



Modulation Classification in Multipath Fading Channels Using Higher-Order Statistics and Optimized SVM Classifier

Hashem Kalbkhani¹✉ and Mahdi Ouria²

1. Associate Professor, Department of Electrical Engineering, Urmia University of Technology, Urmia, Iran. E-mail: h.kalbkhani@uut.ac.ir

2. Assistant Professor, AJA Command and Staff University, Tehran, Iran. E-mail: mahdi.ouria@chmail.ir

Article Info	ABSTRACT
<p>Article type: Research Article</p> <p>Article history: Received Received in revised form Accepted Published online</p> <p>Keywords: <i>Higher-order statistics,</i> <i>Kernel optimization,</i> <i>Modulation classification,</i> <i>Multipath channel</i></p>	<p>Objective: Automatic modulation classification (AMC) is a key technology in modern wireless communication and while facing many challenges, it has attracted wide attention in various fields, especially electronic warfare and military applications. The wireless propagation environment is very complicated due to the existence of wide obstacles and in practice, the channel has a multi-path fading behavior that is not considered in most research.</p> <p>Methodology: In this research, we use high-order statistics as features for AMC in multi-path fading channels. To increase the classification accuracy, the received samples are divided into smaller segments, and statistics are calculated for each part. For classification, the support vector machine (SVM) with Gaussian kernel is used, and the standard deviation of the kernel is optimized using the particle swarm optimization (PSO) algorithm to maximize the classification accuracy.</p> <p>Findings: To evaluate the proposed method, eight commonly used digital modulation types were used. The results show that the number of received samples and also the number of segments affect the correct identification accuracy. Also, optimizing the standard deviation of the kernel improves the accuracy of correct signal identification.</p> <p>Originality: The obtained results show that the proposed method can be used as an effective algorithm to detect the modulation type of digital signals in electronic warfare scenarios and other commercial applications.</p>

Cite this article: Author, A. A., Author, B. B., & Author, C. C. (year). Article title. *Journal Title*, 56 (1), 1-20. DOI: <http://doi.org/00000000000000000000>



© The Author(s)
DOI:

Publisher: Command and Staff University



تشخیص مدولاسیون در کانال‌های محوشونده چندمسیری با استفاده از ویژگی‌های آماری مرتبه بالا و طبقه‌بند SVM بهینه‌شده هاشم کلب‌خانی^۱ و مهدی اوریا^۲

۱. دانشیار گروه مهندسی برق، دانشگاه صنعتی ارومیه، ارومیه، ایران، رایانامه: h.kalbkhani@uut.ac.ir

۲. استادیار دانشگاه فرماندهی و ستاد آجا، تهران، ایران، رایانامه: mahdi.ouria@chmail.ir

اطلاعات مقاله	چکیده
نوع مقاله:	هدف: طبقه‌بندی خودکار مدولاسیون (AMC) یک فناوری کلیدی در ارتباطات بی‌سیم مدرن است و در عین مواجهه با چالش‌های متعدد، توجه گسترده‌ای را در بخش‌های مختلف، به ویژه کاربردهای جنگ الکترونیک و نظامی، به خود جلب کرده است. محیط انتشار بی‌سیم به دلیل وجود موانع گسترده بسیار پیچیده است و در عمل، کانال رفتار محوشونده چندمسیری دارد که در اکثر پژوهش‌ها در نظر گرفته نشده است.
مقاله پژوهشی	
تاریخ دریافت:	روش پژوهش: در این پژوهش از آماره‌های مرتبه بالا به عنوان ویژگی برای طبقه‌بندی خودکار مدولاسیون در کانال‌های محوشونده چندمسیری استفاده می‌کنیم. برای افزایش دقت تشخیص، سیگنال به بخش‌های کوچک‌تری تقسیم‌شده و آماره‌ها برای هر قسمت محاسبه می‌شوند. برای طبقه‌بندی نیز از بردار پشتیبان ماشین (SVM) با کرنل گوسی استفاده می‌شود که مقدار انحراف معیار کرنل با استفاده الگوریتم بهینه‌سازی ازدحام ذرات (PSO) بهینه می‌شود تا دقت طبقه‌بندی بیشینه شود.
تاریخ بازنگری:	یافته‌ها: برای ارزیابی روش پیشنهادی از هشت نوع مدولاسیون دیجیتال پرکاربرد استفاده شد. نتایج نشان می‌دهند که تعداد نمونه‌های سیگنال دریافتی و همچنین تعداد بخش‌ها در دقت شناسایی صحیح تاثیر دارند. هم‌چنین بهینه‌سازی انحراف معیار کرنل، دقت شناسایی صحیح سیگنال را بهبود می‌دهد.
تاریخ پذیرش:	نتیجه‌گیری: نتایج به دست آمده نشان می‌دهند که روش پیشنهادی می‌تواند به عنوان یک الگوریتم موثر برای تشخیص نوع مدولاسیون سیگنال‌های دیجیتال در سناریوهای جنگ الکترونیک و سایر کاربردهای تجاری مورد استفاده قرار گیرد.
تاریخ انتشار:	
کلیدواژه‌ها:	
آماره مرتبه بالا، بهینه‌سازی کرنل، تشخیص مدولاسیون، کانال چندمسیری.	
استناد: نام خانوادگی، نام؛ نام خانوادگی، نام؛ و نام خانوادگی، نام (سال). عنوان مقاله. عنوان/مجله، ۲ (۴)، ۲۰-۱.	
DOI: http://doi.org/00000000000000000000000000000000	
ناشر: دانشگاه فرماندهی و ستاد ارتش جمهوری اسلامی ایران	
© نویسندگان.	



مقدمه

شناسایی سیگنال^۱ لایه فیزیکی^۲ (PHY) زیرمجموعه‌ای از روش‌های شناسایی سیستم است، که در طول سالیان گذشته در پژوهش‌های نظامی، دانشگاهی و صنعتی مرتبط با ارتباطات مورد توجه قرار گرفته و در سال‌های اخیر به دلیل کاربردهای متعدد آن در جنگ الکترونیک و شنود تمرکز فزاینده‌ای روی آن شده است (کمالی و بخشنده، ۱۳۸۹، مهرگان و همکاران، ۱۳۹۷ و محمدی و همکاران، ۱۴۰۱). تشخیص برنامه‌ریزی و اهداف دشمن از چینش نیروها از اهداف مهم بازی جنگ است که در صورت شنود موفق می‌توان به این هدف مهم دست یافت و شرط لازم برای شنود موفق، شناسایی سیگنال‌های دشمن است. با توجه به آخرین پیشرفت‌ها در مورد شبکه‌های نسل پنجم (5G^۳)، یکی از عواملی که باید در طراحی سخت‌افزاری و نرم‌افزاری در نظر گرفته شود، وجود فناوری‌های دسترسی رادیویی (RAT^۴) متعدد و ادغام چندین نوع دستگاه در یک شبکه است (Bolte et al., 2003). به این ترتیب، فناوری شناسایی و نظارت بر دستگاه‌های فعال در یک طیف فرکانسی به دلیل توانایی آن در ارائه موارد ذیل مورد توجه قرار گرفته است:

- کاهش تأخیر برای دستگاه‌هایی با قابلیت‌های محدود (مانند برچسب‌های RFID^۵ و دستگاه‌هایی با الزامات تأخیر کم)
- کاهش مصرف توان برای دستگاه‌هایی مانند موارد فوق
- بهینه‌سازی منابع شبکه، به عنوان مثال، با استفاده از طبقه‌بندی تداخل
- ردیابی دقیق فعالیت دستگاه
- افزایش امنیت شبکه

نمونه‌های قابل ذکر، تکنیک‌های خاصی از تخصیص طیف و تشخیص نفوذ است که می‌تواند برای هر عنصر ارتباطی (مثلاً یک ایستگاه پایه) یک شبکه مفید باشد (Danev et al., 2012). با این حال، اهمیت این فناوری‌ها با در نظر گرفتن محیط‌هایی با چندین

^۱ Signal identification

^۲ Physical layer

^۳ Fifth-generation (5G)

^۴ Radio access technology (RAT)

^۵ Radio frequency identification (RFID)

RAT برجسته می‌شود، به عنوان مثال، توسعه استفاده از طیف بدون مجوز. در زمینه شناسایی سیگنال، هم فرکانس رادیویی (RF)^۱ و هم در موارد دیگر، حوزه‌های کاربردی شامل تشخیص نفوذ، کنترل دسترسی، تشخیص نقص و تشخیص کرم‌چاله است. با توجه به کاربردهای RF در شناسایی سیگنال، طبقه‌بندی خودکار مدولاسیون (AMC)^۲ از برجسته‌ترین زیرمجموعه‌های این حوزه است. بنابراین، در این پژوهش روش جدیدی برای تشخیص مدولاسیون سیگنال‌های دیجیتال ارائه می‌شود. روش ارائه‌شده بر پایه مشخصات آماری مرتبه بالای سیگنال‌های دریافتی در کانال‌های محوشونده چند مسیری می‌باشد.

مبانی نظری و پیشینه‌های پژوهش

مبانی نظری

طبقه‌بندی خودکار مدولاسیون به فرآیند تشخیص دقیق نوع مدولاسیون یک سیگنال مخابراتی اشاره دارد و بخشی از سیستم ارتباطی بین فرآیندهای تشخیص سیگنال و دمدولاسیون^۳ را تشکیل می‌دهد (نمایشی نمادین در شکل ۱ ارائه شده است). اگرچه کاربردهای نظامی به طور سنتی به عنوان کاتالیزور اصلی برای تحقیقات در این زمینه عمل می‌کردند، کاربردهای غیرنظامی نیز در این حوزه در حال گسترش هستند (Dobre et al., 2007 & Zhuo et al., 2016). به عنوان مثال، AMC می‌تواند به تشخیص منبع سیگنال شناسایی شده کمک کند، که یک ویژگی مطلوب برای سیستم‌های بی‌سیم است (مانند تنظیمات اینترنت اشیا (IoT)^۴) (غلام‌نژاد و همکاران، ۱۳۹۸). به همین ترتیب، یک آشکارساز مدولاسیون در رادیویی نرم‌افزاری (SDR)^۵ برای سازگاری سریع و هوشمند با تغییرات طیف، جزء مهمی است. از سوی دیگر، یک حوزه بالقوه در کاربردهای نظامی، ایجاد پارازیت در یک نوع مدولاسیون شناخته‌شده و همچنین رمزگشایی سیگنال‌های رهگیری شده است (Ramjee et al., 2019). دلیلی که در سال‌های اخیر منجر به افزایش علاقه به AMC شده است، قرار گرفتن در برنامه‌ریزی و ساختار ماوراء 5G

^۱ Radio-frequency (RF)

^۲ Automatic modulation classification (AMC)

^۳ Demodulation

^۴ Internet-of-things (IoT)

^۵ Software-defined radio (SDR)

(B5G¹) است، که رواج سیستم‌های چند ورودی-چند خروجی (MIMO²)، در میان عوامل دیگر، منجر به یک طیف الکترومغناطیسی بسیار شلوغ می‌شود. علاوه بر این، حتی تحت استقرارهای فعلی 5G، به دلیل وجود محوشوندگی چندمسیری، دشواری فرآیند تشخیص سیگنال را افزایش می‌دهد (Hermawan et al. 2020).



شکل (1) نمایش نقش تشخیص مدولاسیون در سیستم‌های مخابراتی بی‌سیم

می‌توان ادعا کرد که رویکردهای سنتی برای AMC عمدتاً به یکی از دو دسته مقابل تعلق دارند: مبتنی بر احتمال (LB³) و مبتنی بر ویژگی (FB⁴). دسته اول متشکل از روش‌هایی است که در آن بیان تحلیلی کلاس‌های مختلف سیگنال برای محاسبه آستانه‌ها استفاده می‌شود و تصمیم بر اساس مقایسه با آن‌ها گرفته می‌شود. در حالی که در دسته دوم، کمیت‌های مورد استفاده برای رسیدن به یک تصمیم، ویژگی‌های آماری محاسبه شده از سیگنال‌ها هستند (Ramjee et al., 2019). با این حال، مشکلات و اشکالات ناشی از هر دو روش، منجر به رواج خانواده سوم از روش‌ها، یعنی روش‌هایی که بر شبکه‌های عصبی مصنوعی (ANN⁵) تکیه دارند، شده است. در حالی که روش‌های مربوط به شبکه‌های عصبی مصنوعی را می‌توان به جهات خاصی زیرمجموعه FB در نظر گرفت، تکثیر آن مطمئناً به توسعه سریعی که فناوری شبکه‌های عصبی در سال‌های اخیر از آن

¹ Beyond 5G (B5G)

² Multiple-input multiple-output (MIMO)

³ Likelihood-based (LB)

⁴ Feature-based (FB)

⁵ Artificial neural network (ANN)

بهره برده است، با افزایش تعداد کاربردها در سناریوهای شبکه بی سیم، تسریع شده است (Chen et al., 2019). مهم ترین ویژگی کلیدی این دسته، در ماهیت داده محور آن نهفته است. به طور خاص، در حالی که رویکردهای سنتی معمولاً شامل مواردی مانند تخمین ویژگی ها، تعیین آستانه ها و طبقه بندی بر اساس آن هستند، شبکه های عصبی نیاز به یک مرحله آموزشی را دارند که به نوبه خود مستلزم وجود مجموعه های داده قوی است که برای تنظیم پارامترها و فرآیندها استفاده می شوند و باید از داده های مورد استفاده برای ارزیابی جدا باشد.

پیشینه های پژوهش

از نظر تئوری، تکنیک های AMC مبتنی بر LB می توانند راه حل بهینه را پیدا کنند، اما از نظر محاسباتی فشرده هستند و لازم است دانش پس زمینه فرستنده ها در گیرنده موجود باشد. با این حال، تکنیک های AMC مبتنی بر FB نیازی به دانش قبلی ندارند و می توانند راه حل های ساده تر با هزینه های پردازش پایین تر تولید کنند (Huang et al., 2020). دو جزء حیاتی روش های FB عبارتند از استخراج کننده ویژگی و طبقه بندی. معمولاً استخراج کننده ویژگی و طبقه بندی به طور جداگانه برای یک سیستم AMC ساخته می شوند. به عنوان مثال، دامنه پوش سیگنال، واریانس طیفی توان سیگنال و میانگین فرکانس اندازه سیگنال استخراج شدند تا یک سیگنال را از چندین جنبه مختلف توصیف کنند (Lopatka et al., 2000). از تابع چگالی احتمال نیز فاز برای AMC استفاده شده است (Yang et al., 1991). در این میان، روش های سنتی معمولاً ویژگی های لحظه ای و آماری را با هم ترکیب می کنند. به عنوان مثال، ترکیب گشتاورها و آماره های مرتبه بالا (Sherme et al., 2012). ویژگی ها می توانند سیگنال ها را با استفاده از هر دو سطح مطلق و نسبی توصیف کنند. علاوه بر این، ویژگی های با مرتبه بالا می توانند اثرات نویز را از بین ببرند. آماره هشتم به طور گسترده در چندین روش استفاده شده است. در یک پژوهش، AMC را به عنوان یک مسئله آزمون فرضیه های چندگانه در نظر گرفته و برای به دست آوردن نتایج از نظریه تصمیم گیری استفاده شده است (Wei et al., 2000). فرض شده است که

فاز نویز سفید گوسی جمع‌شونده ($AWGN^1$) تصادفی است و با سیگنال‌ها به عنوان متغیرهای تصادفی با توزیع احتمال شناخته شده برخورد می‌شود. در نهایت از آزمون نسبت درست‌نمایی تعمیم‌یافته یا متوسط برای به دست آوردن نتایج طبقه‌بندی بر اساس آستانه استفاده شد. سپس طبقه‌بندها در سیستم AMC استفاده شدند.

شبکه‌های عصبی کم‌عمق و SVM به عنوان طبقه‌بند استفاده شده‌اند (Wong et al., 2001). شبکه عصبی کانولوشنی (CNN²) با قابلیت‌های یادگیری انتزاعی سطح بالا نیز برای طبقه‌بندی استفاده شده است (Iliadis et al., 2022). با این حال، طبقه‌بندهای سنتی یا به دلیل ظرفیت خود برای نمایش ویژگی یا با نیاز به دانش قبلی کامل، کارایی چندانی ندارند. این رویکرد به تأثیرات منفی بر عملکرد طبقه‌بندی منجر شده است. بسیاری از جنبه‌های مختلف در الگوریتم‌های AMC بررسی و پیاده‌سازی شده است. به عنوان مثال، در حوزه زمانی، دامنه، فرکانس و فاز لحظه‌ای برای استخراج ویژگی‌های لحظه‌ای استفاده شده‌اند (Azzouz et al., 1995 & Popoola et al., 2011). استخراج ویژگی مبتنی بر تبدیل با استفاده از تبدیل فوریه و موجک نیز مورد توجه قرار گرفته‌اند (Chen et al., 2021, Zhou et al., 2022). چندین نوع طبقه‌بند غیرخطی نیز در AMC استفاده شده‌اند، مانند شبکه‌های عصبی و ماشین‌های بردار پشتیبان (SVM³) با کرنل⁴ (Zhang et al., 2021, & Simic et al., 2021). اعتقاد بر این است که SVM مزایایی دارد و همچنین می‌تواند قابلیت تعمیم بهبود یافته را زمانی که تعداد نمونه‌ها محدود است ارائه دهد (Cervantes et al., 2020). بنابراین، در سال‌های اخیر، SVM به طبقه‌بند ترجیحی برای مسائل AMC تبدیل شده است.

یک گیرنده هوشمند می‌تواند داده‌های پیام را رمزگشایی کند و سیگنال مناسب را برای هر برنامه کاربردی مشخص کند (Xu et al., 2019). شبکه‌های عصبی یادگیری عمیق (DLNN⁵) یک نوع موفق از یادگیری ماشینی به دلیل توانایی‌های طبقه‌بندی

¹ Additive white Gaussian noise (AWGN)

² Convolutional neural network (CNN)

³ Support vector machine (SVM)

⁴ Kernel

⁵ Deep learning neural network (DLNN)

برترشان هستند (Murphy, 2022). زمینه‌های مختلفی وجود دارد که از DLNNها استفاده شده است، از جمله طبقه‌بندی تصویر (Alzubaidi et al., 2021 & Moon et al., 2021). این شبکه‌ها در سیستم‌های ارتباطی استفاده می‌شوند زیرا مزایای زیادی دارند. اول از همه، سیستم‌های ارتباطی دارای داده‌های بزرگی هستند که DLNN به آن نیاز دارند، زیرا دستگاه‌های ارتباطی زیادی با نرخ داده بسیار بالا وجود دارد (Peng et al., 2022). دوم، DLNNها می‌توانند ویژگی‌ها را به طور مستقل استخراج کنند، و از تلاش وقت‌گیر انتخاب ویژگی‌های دستی اجتناب کنند. سوم، از آنجا که DL به طور مداوم در حال توسعه است، پتانسیل بسیار خوبی در زمینه‌های ارتباطات دارد. یادگیری عمیق اخیراً به عنوان یک حوزه کاربردی جدید در قلمرو سیستم‌های ارتباطی بی‌سیم ظاهر شده است.

اخیراً، همراه با یک لایه خروجی مبتنی بر احتمال، رمزگذارهای خودکار پراکنده مبتنی بر شبکه‌های عصبی عمیق برای AMC معرفی شدند (Ali et al., 2017). این روش‌ها پتانسیل امیدوارکننده مدل یادگیری عمیق را برای کار AMC نشان دادند. مزیت CNN با اتصالات محلی و وزن‌های گره‌خورده به دنبال شکلی از ادغام به دست می‌آید که منجر به ویژگی‌های تغییرناپذیر با جابجایی می‌شود. علاوه بر این، یک مزیت دیگر این است که آن‌ها پارامترهای کمتری نسبت به شبکه‌های کاملاً متصل با همان تعداد واحد پنهان دارند. یک مجموعه داده با ۲۴ نوع مدولاسیون مختلف، معروف به RadioML 2018.01A ایجاد و با استفاده از CNN به طور خاص با استفاده از اتصالات باقیمانده در شبکه (ResNet¹) به عملکرد طبقه‌بندی بالایی دست یافتند (O'Shea et al., 2018). در پژوهش دیگر، سیگنال ارتباطی را به عنوان داده‌های دو بعدی، شبیه به یک تصویر، در نظر گرفته و آن را به عنوان ماتریس به یک CNN دو بعدی برای AMC استفاده کردند (O'Shea et al., 2016).

یک رویکرد جدید مبتنی بر CNN با پارامترسازی مجدد علی (RepCCNet²) برای دستیابی به عملکرد AMC بسیار دقیق و مقاوم در برابر نویز پیشنهاد شده است (Tang

¹ Residual network (ResNet)

² Reparameterization causal convolutional network (RepCCNet)

et al. 2024). شبکه RepCCNet از کانولوشن‌های علی و تکنیک‌های پارامترسازی مجدد ساختاری برای استخراج ویژگی‌های حوزه زمانی طولانی مدت استفاده می‌کند. نمایش تصویری جدید سیگنال‌های مدولاسیون ترکیبی¹، با نام CPP² از طیف دوره‌ای مرتبه دوم نرمال‌شده سیگنال مدولاسیون ترکیبی دریافت‌شده ساخته شده است (Yan et al., 2014). در ادامه، تبدیل کسینوس گسسته (DCT³) به ماتریس CPP به دست‌آمده اعمال می‌شود تا بردار ویژگی را استخراج کند و در نهایت، جنگل تصادفی (RF⁴) طبقه‌بندی می‌شوند. یک روش طبقه‌بندی کور⁵ برای سیگنال‌های OFDM⁶ ناهم‌زمان و یک مکانیزم مهندسی ویژگی مبتنی بر پراکندگی آماری نرمال‌شده دامنه (NSDA⁷) و آماره‌های مرتبه بالا با طراحی یک روش پردازش ادراکی با ترکیب تبدیل فوریه گسسته (DFT⁸) و کانولوشن خودخطی (SLC⁹) پیشنهاد شده است که باعث دقت تشخیص مدولاسیون در نسبت‌های پایین سیگنال به نویز را بهبود می‌دهد (Yang et al., 2024).

روش‌شناسی پژوهش

سیگنال دریافتی در محیط بی‌سیم و در حضور کانال محوشونده به صورت زیر بیان می‌شود (Yin et al., 2023):

$$y(t) = \exp(j2\pi f_c t) \exp(j2\pi f_o t) \exp(j\phi) x(t) \otimes h(t) + w(t) \quad (1)$$

که $x(t)$ و $y(t)$ به ترتیب بیانگر سیگنال‌های ارسالی و دریافتی هستند. عمگنر کانولوشن با \otimes نشان داده شده و $w(t)$ بیانگر AWGN است. فرکانس حامل، آفست فرکانس و آفست فاز به ترتیب با f_c ، f_o و ϕ نشان داده شده‌اند. کانال بی‌سیم در این پژوهش به

¹ Composite modulation

² Cyclic-paw-print (CPP)

³ Discrete cosine transform (DCT)

⁴ Random forest (RF)

⁵ Blind

⁶ Orthogonal frequency division multiplexing (OFDM)

⁷ Normalized statistical dispersion of amplitude (NSDA)

⁸ Discrete Fourier transform (DFT)

⁹ Self-linear convolution (SLC)

صورت کانال محوشونده چندمسیری است، بنابراین پاسخ ضربه کانال، $h(t)$ ، می تواند به صورت زیر نمایش داده شود (Yin et al., 2023):

$$h(t) = \sum_{k=1}^K \alpha_k \exp(j\varphi_k) \delta(t - \tau_k) \quad (۲)$$

که تعداد مسیره های کانال با K نمایش داده شده است و α_k ، φ_k و τ_k به ترتیب بیانگر دامنه، فاز و تاخیر مسیر k هستند. اگر $x(t)$ ، سیگنال دیجیتال مدوله شده در (۱) باشد، می توان آن به صورت زیر بازنویسی کرد (Yin et al., 2023):

$$y(n) = \exp(j2\pi f_c n) \exp(j\phi) \sum_{k=1}^K \alpha_k \exp(j\varphi_k) \sum_i s_i(n - i - i_k) + w(n) \quad (۳)$$

که $g(n) = p_{rx}(n) \otimes h(n) \otimes p_{tx}(n)$ بیانگر ترکیب پاسخ ضربه فیلترهای گیرنده، کانال و فرستنده است. همچنین T_s بیانگر تاخیر زمانی و بازه ارسال سمبل هستند. همچنین s_i در بازه مقابل تعریف می شود: $n \in (i - 1/2, i + 1/2)$ و درایه های آن بردار تصادفی بوده و دارای توزیع گوسی با میانگین صفر هستند. نشان داده شده است که آماره های مرتبه بالاتر مانند انباشته ها^۱، که از گشتاورها^۲ به دست می آیند، ویژگی های کارآمدی برای شناسایی سیگنال های مخابراتی در کانال های محوشونده بی سیم هستند. در این مقاله از انباشته های مرتبه چهارم، ششم و هشتم استفاده می کنیم که به صورت زیر محاسبه می شوند (Khosraviyani et al., 2019):

$$c_{40} = m_{40} - 3m_{20}^2 \quad (۴)$$

$$c_{61} = m_{61} - 5m_{21}m_{40} - 10m_{20}m_{41} + 30m_{20}^2m_{21} \quad (۵)$$

$$c_{63} = m_{63} - 9m_{21}m_{42} + 12m_{21}^3 - 3m_{20}m_{43} - 3m_{22}m_{41} \quad (۶)$$

$$c_{80} = m_{80} - 35m_{40}^2 - 28m_{60}m_{20} + 420m_{40}m_{20}^2 - 630m_{20}^4 \quad (۷)$$

که m_{pq} بیانگر گشتاور سیگنال است که به صورت زیر محاسبه می شود:

$$m_{pq} = E \left[(y(n))^{p-q} (y^*(k))^q \right] \quad (۸)$$

^۱ Cumulant

^۲ Momentum

برای بررسی بهتر سیگنال دریافتی، پیشنهاد می‌شود که مجموعه N سمبل دریافتی به n_s بخش کوچک‌تر به طول M سمبل تقسیم شده و انباشته‌های محاسبه‌شده در روابط (۴)-(۷) برای هر بخش محاسبه شده و بردار ویژگی نهایی به طول $4n_s$ ویژگی تشکیل می‌شود.

در این پژوهش از SVM با کرنل گوسی برای طبقه‌بندی بردارهای ویژگی استفاده می‌شود. SVMها طبقه‌بندهای باینری بهینه هستند که با ایجاد ابرصفحه بهینه که داده‌ها را به دو کلاس جدا می‌کند، طبقه‌بندی را انجام می‌دهند. SVM حاشیه نرم^۱ (همچنین به عنوان C-SVM شناخته می‌شود) می‌تواند برای طبقه‌بندی ویژگی‌ها برای طبقه‌بندی باینری استفاده شود. اگرچه SVMها در ابتدا به عنوان طبقه‌بندهای باینری طراحی شده بودند، اما نسخه‌های مختلفی وجود دارد که SVMها را قادر می‌سازد تا بیش از دو کلاس را مدیریت کنند (Kalbkhani et al., 2013). طبقه‌بندهای SVM چندکلاسی را می‌توان تقریباً به دو گروه تقسیم کرد، روش‌های همه با هم^۲ و روش‌های مبتنی بر طبقه‌بندهای باینری (Burges, 1998). در این پژوهش برای طبقه‌بندی چند کلاسی با SVM، از روش یک در مقابل یک^۳ استفاده می‌کنیم که به طور گسترده مورد استفاده قرار گرفته است (Burges, 1998). در این روش تعداد SVM باینری استفاده‌شده برای هر جفت کلاس، برابر $Combination(N_c/2)$ است که در آن N_c تعداد کلاس‌ها است. عملکرد SVM با کرنل گوسی به انحراف معیار کرنل وابسته است که مقدار بهینه آن باید محاسبه شود که در این پژوهش از بهینه‌سازی ازدحام ذرات (PSO^۴) برای این منظور استفاده شده است. شبه‌کد الگوریتم PSO در الگوریتم ۱ آورده شده است. هم‌چنین تنظیمات پارامترهای این الگوریتم به شرح مقابل می‌باشند: متغیر خروجی: انحراف معیار کرنل، تعداد ذرات: ۱۰۰، حداقل مقدار خروجی: ۰،۰۱، حداکثر مقدار خروجی: ۵۰، $c_1 = c_2 = 2$ ، $\omega = 0.7$.

¹ Soft margin

² All-together

³ One-against-one

⁴ Particle swarm optimization (PSO)

الگوریتم (۱) شبه کد الگوریتم PSO

Step 1. Initialization

For each particle $i = 1, \dots, N_p$

- (a) Initialize the particle's position with a uniform distribution as $P_i(0) \sim (LB, UB)$, where LB and UB represent the lower and upper bounds of search space
- (b) Initialize $pbest$ to its initial position: $gbest = P_i(0)$
- (c) Initialize $gbest$ to the minimal value of the swarm: $gbest(0) = \operatorname{argmin} f[P_i(0)]$
- (d) Initialize velocity: $V_i \sim U(-|UB - LB|, |UB - LB|)$

Step 2. Repeat until a termination criterion is met

For each particle $i = 1, \dots, N_p$, do

- (a) Pick random numbers: $r_1, r_2 \sim U(0, 1)$
- (b) Update particle's velocity as $V_i(t+1) = \omega V_i(t) + c_1 r_1 (pbest(i, t) - P_i(t)) + c_2 r_2 (gbest(i, t) - P_i(t))$
- (c) Update particle's position as $P_i(t+1) = P_i(t) + V_i(t+1)$
- (d) If $f[P_i(t)] < f[gbest(i, t)]$, do
 - (i) Update the best-known position of particle i : $pbest(i, t) = P_i(t)$
 - (ii) If $f[P_i(t)] < f[gbest(t)]$, update the swarm's best-known position: $gbest(t) = P_i(t)$.
- (e) $t \leftarrow (t + 1)$;


Step 3. Output $gbest(t)$ that holds the best-found solution.

تجزیه و تحلیل داده‌ها

از نرم‌افزار MATLAB برای شبیه‌سازی عملکرد روش پیشنهادی استفاده شده است. در این پژوهش، هشت سیگنال دیجیتال شامل 4PSK، 2PSK، 4ASK، 2ASK، 2FSK، 16QAM و 32QAM با پارامترهای مقابل در نظر گرفته شدند: فرکانس حامل ۲۰۰۰ هرتز و فرکانس نمونه‌برداری ۸۰۰۰ هرتز. عملکرد الگوریتم‌های پیشنهادی با فرض تخمین کانال کامل به دست آمد. داده‌های مورد نیاز برای AMC، با استفاده از شبیه‌سازی‌های Monte Carlo به دست آمدند. برای این منظور، در هر مقدار SNR، به تعداد

۱۰۰۰۰۰ نمونه دریافتی تولید شدند. از این نمونه‌ها، ۷۰٪ برای آموزش و ۳۰٪ نیز برای ارزیابی استفاده شدند.

نمودار (۱)، دقت تشخیص صحیح (PCI^1) روش پیشنهادی را در نسبت‌های مختلف سیگنال به نویز (SNR^2) از -10 dB تا 20 dB و طول‌های مختلف سیگنال دریافتی از ۵۱۲ نمونه تا ۴۰۹۶ نمونه نشان می‌دهد. مشاهده می‌شود که در مقدار ثابت تعداد نمونه‌های دریافتی، مقدار PCI با افزایش SNR افزایش می‌یابد که به دلیل تخمین صحیح مقادیر ویژگی‌ها با کاهش مقدار نویز و افزایش مقدار SNR است. هم‌چنین افزایش تعداد نمونه‌های دریافتی نیز به تخمین صحیح مقدار ویژگی‌های آماری کمک می‌کند که به بهبود PCI می‌انجامد و این مورد با بررسی نمودار (۱) قابل شناسایی است.




نمودار (۱) دقت طبقه‌بندی برای تعداد نمونه‌های مختلف سیگنال دریافتی

نمودار (۲)، مقدار PCI روش پیشنهادی را در مقدار ثابت تعداد نمونه‌های دریافتی، $N = 4096$ ، به ازای مقادیر مختلف بخش‌های کوچک‌تر سیگنال دریافتی، m_s ، نمایش داده شده است. همان‌طور که مشاهده می‌شود با افزایش تعداد زیربخش‌ها، ابتدا مقدار PCI

¹ Probability of correct identification (PCI)


² Signal-to-noise ratio (SNR)

افزایش می‌یابد ولی بعد از آن کاهش می‌شود. با افزایش تعداد زیربخش‌ها، تعداد نمونه‌ها در هر زیربخش کاهش می‌یابد، تخمین مقدار ویژگی‌ها دشوار می‌شود ولی تعداد ویژگی‌ها افزایش یافته و طول بردار ویژگی زیاد می‌شود که باعث بهبود دقت تشخیص مدولاسیون می‌شود. با افزایش زیاد تعداد زیربخش‌ها، تعداد نمونه‌ها در هر زیربخش بسیار اندک می‌شود که تخمین ویژگی‌ها را شدیداً نویزی کرده و دقت تشخیص کاهش می‌شود.



نمودار (۲) تاثیر تعداد زیربخش‌های سیگنال دریافتی بر PCI

نمودار (۳) تاثیر استفاده از بهینه‌سازی PSO در تنظیم انحراف معیار کرنل گوسی طبقه‌بند بر دقت شناسایی صحیح را نشان می‌دهد. همانطور که مشاهده می‌شود بهینه‌سازی انحراف معیار کرنل دقت طبقه‌بندی را به صورت چشم‌گیری بهبود می‌دهد. شایان ذکر است طبقه‌بند SVM با کرنل خطی به دقت ۹۴٫۲۷٪ و طبقه‌بندی kNN به دقت ۹۵٫۸۳٪ رسیدند که از دقت طبقه‌بند SVM با کرنل گوسی پایین‌تر است. جدول (۱)، دقت طبقه‌بندی را با در نظر گرفتن هر کدام از آماره‌ها به تنهایی نشان می‌دهد. همان‌طور که مشاهده می‌شود آماره c_{80} بیشترین دقت طبقه‌بندی را دارد و بعد از آن، آماره‌های c_{63} ، c_{61} و c_{40} دقت بالاتری دارند.



نمودار (۳) تاثیر بهینه‌سازی کرنل طبقه‌بند گوسی بر دقت شناسایی صحیح

جدول (۱) دقت طبقه‌های هر کدام از آماره‌ها

آماره	C_{40}	C_{61}	C_{63}	C_{80}
دقت طبقه‌بندی	۰٫۶۱۲	۰٫۷۳۸	۰٫۸۱۴	۰٫۸۸۶

همان‌طور که در رابطه (۱) نشان داده شده است، انحراف‌های فرکانس و فاز می‌توانند کیفیت سیگنال دریافتی را کاهش دهند. شبیه‌سازی نشان دادند که انحراف فرکانس اثر مخرب بیشتری نسبت به انحراف فاز بر روی سیگنال دریافتی دارد و در مقادیر SNR بالا، می‌تواند تا ۳۸٪ دقت طبقه‌بندی را کاهش دهد، در حالی که انحراف فاز، حداکثر ۱۶٪ دقت طبقه‌بندی را کاهش می‌دهد.

نتیجه‌گیری و پیشنهادها

با توجه به گسترش روزافزون تکنیک‌های جنگ الکترونیک در سیستم‌های نظامی، در این پژوهش روش جدیدی برای تشخیص مدولاسیون سیگنال‌های دیجیتال ارائه شد که الزامات شنود در جنگ الکترونیک می‌باشد. روش پیشنهادی مبتنی بر آماره‌های مرتبه بالا و انباشته‌ها است و چهار انباشته از سیگنال دیجیتال دریافتی برای این هدف استخراج شدند. برای افزایش تعداد ویژگی‌ها و مقاومت در برابر نویز، سیگنال دریافتی به بخش‌های

کوچک‌تری تقسیم‌شده و ویژگی‌ها برای هر بخش محاسبه می‌شوند. طبقه‌بند SVM با کرنل گوسی بهینه‌شده با الگوریتم PSO برای طبقه‌بندی ویژگی‌های استفاده‌شده و تشخیص نوع مدولاسیون استفاده شد. در این پژوهش، هشت نوع مدولاسیون از کلاس-های ASK، FSK، PSK و QAM مورد بررسی قرار گرفتند. نتایج شبیه‌سازی نشان دادند که با افزایش مقدار SNR و تعداد سمبل‌های دریافتی، دقت شناسایی صحیح افزایش می‌یابد که به دلیل بهبود ویژگی‌های استخراج‌شده است. هم‌چنین افزایش تعداد زیربخش‌های تا مقدار شش، دقت تشخیص را بهبود می‌دهد ولی افزایش بیش از حد آن، باعث کاهش دقت شناسایی می‌شود. از طرف دیگر، نتایج نشان دادند که دقت شناسایی صحیح با استفاده از الگوریتم PSO برای بهینه‌سازی مقدار واریانس کرنل گوسی بهبود می‌یابد.

در پژوهش‌های آتی می‌توان با افزایش تعداد آماره‌های محاسبه‌شده تعداد بیشتری از مدولاسیون‌ها را شناسایی کرد. هم‌چنین می‌توان با استفاده از روش‌های یادگیری عمیق، مقاومت سیستم پیشنهادی در برابر نویز را افزایش داد.

منابع

- غلام‌نژاد، پژمان، غلامی، محمود و پورمکاری، علیرضا. (۱۳۹۸). کاربردهای نظامی اینترنت اشیا با تأکید بر ماموریت‌های نیروی هوایی ارتش جمهوری اسلامی ایران. علوم و فنون نظامی، ۱۵(۴۹)، ۱۴۱-۱۶۳.
- کمالی، روزبه، و بخشنده، محمد. (۱۳۸۹). اختلال هوشمند در سامانه‌های موقعیت‌یاب جهانی (GPS). علوم و فنون نظامی، ۷(۱۸)، ۵۱-۶۴.
- محمدی، اردشیر، نواده توپچی، حسین، فروزان، ایرج، شکوهی، حسین، و ایجابی، ابراهیم. (۱۴۰۱). مؤلفه‌های اثرگذار بر کشف و مقابله با هواپیمای بدون سرنشین در صحنه‌های نبرد آینده. آینده‌پژوهی دفاعی، ۷(۲۵)، ۱۳۷-۱۶۶.

مهرگان، محمدرضا، خراشادی‌زاده، محمدرضا و پرتوی، محمدتقی. (۱۳۹۷). شبیه‌سازی کشف و شناسایی اهداف پرنده در سامانه‌های فرماندهی و کنترل با بهره‌گیری از نظریه فازی. آینده پژوهی دفاعی، ۳(۱۱)، ۹۹-۱۱۷.

- Ali, A., Yangyu, F., & Liu, S. (2017). Automatic modulation classification of digital modulation signals with stacked autoencoders. *Digital Signal Processing*, 71, 108–116.
- Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., Santamaría, J., Fadhel, M. A., Al-Amidie, M., & Farhan, L. (2021). Review of deep learning: concepts, CNN architectures, challenges, applications, future directions, *Journal of Big Data*, 8 (1), 1–74.
- Azzouz, E. E., & Nandi, A. K. (1995). Automatic identification of digital modulation types. *Signal processing*, 47(1), 55-69.
- Bolle, R., Connell, J., Pankanti, S., Ratha, N., & Senior, A. (2003). *Guide to Biometrics*, Springer Professional Computing.
- Burges, C. J. (1998). A tutorial on support vector machines for pattern recognition. *Data mining and knowledge discovery*, 2(2), 121-167.
- Cervantes, J., Garcia-Lamont, F., Rodríguez-Mazahua, L., & Lopez, A. (2020). A comprehensive survey on support vector machine classification: Applications, challenges and trends. *Neurocomputing*, 408, 189-215.
- Chen, M., Challita, U., Saad, W., Yin, C., & Debbah, M. (2019). Artificial neural networks-based machine learning for wireless networks: a tutorial. *IEEE Communications Surveys Tutorials*, 21(4), 3039-3071.
- Chen, W., Jiang, Y., Zhang, L., & Zhang, Y. (2021). A new modulation recognition method based on wavelet transform and high-order cumulants. In *Journal of Physics: Conference Series*, 1738(1), 012025.
- Danev, B., Zanetti, D., & Capkun, S. (2012), On physical-layer identification of wireless devices. *ACM Computing Survey*, 45(1), 6-29.
- Dobre, O. A., Abdi, A., Bar-Ness, Y., and Su, W. (2007). Survey of automatic modulation classification techniques: classical approaches and new trends. *IET Communications*, 1(2), 137-156.
- Hermawan, A. P., Ginanjar, R. R., Kim, D., & Lee, J., (2020). CNN-based automatic modulation classification for beyond 5G communications. *IEEE Communications Letters*, 24(5), 1038-1041.
- Huang, S., Lin, C., Xu, W., Gao, Y., Feng, Z., & Zhu, F. (2020). Identification of active attacks in Internet of Things: Joint model-and data-driven automatic modulation classification approach. *IEEE Internet of Things Journal*, 8(3), 2051-2065.

- Iliadis, L., & Magri, L. (2022). Special issue on deep learning modeling in real life: anomaly detection, biomedical, concept analysis, finance, image analysis, recommendation. *Neural Computing and Applications*, 34(22), 19397-19400.
- Kalbkhani, H., Shayesteh, M. G., & Zali-Vargahan, B. (2013). Robust algorithm for brain magnetic resonance image (MRI) classification based on GARCH variances series. *Biomedical Signal Processing and Control*, 8(6), 909-919.
- Khosraviyani, M., Kalbkhani, H., & Shayesteh, M. G. (2019). Higher order statistics for modulation and STBC recognition in MIMO systems. *IET Communications*, 13(16), 2436-2446.
- Lopatka, J., & Pedzisz, M. (2000, August). Automatic modulation classification using statistical moments and a fuzzy classifier. In *5th International Conference on Signal Processing Proceedings*, 3, 1500-1506.
- Moon, J., Hossain, M. B., Chon, K. H. (2021). AR and ARMA model order selection for time-series modeling with ImageNet classification. *Signal Processing*, 183, 108026.
- Murphy, K. P. (2022). *Probabilistic Machine Learning: An Introduction*. Cambridge, MA, USA: MIT Press.
- O'Shea, T. J., Corgan, J., & Clancy, T. C. (2016). Convolutional radio modulation recognition networks. In *Engineering Applications of Neural Networks: 17th International Conference, EANN 2016, Aberdeen, UK*, 213-226.
- O'Shea, T. J., Roy, T., & Clancy, T. C. (2018). Over-the-air deep learning-based radio signal classification, *IEEE Journal of Selected Topics in Signal Processing*, 12(1), 168-179.
- Peng, S., Sun, S., and Yao, Y.-D. (2022). A survey of modulation classification using deep learning: Signal representation and data preprocessing. *IEEE Transactions on Neural Networks Learning Systems*, 33(12), 7020-7038.
- Popoola, J. J., & Van Olst, R. (2011). A novel modulation-sensing method. *IEEE Vehicular Technology Magazine*, 6(3), 60-69.
- Ramjee, S., Ju, S., Yang, D., Liu, X., Gamal, A., & Eldar, Y. C. (2019). Fast deep learning for automatic modulation classification, *arXiv preprint*, arXiv:1901.05850.
- Sherme, A. E. (2012). A novel method for automatic modulation recognition. *Applied Soft Computing*, 12(1), 453-461.
- Simic, M., Stanković, M., & Orlic, V. D. (2021). Automatic Modulation Classification of Real Signals in AWGN Channel Based on Sixth-Order Cumulants. *Radioengineering*, 30(1).

- Tang, N., Wang, X., Zhou, F., Tang, S., & Lyu, Y. (2024). Reparameterization Causal Convolutional Network for Automatic Modulation Classification. *IEEE Transactions on Vehicular Technology*.
- Wei, W., & Mendel, J. M. (2000). Maximum-likelihood classification for digital amplitude-phase modulations. *IEEE Transactions on Communications*, 48(2), 189-193.
- Wong, M. D., & Nandi, A. K. (2001, August). Automatic digital modulation recognition using spectral and statistical features with multi-layer perceptron. In *Proceedings of the sixth international symposium on signal processing and its applications*, 2, 390-393.
- Xu, Y., Li, D., Wang, Z., Guo, Q., & Xiang, W. (2019). A deep learning method based on convolutional neural network for automatic modulation classification of wireless signals, *Wireless Networks*, 25(7), 3735–3746.
- Yan, X., Chen, Y., Zhong, X., Wu, H. C., & Wang, Q. (2024). Efficient Automatic Composite-Modulation Classifier Using Cyclic-Paw-Print Features. *IEEE Communications Letters*.
- Yang, Y., & Soliman, S. S. (1991, June). Optimum classifier for M-ary PSK signals. In *International Conference on Communications Conference Record*, 1693-1697.
- Yang, Y., Yang, J., Xu, C., & Shen, X. (2024). Sensing-based Feature Engineering and Asynchronous OFDM Blind Modulation Classification Using SMOTE-DNN. *IEEE Sensors Journal*.
- Yin, L., Xiang, X., & Liang, Y. (2023). Cyclostationary Feature-based Modulation Classification with Convolutional Neural Network in Multipath Fading Channels. *IEEE Access*, 11, 105455 – 105465.
- Zhang, H., Nie, R., Lin, M., Wu, R., Xian, G., Gong, X., ... & Luo, R. (2021). A deep learning-based algorithm with multi-level feature extraction for automatic modulation recognition. *Wireless Networks*, 27(7), 4665-4676.
- Zhuo, F., Huang, Y., & Chen, J. (2016). Specific emitter identification based on linear polynomial fitting of the energy envelope. In *Proc. of 6th International Conference on Electronics Information and Emergency Communication (ICEIEC)*, 278-281.
- Zhou, Q., Zhang, R., Zhang, F., & Jing, X. (2022). An automatic modulation classification network for IoT terminal spectrum monitoring under zero-sample situations. *EURASIP Journal on Wireless Communications and Networking*, 2022(1), 25.