوردهای عملکرد گزارش شده دارد.
- ❖ تجزیه و تحلیل مقایسه ای: از طریق ارزیابی مدل، مشاهده شد که مدل ترکیبی CNN از سایر مدل ها، به ویژه در سناریوهای SNR پایین، بهتر عمل می کند. این نشان دهنده توانایی مدل در مدیریت مؤثر تخریب سیگنال و حفظ دقت بالای دسته بندی است.
- ❖ بررسی روش رأی اکثریت که با استفاده از بخش های مختلف سیگنال و ترکیب پیش بینی های آن ها، دقت و استحکام بالاتری برای نویز ارائه می دهد.

یافته های این مطالعه به طور چشمگیری به حوزه پردازش سیگنال و به خصوص در زمینه AMC کمک می کند. ادغام الگوریتم های یادگیری ماشین نشان داد که نه تنها دقت دسته بندی

را افزایش می‌دهد، بلکه یک راه‌حل مقیاس‌پذیر برای تجزیه و تحلیل سیگنال‌های سریع فراهم می‌آورد. کاربردهای عملی این تحقیق شامل ارتباطات امنیتی پیشرفته و مدیریت طیف کارآمدتر است.

پیشنهادهای پژوهش

- مواردی که برای تحقیقات آتی می‌توان بیان نمود؛ به شرح زیر هستند:
- ✓ اصلاح و توسعه تابع زیان تطبیقی و دیگر تابع‌های مرتبط با آن برای افزایش سرعت آموزش، بدون تأثیر منفی بر روی دقت؛
 - ✓ بررسی کاربرد تابع زیان تطبیقی در انواع دیگر معماری‌های شبکه عصبی؛
 - ✓ بررسی ادغام این رویکرد با سایر روش‌های پردازش سیگنال همانند افزایش داده‌ها جهت بهبود بیشتر در عملکرد؛
 - ✓ گسترش داده‌های مورد استفاده برای شامل کردن سایر مدولاسیون‌های رایج؛
 - ✓ تمرکز بر روی توسعه الگوریتم‌های کارآمدتری که به داده‌های کمتری نیاز دارند و دقت را حفظ می‌کنند.



References

- Ding, H., Fang, Y., Huang, X., Pan, M., Li, P., & Glisic, S. (2017). Cognitive Capacity Harvesting Networks: Architectural Evolution Toward Future Cognitive Radio Networks. *IEEE Communications Surveys & Tutorials*, PP, 1-1. <https://doi.org/10.1109/COMST.20>
- Dobre, O. A., Abdi, A., Bar-Ness, Y., & Su, W. (2007). Survey of automatic modulation classification techniques: classical approaches and new trends. *IET Communications*, 1(2), 137-156. https://digital-library.theiet.org/content/journals/10.1049/iet-com_20050176
- Gardner, W. (1994). *An Introduction to Cyclostationary Signals*. Cyclostationarity in Communications and Signal Processing.
- Huang, L., Pan, W., Zhang, Y., Qian, L., Gao, N., & Wu, Y. (2020). Data Augmentation for Deep Learning-Based Radio Modulation Classification. *IEEE Access*, 8, 1498-1506. <https://doi.org/10.1109/ACCESS.2019.2960775>
- Ian Goodfellow, Y. B. a. A. C. (2016). *Deep Learning*. MIT Press. <http://www.deeplearningbook.org>
- Ioffe, S., & Szegedy, C. (2015). Batch normalization :Accelerating deep network training by reducing internal covariate shift. *International conference on machine learning*.
- Lu, M., Peng, T., Yue, G., Ma, B., & Liao, X. (2021). Dual-channel hybrid neural network for modulation recognition. *IEEE Access*, 9, 76.۷۶۶۶۹-۷۶۰.
- O'Shea, T. J., Corgan, J., & Clancy, T. C. (2016, 2016//). *Convolutional Radio Modulation Recognition Networks*. Engineering Applications of Neural Networks, Cham.
- Pham, Q.-V., Nguyen, N. T., Huynh-The, T., Bao Le, L., Lee, K., & Hwang, W.-J. . (۲۰۲۱) Intelligent Radio Signal Processing: A Survey. *IEEE Access*, 9, 83818-83850. <https://doi.org/10.1109/access.2021.3087136>
- Sang, Y., & Li, L. A. (2018). Application of novel architectures for Modulation Recognition. 2018 IEEE Asia Pacific Conference on Circuits and Systems (APCCAS), 159-162.
- Shea, T. J., & West, N. (2016). Radio Machine Learning Dataset Generation with GNU Radio. *Proceedings of the GNU Radio Conference*, 1(1). <https://pubs.gnuradio.org/index.php/grcon/article/view/11>
- Wang, D., Lin ,M., Zhang, X., Huang, Y., & Zhu, Y. (2023). Automatic Modulation Classification Based on CNN-Transformer Graph Neural Network. *Sensors*, 23(16), 7281. <https://www.mdpi.com/1424-8220/23/16/7281>
- Wu, Y., Li, X., & Fang, J. (2018). A Deep Learning Approach for Modulation Recognition via Exploiting Temporal Correlations. <https://doi.org/10.1109/SPAWC.2018.8445938>
- Xie, G., Hu, S., Yu, C., Zhu, P., Peng, X., & Ouyang, J. (2019). Deep Learning in Digital Modulation Recognition Using High Order Cumulants. *IEEE Access*, PP, 1-1. <https://doi.org/10.1109/ACCESS.2019.2916833>
- Yang, F., Li, Z., Zeng, S., Hao, B., Qi, P., & Pang, Z. (2016). A Novel Method for Wireless Communication Signal Modulation Recognition in Smart Grid. *J. Commun.*, 11(9), 813-818.

- Yashashwi, K., Sethi, A., & Chaporkar, P. (2018). A Learnable Distortion Correction Module for Modulation Recognition. IEEE Wireless Communications Letters, 8. <https://doi.org/10.1109/LWC.2018.2855749>
- Zeng, Y., Zhang, M., Han, F., Gong, Y., & Zhang, J. (2019). Spectrum Analysis and Convolutional Neural Network for Automatic Modulation Recognition. IEEE Wireless Communications Letters, 8, 929-932.
- Zhang, Z., & Sabuncu, M. (2018a). Generalized cross entropy loss for training deep neural networks with noisy labels. Advances in neural information processing systems, 31.
- Zhang, Z., & Sabuncu, M. (2018b). Generalized Cross Entropy Loss for Training Deep Neural Networks with Noisy Labels.
- Zheng, Q., Tian, X., Yu, Z., Wang, H., Elhanashi, A., & Saponara, S. (2023). DL-PR: Generalized automatic modulation classification method based on deep learning with priori regularization. Engineering Applications of Artificial Intelligence, 122. <https://doi.org/10.1016/j.engappai.2023.106082>