

آشکارسازی کور سیگنال های مخابرات ماهواره ای مبتنی بر مدولاسیون کلیدزنی قطبش

مصطفی امیری^{۱*}، حامد احمدیان یزدی^۲ و حمیدرضا خدادادی^۲

۱- دانشجوی دکتری، دانشکده مهندسی برق، دانشگاه جامع امام حسین (ع)، تهران، ایران

۲- استادیار، دانشکده مهندسی برق، دانشگاه جامع امام حسین (ع)، تهران، ایران

چکیده

در این مقاله، مسئله آشکارسازی کور مدولاسیون کلیدزنی قطبش در حضور نویز AWGN و در کنار سایر مدولاسیون های متداول در مخابرات ماهواره ای (PSK و QAM) مورد بررسی قرار گرفته است. با توجه به اهمیت امنیت و مقاومت در برابر اختلال در لینک های ماهواره ای، مدولاسیون POLSK به عنوان گزینه ای نوین با قابلیت ذخیره سازی اطلاعات در بعد قطبش مطرح می شود. بدین منظور، بردارهای استوکس استخراج شده از سیگنال دریافتی به عنوان ورودی به دو معماری یادگیری عمیق شامل شبکه پرسپترون چندلایه (MLP) و شبکه عصبی کوآترنیونی (QNN) اعمال شد و عملکرد این دو آشکارساز از منظر دقت طبقه بندی و ماتریس درهم ریختگی در بازه SNR صفر تا ۲۰ dB ارزیابی گردید. به منظور ارزیابی جامع، یک مجموعه داده شامل حدود شش میلیون نمونه بردار استوکس برای هر کلاس تولید شد. نتایج شبیه سازی بر روی پایگاه داده ترکیبی شامل سیگنال های POLSK، PSK، QAM و نویز نشان می دهد که شبکه QNN با بهره گیری از ماهیت جبری کوآترنیونی و مدل سازی هم بستگی بین مؤلفه های چندبعدی بردار استوکس، عملکرد بسیار بهتری نسبت به MLP دارد. این شبکه توانست به میانگین دقت کلی ۹۵/۸ درصد در کل بازه SNR دست یابد و خطای طبقه بندی را به ویژه در تفکیک POLSK از سایر مدولاسیون ها به حداقل برساند. بررسی ماتریس های درهم ریختگی نشان می دهد که QNN برخلاف شبکه MLP قادر به تفکیک مؤثر کلاس POLSK از سایر مدولاسیون ها و نویز است. و به عنوان گزینه ای مناسب تر برای آشکارسازی کور در کاربردهای عملی مخابرات ماهواره ای معرفی می گردد.

واژه های کلیدی: آشکارسازی کور، قطبش، یادگیری عمیق، کوآترنیونی

Blind Detection of Satellite Communication Signals Based on Polarization Shift Keying Modulation

Mustafa Amiri¹, Hamed Ahmadian Yazdi², Hamid Reza Khodadadi²

1. PhD Student, Faculty of Electrical Engineering Department, Imam Hossein University, Tehran, Iran,

2. Assistant Professor, Faculty of Electrical Engineering Department, Imam Hossein University, Tehran, Iran.

Abstract

In this research, the problem of blind detection of Polarization Shift Keying (POLSK) modulation is investigated in the presence of Additive White Gaussian Noise (AWGN) and alongside other common satellite communication modulations (PSK and QAM). Given the critical importance of security and anti-jamming capabilities in satellite links, POLSK emerges as a novel alternative capable of embedding information within the polarization domain. To this end, Stokes vectors extracted from the received signals were utilized as input features for two deep learning architectures: a Multilayer Perceptron (MLP) and a Quaternion Neural Network (QNN). The detection performance of these models was evaluated based on classification accuracy and confusion matrices over a SNR range of 0 to 20 dB. For a comprehensive evaluation, a large-scale dataset comprising approximately six million Stokes vector samples per class was generated. Simulation results on the combined dataset including POLSK, PSK, QAM, and noise demonstrate that the QNN significantly outperforms the MLP by leveraging quaternion algebra and effectively modeling the multidimensional correlations among the Stokes vector components. The QNN architecture achieved an average overall accuracy of 95.8% across the entire SNR range, substantially minimizing classification errors, particularly in isolating POLSK from other modulations. Furthermore, analysis of the confusion matrices reveals that the QNN, unlike the PMLP, is highly capable of discriminating the POLSK class from interference and noise, establishing it as a highly robust and suitable candidate for blind detection in practical satellite communication applications.

Key words: Electronic Warfare, Artificial Intelligence, Neural Networks, Deception, Electronic Countermeasures.

شناسایی کور مدولاسیون^۱ یکی از مسائل کلیدی در سامانه‌های مخابراتی مدرن، به‌ویژه در کاربردهایی نظیر شنود تطبیقی، رادیوشناختی و جنگ الکترونیک محسوب می‌شود [۱،۲]. در این مسئله، گیرنده بدون دسترسی به اطلاعات جانبی فرستنده نظیر نوع مدولاسیون، توان سیگنال، فرکانس حامل، فاز اولیه و اطلاعات زمانی، تلاش می‌کند نوع مدولاسیون سیگنال دریافتی را تشخیص دهد. در طول دهه‌های گذشته، رویکردهای متنوعی برای حل این مسئله ارائه شده‌اند که به‌طور کلی می‌توان آن‌ها را به روش‌های سنتی و روش‌های مبتنی بر یادگیری داده‌محور تقسیم کرد [۱،۳]. نخستین و کلاسیک‌ترین دسته از روش‌های شناسایی کور، روش‌های مبتنی بر توزیع آماری و نظریه تصمیم هستند. این روش‌ها بر این فرض استوارند که هر نوع مدولاسیون دارای مشخصات آماری منحصر به فردی است که می‌توان آن‌ها را از سیگنال دریافتی استخراج و با مدل‌های مرجع مقایسه کرد. در این چارچوب، آزمون‌های نیکویی برازش^۲ نظیر آزمون کولموگروف-اسمیرنوف و آزمون کای-دو به‌طور گسترده مورد استفاده قرار گرفته‌اند [۴]. این روش‌ها معمولاً دقت بالایی در شرایط نویزی ساده نظیر کانال AWGN دارند، اما عملکرد آن‌ها به‌شدت به دقت مدل‌سازی نویز و کانال وابسته بوده و در کانال‌های چندمسیره یا زمان متغیر با افت کارایی مواجه می‌شوند [۳]. دسته دیگری از روش‌های سنتی، روش‌های مبتنی بر بیشینه درست‌نمایی^۳ هستند که با محاسبه تابع درست‌نمایی سیگنال دریافتی تحت فرض انواع مختلف مدولاسیون، تصمیم‌گیری را انجام می‌دهند [۵،۶]. این روش‌ها از نظر تئوریک بهینه محسوب می‌شوند و می‌توانند مرزهای تصمیم دقیق‌تری نسبت به روش‌های ساده آماری فراهم کنند. با این حال، پیچیدگی محاسباتی بالا و نیاز به دانستن یا تخمین دقیق پارامترهای کانال و نویز، استفاده عملی از آن‌ها را در بسیاری از کاربردها محدود می‌سازد. در گام بعدی، روش‌های مبتنی بر استخراج ویژگی^۴ معرفی شدند که با هدف کاهش وابستگی به مدل‌های آماری دقیق توسعه یافتند [۷،۸]. در این روش‌ها، ویژگی‌های متمایزکننده‌ای از سیگنال استخراج می‌شود و فرآیند شناسایی بر اساس این ویژگی‌ها صورت می‌گیرد. این ویژگی‌ها می‌توانند شامل ویژگی‌های آماری مرتبه‌های بالا نظیر چولگی و کشیدگی، ویژگی‌های طیفی مانند پهنای باند و توزیع انرژی در فرکانس، و ویژگی‌های حوزه تبدیل نظیر ضرایب تبدیل ویولت یا تبدیل فوریه کوتاه‌مدت باشند. روش‌های مبتنی بر ویژگی نسبت به روش‌های آماری کلاسیک انعطاف‌پذیری بیشتری داشته و در شرایط کانالی متنوع عملکرد پایدارتری ارائه می‌دهند، اما انتخاب مجموعه ویژگی مناسب و طراحی آستانه‌های تصمیم‌گیری همچنان چالش برانگیز است [۷،۸]. با پیشرفت روش‌های محاسباتی، یادگیری ماشین کلاسیک به‌عنوان رویکردی میانی بین روش‌های سنتی و یادگیری عمیق مطرح شد [۳]. در این چارچوب، ویژگی‌های

استخراج‌شده به‌عنوان ورودی به طبقه‌بندهایی نظیر ماشین بردار پشتیبان، شبکه‌های عصبی چندلایه (MLP)، روش‌های مبتنی بر نزدیک‌ترین همسایه و درخت‌های تصمیم داده می‌شوند [۸]. این روش‌ها قادرند مرزهای تصمیم غیرخطی را یاد بگیرند و نسبت به تغییرات پارامترهای کانال مقاوم‌تر باشند. با این حال، عملکرد آن‌ها به‌شدت به کیفیت ویژگی‌های ورودی وابسته بوده و فرآیند طراحی ویژگی همچنان نیازمند دانش تخصصی است. در سال‌های اخیر، روش‌های مبتنی بر یادگیری عمیق تحولی اساسی در شناسایی کور مدولاسیون ایجاد کرده‌اند [۹،۱۰]. شبکه‌های عصبی کانولوشنی (CNN) با بهره‌گیری از ساختار مکانی داده‌ها، توانایی استخراج خودکار ویژگی‌ها از نمونه‌های خام سیگنال را دارند [۹]. همچنین شبکه‌های بازگشتی (RNN) و ساختارهای مبتنی بر حافظه مانند LSTM و GRU برای مدل‌سازی وابستگی‌های زمانی سیگنال به‌کار گرفته شده‌اند [۱۰]. این رویکردها نیاز به استخراج دستی ویژگی را تا حد زیادی حذف کرده و امکان یادگیری مستقیم از داده خام را فراهم می‌کنند که این امر به بهبود قابل توجه عملکرد در شرایط نویزی شدید و کانال‌های پیچیده منجر شده است. با این حال شبکه‌های CNN برای داده‌های مثل تصویر و LSTM برای وابستگی‌های زمانی عالی هستند. اما مدولاسیون POLSK اطلاعات را در بعد قطبش و روی کره پوانکاره کدگذاری می‌کند که با بردارهای استوکس چهاربعدی نمایش داده می‌شوند. در نتیجه هیچ‌کدام از ساختارهای CNN یا LSTM ذاتاً برای درک این هندسه چندبعدی طراحی نشده‌اند. در حالی که شبکه کوآترنیونی (QNN) دقیقاً برای پردازش داده‌های چهار بعدی ساخته شده است. در جمع‌بندی، اگرچه روش‌های آماری، درست‌نمایی و مبتنی بر ویژگی از نظر تئوریک قابل تحلیل بوده و در شرایط ساده عملکرد مناسبی دارند، اما وابستگی آن‌ها به مدل‌های دقیق، حساسیت به تغییرات کانال و محدودیت در مقیاس‌پذیری، کاربرد آن‌ها را در سناریوهای واقعی محدود می‌سازد. نوآوری این مقاله عبارت است از ارائه یک چارچوب مبتنی بر شبکه عصبی کوآترنیونی برای آشکارسازی کور مدولاسیون POLSK در حضور سایر مدولاسیون‌ها و نویز محیطی. در این رویکرد، به جای استفاده از شبکه‌های متداول اشاره شده در بالا از جبر کوآترنیونی استفاده شده است. این نوآوری به شبکه اجازه می‌دهد تا همبستگی‌های ذاتی بین پارامترهای استوکس را به‌طور یکپارچه مدل‌سازی کرده و به تفکیک‌پذیری و دقت بسیار بالاتری نسبت به شبکه‌های رایج در بازه‌های مختلف SNR دست یابد. بر این اساس، هدف اصلی این مطالعه، بر تمرکز بر تشخیص حضور یا عدم حضور مدولاسیون POLSK معطوف است. با این وجود، به منظور ارزیابی مدل در شرایطی مشابه با محیط‌های واقعی و چالش برانگیز مخابرات ماهواره‌ای، سیگنال‌هایی با مدولاسیون‌های متداول نظیر PSK و QAM به همراه نویز سفید گوسی AWGN نیز در محیط شبیه‌سازی لحاظ شده‌اند.

³- Maximum Likelihood

⁴- Feature-Extraction

¹- Blind Modulation Recognition

²- Goodness-of-Fit

$$J = \begin{pmatrix} A_x e^{j\phi_x} \\ A_y e^{j\phi_y} \end{pmatrix} = \begin{pmatrix} X_I + jX_Q \\ Y_I + jY_Q \end{pmatrix} \quad (2)$$

این نمایش برای سیستم‌های همدوس مناسب است، اما وابستگی آن به فاز مطلق، کاربرد آن را در شرایط عملی محدود می‌کند [۱۶]. برای غلبه بر این محدودیت، از بردار استوکس استفاده می‌شود که مستقل از فاز مطلق بوده و توصیفی تجربی از حالت قطبش ارائه می‌دهد. بردار استوکس مطابق رابطه (۳) شامل چهار پارامتر زیر است [۱۵]:

$$S = \begin{pmatrix} S_0 \\ S_1 \\ S_2 \\ S_3 \end{pmatrix} = \begin{pmatrix} A_x^2 + A_y^2 \\ A_x^2 - A_y^2 \\ 2A_x A_y \cos \delta \\ 2A_x A_y \sin \delta \end{pmatrix} = \begin{pmatrix} X_I^2 + X_Q^2 + Y_I^2 + Y_Q^2 \\ X_I^2 + X_Q^2 - Y_I^2 - Y_Q^2 \\ 2(X_I Y_I + X_Q Y_Q) \\ 2(X_Q Y_I - X_I Y_Q) \end{pmatrix} \quad (3)$$

در این نمایش:

- S_0 متناسب با توان کل سیگنال است،
- S_1 بیانگر قطبش خطی افقی/عمودی،
- S_2 بیانگر قطبش خطی قطری ($\pm 45^\circ$)،
- S_3 نشان‌دهنده قطبش دایروی راست‌گرد یا چپ‌گرد است.

برای توان ثابت، بردار (S_1, S_2, S_3) نقاطی را روی کره پوانکره^۴ تشکیل می‌دهد که نمایش هندسی حالات مختلف قطبش را فراهم می‌کند [۱۸] (مطابق شکل مرجع کره پوانکره). در این فضا، حالات قطبش متعامد در نقاط مقابل یکدیگر روی کره قرار می‌گیرند.

۲-۲- اصول مدولاسیون POLSK و پرش قطبش

در POLSK، اطلاعات دیجیتال به مجموعه‌ای از حالات قطبش از پیش تعریف‌شده^۵ (SOP) نگاشته می‌شوند. این SOPها به صورت نقاط مشخصی روی کره پوانکره انتخاب شده و به عنوان صورت‌فلکی مدولاسیون عمل می‌کنند [۱۵].

برای افزایش امنیت و خاصیت LPE، از مفهوم پرش شبه تصادفی قطبش^۶ استفاده می‌شود. در این حالت، نگاشت بیت‌ها به SOPها بر اساس یک دنباله شبه تصادفی انجام شده و حالت قطبش سیگنال ارسالی به صورت نماد به نماد تغییر می‌کند. در نتیجه، برای شنودگر فاقد کلید یا کد پرش، سیگنال دریافتی مشابه نویز شبه تصادفی ظاهر می‌شود.

۲- معرفی مدولاسیون کلید زنی قطبش

در طراحی سیستم‌های مخابراتی امن و پایدار، دو ویژگی احتمال پایین بهره‌برداری^۷ (LPE) و مقاومت در برابر اختلال^۸ (AJ) نقش کلیدی دارند. هدف اصلی در چنین سیستم‌هایی کاهش قابلیت آشکارسازی، شنود و اختلال عمدی سیگنال، در کنار حفظ کارایی طیفی و نرخ داده مناسب است [۱۲]. روش‌های کلاسیک نظیر طیف گسترده دنباله مستقیم (DSSS) و پرش فرکانسی (FH) اگرچه سطح بالایی از LPE و AJ را فراهم می‌کنند، اما به قیمت افزونگی پهنای باند و کاهش بهره طیفی تمام می‌شوند [۱۲]. با افزایش تراکم طیفی و نیاز به لینک‌های پرسرعت، استفاده از مدولاسیون‌هایی با پهنای باند باریک‌تر و در عین حال امن، به یک ضرورت تبدیل شده است [۱۳]. در این راستا، مدولاسیون کلید زنی قطبش^۹ (POLSK) به عنوان رویکردی نوین مطرح شده است که با بهره‌گیری از بعد قطبش، امکان انتقال اطلاعات، افزایش امنیت و بهبود مقاومت در برابر اختلال را بدون نیاز به گسترش طیف فراهم می‌کند [۱۴]. در این روش، اطلاعات دیجیتال به جای دامنه یا فاز، در حالت قطبش سیگنال الکترومغناطیسی نهفته می‌شوند [۱۵]. در مخابرات مایکروویو و ماهواره‌ای، انتشار موج الکترومغناطیسی معمولاً به صورت موج صفحه‌ای عرضی (TEM) مدل می‌شود که در آن میدان الکتریکی عمود بر جهت انتشار است [۱۴-۱۶]. میدان الکتریکی یک موج تک‌فرکانس منتشرشونده در راستای z ، در دستگاه مختصات دکارتی به صورت معادله (۱) بیان می‌شود [۱۶]:

$$E(t, z) = \begin{pmatrix} E_x(t, z) \\ E_y(t, z) \end{pmatrix} = \begin{pmatrix} A_x e^{j(\omega t - k_z z + \phi_x)} \\ A_y e^{j(\omega t - k_z z + \phi_y)} \end{pmatrix} \quad (1)$$

که در آن A_x و A_y دامنه‌ها و ϕ_x و ϕ_y فاز مؤلفه‌های افقی و عمودی میدان هستند. اختلاف فاز $\phi_y - \phi_x = \delta$ و نسبت دامنه‌ها A_x/A_y ، نوع قطبش موج را تعیین می‌کنند. بر این اساس، حالات قطبش به سه دسته‌ی اصلی قطبش خطی (افقی، عمودی یا مایل)، قطبش دایروی (راست‌گرد و چپ‌گرد)، قطبش بیضوی تقسیم می‌شوند [۱۷].

۱-۲- نمایش ریاضی حالت قطبش

برای توصیف تحلیلی حالت قطبش، از بردار جونز استفاده می‌شود که شامل دامنه و فاز مختلط مؤلفه‌های متعامد میدان الکتریکی مطابق معادله (۲) است [۱۶]:

⁸- Poincaré Sphere


⁹- States of Polarization

¹⁰- Pseudo-random Polarization Hopping

⁵- Low Probability of Exploitation

⁶- Anti-Jamming

⁷- Polarization Shift Keying



شکل ۲- بلوک دیاگرام گیرنده POLSK


اول آن که آشکارساز مدولاسیون باید بتواند بیشترین تعداد ممکن مدولاسیون را آشکارسازی کند. این باعث می‌شود که آشکارسازی مدولاسیون در کاربردهای مختلفی قابل پیاده‌سازی باشد و نیازی به اصلاح روش و اضافه کردن مدولاسیون‌های بیشتر نباشد. دوم آن که آشکارساز مدولاسیون باید از دقت بالایی برخوردار باشد. این دقت آشکارسازی بالا وابسته به سطوح مختلف نویز است. سوم آن که آشکارساز مدولاسیون باید در شرایط مختلف کانال مقاوم^۲ باشد. مقاوم بودن آشکارساز را می‌توان با تخمین شرایط کانال و مکانیسم‌های اصلاحی فراهم ساخت. چهارم آن که آشکارساز مدولاسیون باید از نظر پیچیدگی محاسباتی بهینه باشد. در بسیاری از کاربردها، محدودیت شدیدی در توان محاسباتی وجود دارد و این باعث می‌شود که آشکارسازهای مدولاسیون با پیچیدگی محاسباتی بالا برای این کاربردها مناسب و کاربردی نباشند. همچنین، بعضی از کاربردها نیاز به انجام تصمیم‌گیری سریعی دارند، که باعث می‌شود که پروسه آشکارسازی بسیار سریع انجام شود. فقط آشکارسازهای مدولاسیون با بهره‌وری محاسباتی بالا می‌توانند برای این کاربردها مناسب باشند. در کل باید به این نکته اشاره نمود که، یک الگوریتم آشکارسازی مدولاسیون بایستی دارای سرعت مناسب با پیچیدگی محاسباتی پائین و دقت بالا باشد. در این پژوهش قصد داریم عملکرد دو شبکه آشکارساز MLP و QNN را در تشخیص مدولاسیون POLSK بررسی کنیم.

۳-۱- شبکه MLP

شبکه پرسپترون چندلایه یکی از متداول‌ترین معماری‌های شبکه‌های عصبی پیش‌خور است که از لایه ورودی، یک یا چند لایه پنهان کاملاً متصل^۴ و لایه خروجی تشکیل می‌شود (شکل ۳). [۲۱]. هر نورون با اعمال ترکیب خطی وزن‌دار روی ورودی‌ها و سپس عبور از یک تابع فعال‌ساز غیرخطی (مانند Sigmoid، tanh یا ReLU) قادر به مدل‌سازی روابط غیرخطی در داده‌ها است. در مسائل رگرسیون معمولاً از خروجی خطی و در مسائل طبقه‌بندی چندکلاسه از تابع Softmax در لایه خروجی استفاده می‌شود [۲۲].

۲-۳- مدل فرستنده

فرستنده POLSK (شکل ۱) از دید ساختاری مشابه یک مدولاتور QAM دوکاناله است که خروجی‌های آن به دو محور قطبش افقی و عمودی اعمال می‌شوند. پارامترهای دامنه و فاز هر نماد از طریق جدول جستجوی سمبل و بر اساس صورت‌فلکی تعریف‌شده در فضای استوکس تعیین می‌شوند [۱۴]. توزیع یکنواخت توان بین دو قطبش موجب بهبود پایداری بازیابی حامل و افزایش مقاومت سیستم در برابر نوسانات فاز و کانال می‌شود زنجیره ارسال شامل شکل‌دهی پالس، نمونه‌برداری افزایشی، تبدیل فرکانسی و کنترل بهره خودکار بوده و مشابه فرستنده‌های دیجیتال متداول پیاده‌سازی می‌شود [18].



شکل ۱- بلوک دیاگرام فرستنده POLSK

۲-۴- مدل گیرنده

گیرنده POLSK (شکل ۲) علاوه بر زنجیره کلاسیک پایین‌تبدیل و فیلتر، نیازمند پردازش قطبش برای استخراج SOP دریافتی است. با تخمین پارامترهای استوکس و نگاشت نقطه دریافتی در فضای پوینکر، آشکارسازی نماد با استفاده از معیار حداقل فاصله انجام می‌شود [۱۴]. حذف وابستگی به فاز مطلق در نمایش استوکس، فرآیند بازیابی حامل را ساده‌تر و مقاوم‌تر از مدولاسیون‌های فازی متداول می‌سازد و همین امر POLSK را به گزینه‌ای مناسب برای لینک‌های ماهواره‌ای و محیط‌های دارای ناپایداری فاز تبدیل می‌کند [۱۴].

۳- آشکارسازی

در تمام الگوریتم‌های آشکارسازی راندمان و دقت آشکارسازی مدولاسیون‌ها از اهمیت ویژه‌ای برخوردار است. مشخصه‌های یک آشکارسازی مدولاسیون شامل موارد زیر است [۲۰]:

¹²- multi layer perceptron
¹³- Fully Connected/Dense

¹¹- Adaptive Polarization Nulling
¹²- Robust

با توجه به روابط بالا و اینکه سه محور موهومی i, j, k نسبت به هم عمود هستند لذا می‌توان گفت که شبکه QNN برای بررسی ساختارهای سه بعدی مناسب هستند. نرم عدد کوترنیون از رابطه (۵) بدست می‌آید:

$$|q| = \sqrt{q_0^2 + q_1^2 + q_2^2 + q_3^2} \quad (۵)$$

یک عدد کوترنیونی را می‌توان به شکل قطبی به صورت رابطه (۶) زیر نمایش داد [۲۶]:

$$q = |q|(\cos \Phi + \eta \sin \Phi) = |q|e^{\eta \Phi}$$

$$\eta = \frac{1}{|q|\sqrt{1 - \left(\frac{q_0}{|q|}\right)^2}}(q_1 i + q_2 j + q_3 k)$$

$$\Phi = \arccos\left(\frac{q_0}{|q|}\right) \quad (۶)$$

که در آن Φ محور کوترنیون و η فاز کوترنیون است. ضرب بیرونی یا همیلتون دو عدد کوترنیون به صورت رابطه (۷) است که حاصل آن یک عدد کوترنیون است [۲۷]:

$$q_1 = (a_1, \tilde{q}) = a_1 + b_1 i + c_1 j + d_1 k$$

$$q_2 = (a_2, \tilde{q}) = a_2 + b_2 i + c_2 j + d_2 k$$

$$q_1 \otimes q_2 = a_1 a_2 - b_1 b_2 - c_1 c_2 - d_1 d_2$$

$$+ (a_1 b_2 + b_1 a_2 + c_1 d_2 - d_1 c_2) i$$

$$+ (a_1 c_2 - b_1 d_2 + c_1 a_2 + d_1 b_2) j$$

$$+ (a_1 d_2 + b_1 c_2 - c_1 b_2 + d_1 a_2) k \quad (۷)$$

ضرب درونی کوترنیون دارای دو تعریف رایج به صورت رابطه (۸) است که در آن حاصل اسکالر است [۲۷]:

$$q_1 \odot q_2 = (a_1 a_2 + b_1 b_2 + c_1 c_2 + d_1 d_2) \quad (۸)$$


در QNN، عملیات انتشار رو به جلو و پس انتشار گرادینان بر پایه ضرب و جمع کوترنیونی تعریف می‌شود. معماری QNN مشابه شبکه‌های پیش‌خور شامل لایه‌های ورودی، پنهان و خروجی است، با این تفاوت که تمام پارامترها کوترنیونی هستند (شکل ۴). لذا صرفاً به علت ماهیت ورودی، خروجی، وزن‌ها و بایاس لایه‌ها که از جنس کوترنیون هستند این انتظار است که عملکرد بهتری نسبت به MLP داشته باشد. در مدل ارایه شده در بالا وزن سیناپسی را با w_{oji} (وزن بین نورون i به j در لایه o) و مطابق رابطه (۹) نمایش می‌دهیم:

$$w_{oji} = (w_{0,oji}, \tilde{w}_{oji}) \quad (۹)$$

وضعیت داخلی نورون j در لایه o (v_{oj}) به صورت رابطه (۱۰) خود را بروز رسانی می‌کند:

$$v_{oj} = \sum_i w_{oji} \otimes u_{(o-1)i} + \theta_{oj} \quad (۱۰)$$

به طوریکه $u_{(o-1)i}$ مقدار نورون i ام در لایه $(o-1)$ م و θ_{oj} مقدار بایاس نورون j در لایه o است.



شکل ۳- ساختار شبکه MLP

آموزش شبکه MLP مبتنی بر الگوریتم پس انتشار خطا^{۱۴} و بهینه‌سازی گرادینانی پارامترها با بهینه‌سازهایی نظیر SGD، Adam یا RMSprop انجام می‌گیرد. این شبکه به‌طور گسترده در مسائل طبقه‌بندی و رگرسیون روی داده‌های عددی به کار می‌رود، اما در مقایسه با معماری‌های تخصصی‌تر مانند CNN و LSTM در استخراج ویژگی‌های مکانی و زمانی پیچیده کارایی کمتری دارد. با این حال، سادگی ساختار، قابلیت تقریب توابع غیرخطی و پایداری آموزش، MLP را به یک خط پایه مهم در بسیاری از کاربردهای یادگیری ماشین تبدیل کرده است.

۳-۲- شبکه QNN^{۱۵}

شبکه‌های کوترنیونی خانواده‌ای از شبکه‌های هوش مصنوعی هستند که به جای مقادیر حقیقی یا مختلط، از اعداد کوترنیونی برای نمایش ورودی‌ها، وزن‌ها، بایاس‌ها و خروجی نورون‌ها استفاده می‌کنند [23]. کوترنیون‌ها به‌طور طبیعی قادر به نمایش بردارها و چرخش‌ها در فضای سه‌بعدی هستند و به همین دلیل در حوزه‌هایی نظیر پردازش سیگنال تصویری [۲۴]، بینایی ماشین، و محاسبات فضایی کاربرد گسترده‌ای داشته‌اند [۲۵]؛ به‌طور خاص، استفاده از نمایش کوترنیونی در پردازش سیگنال‌های چندمؤلفه‌ای (مانند سیگنال‌های قطبیده و داده‌های چندکاناله نظیر RGB) امکان مدل‌سازی هم‌بستگی درون کانالی را با تعداد پارامتر کمتر و ساختار جبری غنی‌تر فراهم می‌کند [۲۴]. در سال‌های اخیر، معماری‌های عمیق مبتنی بر کوترنیون، از جمله نسخه‌های کوترنیونی شبکه‌های کانولوشنی الهام گرفته از CNN، برای بهبود کارایی در تحلیل تصاویر رنگی و سیگنال‌های چندبعدی پیشنهاد شده‌اند [24]. از منظر ریاضی، یک عدد کوترنیون به‌صورت رابطه (۴) تعریف می‌شود که شامل یک مؤلفه حقیقی و سه مؤلفه موهومی عمود بر هم است [۲۶]:

$$q = (q_0, \tilde{q}) = q_0 + q_1 i + q_2 j + q_3 k \quad (۴)$$

¹⁵⁻ Quaternion neural network

¹⁴⁻ Backpropagation

که در آن C تعداد کلاس‌هایی است که در خروجی v_0 ظاهر می‌شود، D کلاس مطلوب است که به عنوان سیگنال آموزش دهنده عمل میکند و I {0 یا 1} تابع منطقی است بطوریکه چنانچه مقدار j برابر با کلاس مطلوب باشد 1 و در غیر اینصورت صفر خواهد بود. بهینه‌سازی پارامترها با روش‌های گرادیان کاهشی نظیر Gradient Descent و تعمیم‌های آن انجام می‌شود که در آن گرادیان‌ها مطابق با قواعد مشتق‌گیری در جبر کواترنیونی محاسبه و وزن‌ها و بایاس‌ها به‌روزرسانی می‌گردند تا خطا را به حداقل برسانند. گرادیان $J(v_0)$ به صورت رابطه (۱۶) داده می‌شود [۲۸]:

$$\nabla_{v_{toj}} J(v_o) = 2 \left(I\{j = D\} \frac{|e^{v_{toj}}|^2}{|e^{v_{oj}}|^2} - \frac{|e^{v_{toj}}|^2}{\sum_{j=1}^C |e^{v_{oj}}|^2} \right) \quad (16)$$

که در آن $t=0,1,2,3$ اندیس عناصر کواترنیون است. در این فرآیند، مقدار وزن و مقدار بایاس با رابطه (۱۷) به روز می‌شوند:

$$\begin{aligned} w_{oji}(r+1) &= w_{oji}(r) - \lambda \Delta w_{oji} \\ \theta_{oj}(r+1) &= \theta_{oj}(r) - \lambda \Delta \theta_{oj} \end{aligned} \quad (17)$$


که r تعداد تکرارهای یادگیری و λ نرخ یادگیری است.

۴- شبیه‌سازی

مهمترین گام برای ساخت یک شبکه قدرتمند با توان تشخیص بالا این است که مدل را با داده‌های مناسب و با تنوع خوب آموزش دهیم. در این پژوهش ورودی شبکه پارامترهای استوکس استخراج شده در گیرنده می‌باشد که به جهت رعایت شرط کور بودن آشکارسازی، پارامترهای استوکس از سیگنال‌های دریافت شده بعد از آنتن استخراج می‌گردد. برای افزایش دقت و منعطف تر بودن شبکه نسبت به سایر مدولاسیون‌ها و سیگنال‌های ورودی، علاوه بر مدولاسیون POLSK که مدولاسیون هدف می‌باشد پایگاه داده مربوط به مدولاسیون‌های PSK و QAM نیز تحت کلاس Others به شبکه اعمال می‌گردد. علاوه بر آن شبکه طراحی شده باید توانایی تشخیص نویز AWGN را نیز داشته باشد. در انتها عملکرد آشکارسازی دو شبکه را از نظر دقت و ماتریس درهم ریختگی مقایسه گردیده و شبکه پیشنهادی با توجه به معیارهای ارائه شده، انتخاب می‌گردد.

۴-۱- ایجاد پایگاه داده

در این پژوهش، از یک پایگاه داده ترکیبی شامل سه نوع مدولاسیون MPOLSK، MQAM و MPSK تحت تأثیر نویز در این پژوهش، از یک پایگاه داده ترکیبی شامل سه نوع



شکل ۴- ساختار شبکه QNN

توابع فعال‌ساز متداول در QNN شامل دو دسته اصلی اند [۲۸]:

۱) تابع فعال‌ساز Elementwise: که تابعی مانند tanh را به صورت مستقل بر هر مؤلفه حقیقی و موهومی اعمال می‌کند:

$$f(x) = \tanh(x) = \frac{\sinh(x)}{\cosh(x)} = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (11)$$

حال در شبکه QNN- Elementwise خروجی نرون u_{oj} توسط تابع فعال‌ساز Elementwise به صورت رابطه (۱۲) فعال می‌شود [۲۸]:

$$\begin{aligned} u_{oj} &= f_E(v_{oj}) \\ &= f(v_{0oj}) + f(v_{1oj})i + f(v_{2oj})j + f(v_{3oj})k \end{aligned} \quad (12)$$

۲) تابع فعال‌ساز Isotropic: که مطابق رابطه (۱۳) بر اساس نرم و فاز کواترنیون تعریف می‌شوند [۲۸]:

$$u_{oj} = f_I(v_{oj}) = f(|v_{oj}|) \frac{v_{oj}}{|v_{oj}|} = f(|v_{oj}|) e^{\eta\Phi} \quad (13)$$

که تابع $f(\cdot)$ همان $\tanh$ است. در مسائل طبقه‌بندی چند کلاسه، Softmax (به صورت تعمیم یافته برای ورودی‌های کواترنیونی) در لایه خروجی به کار می‌رود. تابع Softmax احتمالات هر کلاس هدف را بر روی تمام کلاس‌های هدف ممکن محاسبه می‌کند (که به تعیین کلاس هدف کمک می‌کند). در شبکه QNN تابع softmax کواترنیون به صورت رابطه (۱۴) تعریف می‌شود [۲۹]:

$$\text{softmax}(v_o) = \frac{|e^{v_{oj}}|^2}{\sum_{j=1}^C |e^{v_{oj}}|^2} \quad (14)$$

در رابطه بالا $e(\cdot)$ تابع نمایی Elementwise می‌باشد. همچنین رابطه (۱۵) تابع خطای استفاده شده در مدل QNN- cross-entropy است که به صورت زیر تعریف می‌شود [۲۸]:


$$J(v_o) = \sum_{j=1}^C I\{j = D\} \log \frac{|e^{v_{oj}}|^2}{\sum_{j=1}^C |e^{v_{oj}}|^2} \quad (15)$$

به طور مشابه نتایج آشکارسازی توسط شبکه QNN طراحی شده با تکرار ۵۰ مطابق شکل (7) است.

جدول ۲- پارامترهای شبکه های QNN و MLP

پارامتر	MLP	QNN
تعداد لایه ها	۳ لایه خطی پنهان + ۱ لایه softmax	۳ لایه کوآرتونیونی خطی + ۱ لایه خطی نهایی
توابع فعال ساز	Relu	Qnn-Elementwise
تابع خطا (Loss)	CrossEntropyLoss	CrossEntropyLoss
تابع بهینه ساز	Adam(lr=0.001)	DSG(lr=0.001)
تعداد Epoch	50	50
Train, Test Split	80% آموزش، 20% تست	80% آموزش، 20% تست
ارزیابی	Confusion Matrix	Confusion Matrix

همانطور که مشاهده می گردد عملکرد شبکه QNN در آشکارسازی و تشخیص مدولاسیون POLSK بسیار بهتر از شبکه MLP می باشد. این امر به این دلیل است که ماهیت جبری کوآرتونیونی جهت بیان فرایندهای سه بعدی همچنین قابلیت ذاتی شبکه QNN در مدل سازی هم بستگی بین مؤلفه های چند بعدی - مانند بردارهای استوکس - موجب بهبود دقت آشکارسازی، کاهش خطای طبقه بندی و افزایش تفکیک پذیری کلاس POLSK از سایر مدولاسیون ها و نویز، به ویژه در شرایط نویزی شدید گردیده است.



شکل ۶- ماتریس درهم ریختگی حاصل از شبکه MLP

مدولاسیون MPOLSK، MPSK، MQAM و تحت تأثیر نویز AWGN استفاده شده است. برای تولید پایگاه داده های هر کلاس ابتدا لینک هر مدولاسیون مطابق با پارامترهای ذکر شده در جدول (۱) در محیط MATLAB پیاده سازی گردیده سپس بردارهای استوکس هر در گیرنده مدولاسیون در بازه SNR صفر دسی بل تا ۲۰ dB و با ۱۰ تکرار در هر SNR استخراج و ذخیره گردیده است. همچنین لازم است که نویز AWGN نیز به عنوان یک ورودی مستقل به شبکه آموزش داده شود؛ بنابراین پایگاه داده مربوط به نویز را نیز با همان ساختار مشابه مدولاسیون ها استخراج می گردد.

جدول ۱- پارامترهای در نظر گرفته شده جهت تولید پایگاه داده

ردیف	عنوان پارامتر	جزئیات
1	کلاس مدولاسیون ها	MPOLSK, MPSK, MQAM
2	مرتبه مدولاسیون	2, 4, 8, 16, 32
3	SNR	0-20dB
4	SPS	4
5	Roll-off_factor	0.25
6	فرکانس مرکزی	170 MHz
7	channel type	AWGN


در نتیجه مطابق شکل (۵) خروجی نهایی به سه کلاس زیر تقسیم می شود:

کلاس ۱: سیگنالهای مدوله شده با MPOLSK

کلاس ۲: سایر مدولاسیون ها (MPSK, MQAM)

کلاس ۳: نویز

حجم داده برای هر کلاس حدود ۶ میلیون سطر بردار استوکس در بازه SNR مدنظر است.



شکل ۵- ساختار کلی سیستم آشکارساز


۴-۲- پیاده سازی و نتایج

پایگاه داده های بدست آمده به منظور آموزش و اجرای شبکه های MLP و QNN و ارزیابی عملکرد آشکارسازی و تشخیص کلاس POLSK به شبکه های مذکور با مشخصات جدول (۲) اعمال می شود. شکل (۶) ماتریس درهم ریختگی حاصل از آموزش و اجرای شبکه MLP را بعد از ۵۰ تکرار^۱ نشان می دهد.

سناریوهای واقعی مخابرات ماهواره‌ای می‌تواند عملکرد آشکارساز را تحت تأثیر قرار دهد. در راستای توسعه این پژوهش و غلبه بر محدودیت‌های ذکر شده، پیشنهاد می‌شود در کارهای آینده از ویژگی‌های ابداعی و جدید استخراج شده از پارامترهای استوکس (به جای استفاده صرف از مقادیر خام) جهت بهبود فضای ویژگی استفاده گردد. افزون بر این، برای شبیه‌سازی دقیق‌تر شرایط عملیاتی، اعمال خطاهای ناشی از عدم قطعیت کانال از جمله آفست فاز، آفست فرکانس و همچنین تضعیف متقاطع مدولاسیون^۱ به سیگنال‌های تولیدی در دستور کار قرار دارد تا پایداری و تاب‌آوری شبکه‌های کوانترنیونی در محیط‌های واقعی و پرچالش به طور جامع‌تری ارزیابی شود.

مراجع

- [1] Dobre, Octavia A., et al. "Survey of automatic modulation classification techniques: classical approaches and new trends." *IET communications* vol. no.2, pp. 137-156, 2007
- [2] Huynh-The, Thien, et al. "Automatic modulation classification: A deep architecture survey." *IEEE Access*, vol.9 pp. 142950-142971, 2021
- [3] A. Kumar, et al., "A survey of blind modulation classification techniques for OFDM signals," *Sensors*, vol. 22, no. 3, p. 1020, 2022
- [4] F. Wang and X. Wang, "Fast and robust modulation classification via Kolmogorov-Smirnov test," *IEEE Transactions on Communications*, vol. 58, no. 8, pp. 2324-2332, Aug. 2010.
- [5] F. Hameed, O. A. Dobre, and D. C. Popescu, "On the likelihood-based approach to modulation classification," *IEEE Transactions on Wireless Communications*, vol. 8, no. 12, pp. 5884-5892, Dec. 2009.
- [6] Z. Zhu and A. K. Nandi, *Automatic Modulation Classification: Principles, Algorithms and Applications*. Hoboken, NJ, USA: John Wiley & Sons, 2015.
- [7] S. Majhi, R. Gupta, W. Xiang, and S. Glisic, "Hierarchical hypothesis and feature-based blind modulation classification for linearly modulated signals," *IEEE Transactions on Vehicular Technology*, vol. 66, no. 12, pp. 11057-11069, Dec. 2017.
- [8] R. Gupta, S. Majhi, and O. A. Dobre, "Design and implementation of a tree-based blind modulation classification algorithm for multiple-antenna systems," *IEEE Transactions on Instrumentation and Measurement*, vol. 68, no. 8, pp. 3020-3031, Aug. 2018.
- [9] S. Peng, S. Sun, and Y.-D. Yao, "A survey of modulation classification using deep learning: Signal representation and data preprocessing," *IEEE Transactions on Neural Networks and Learning Systems*, vol. 33, no. 12, pp. 7020-7038, Dec. 2021.
- [10] R. Zhou, F. Liu, and C. W. Gravelle, "Deep learning for modulation recognition: A survey with a demonstration," *IEEE Access*, vol. 8, pp. 67366-67376, 2020.
- [11] S. Benedetto and P. Poggiolini, "Theory of polarization shift keying modulation," *IEEE Transactions on Communications*, vol. 40, no. 4, pp. 708-721, Apr. 2002.



شکل ۷- ماتریس درهم‌ریختگی حاصل از شبکه QNN

۵- نتیجه گیری

در این پژوهش، چارچوبی برای آشکارسازی کور و تشخیص حضور مدولاسیون POLSK در محیط‌های شلوغ مخابراتی شامل تداخلات ناشی از مدولاسیون‌های PSK، QAM و نویز AWGN ارائه گردید. دستاورد و تمرکز اصلی این مطالعه، ارزیابی توانمندی بازنمایی هندسی و چهاربعدی بردارهای استوکس در ترکیب با معماری‌های یادگیری عمیق بود. بدین منظور، شبکه عصبی کوانترنیونی (QNN) به دلیل تطابق با ساختار جبری داده‌ها پیشنهاد شد و عملکرد آن با شبکه پرسپترون چندلایه (MLP) به عنوان مدل پایه، از منظر دقت طبقه‌بندی و ماتریس درهم‌ریختگی در بازه‌های مختلف RSNR مورد مقایسه قرار گرفت. بر اساس نتایج شبیه‌سازی‌ها بر روی پایگاه داده ترکیبی، شبکه MLP علی‌رغم توانایی در یادگیری مرزهای تصمیم غیرخطی در SNRهای بالا، در شرایط نویزی شدید و در مواجهه با داده‌های چند بعدی با افت عملکرد مواجه شد. این امر نشان‌دهنده چالش‌های معماری‌های استاندارد در مدل‌سازی همبستگی‌های درون مؤلفه‌ای سیگنال‌های قطبیده است. در مقابل، شبکه QNN نشان داد که ماهیت جبری کوانترنیونی و قابلیت ذاتی آن در پردازش هم‌زمان مؤلفه‌های چندبعدی بردار استوکس، می‌تواند به بهبود دقت آشکارسازی و افزایش تفکیک‌پذیری کلاس POLSK کمک کند. این معماری با بهره‌گیری کارآمدتر از پارامترها، انطباق ساختاری بهتری با ماهیت سیگنال‌های قطبیده داشته و پایداری مناسب‌تری نسبت به تغییرات SNR از خود نشان داد. با وجود نتایج امیدوارکننده، این مطالعه با محدودیت‌هایی نیز همراه است. در مدل‌سازی‌های فعلی، فرض بر شرایط نسبتاً ایده‌آل بوده و اثرات مخرب سخت‌افزاری و ناپایداری‌های پیچیده کانال انتشار به طور کامل در تولید داده‌ها لحاظ نشده‌اند؛ موضوعی که در

¹- Cross-modulation attenuation

- [12] H. B. Goldman, "Considerations in AJ System Development, Operation and Definitions," in *International Telemetry Conference Proceedings*, Nov. 1978.
- [13] P. H. Wu, "Secure Communications System Through Concurrent AJ and LPD Evaluation," *Wireless Personal Communications*, vol. 48, no. 2, pp. 209–223, Apr. 2009.
- [14] L. Arend, R. Sperber, M. Marso, and J. Krause, "Implementing polarization shift keying over satellite–system design and measurement results," *International Journal of Satellite Communications and Networking*, vol. 34, no. 2, pp. 211–229, Mar./Apr. 2016.
- [15] S. Benedetto and P. Poggiolini, "Theory of polarization shift keying modulation," *IEEE Transactions on Communications*, vol. 40, no. 4, pp. 708–721, Apr. 2002.
- [16] J. G. Proakis, *Digital Communications*, 5th ed. Boston, MA, USA: McGraw-Hill, 2008.
- [17] Y. R. Shen, *The Principles of Nonlinear Optics*. New York, NY, USA: Wiley-Interscience, 1984.
- [18] P. Leopardi, "Distributing points on the sphere," Ph.D. dissertation, Univ. New South Wales, Sydney, NSW, Australia, 2007.
- [19] C. Huang, Z. Chen, R. Liu, and S. Zhang, "Adaptive dual-polarization filtering method for countering active jamming," *International Journal of Antennas and Propagation*, vol. 2020, Art. no. 4961402, pp. 1–9, 2020.
- [20] Q. Zheng, X. Tian, and L. Yu, "Recent advances in automatic modulation classification technology: Methods, results, and prospects," *International Journal of Intelligent Systems*, vol. 2025, pp. 1–28, Feb. 2025.
- [21] A. Shrestha and A. Mahmood, "Review of deep learning algorithms and architectures," *IEEE Access*, vol. 12, pp. 53064–53089, 2024.
- [22] C. M. Bishop, *Pattern Recognition and Machine Learning*. New York, NY, USA: Springer, 2006.
- [23] X. Chen, Q. Song, Z. Li, Z. Zhao, and Y. Liu, "Stability analysis of continuous-time and discrete-time quaternion-valued neural networks with linear threshold neurons," *IEEE Trans. Neural Netw. Learn. Syst.*, vol. 29, no. 7, pp. 2769–2781, Jul. 2018.
- [24] T. Parcollet, M. Morchid, and G. Linarès, "Quaternion convolutional neural networks for heterogeneous image processing," in *Proc. IEEE Int. Conf. Acoust., Speech Signal Process. (ICASSP)*, May 2019, pp. 8514–8518.
- [25] N. Matsui, T. Isokawa, H. Kusamichi, F. Peper, and H. Nishimura, "Quaternion neural network with geometrical operators," *J. Intell. Fuzzy Syst.*, vol. 15, nos. 3–4, pp. 149–164, 2004.
- [26] R. C. Lyndon, R. C. Lyndon, A. Boidin, and A. Fromageot, *Groups Geometry*, vol. 101. Cambridge, U.K.: Cambridge Univ. Press, 1985.
- [27] F. Zhang, "Quaternions and matrices of quaternions," *Linear Algebra and Its Applications*, vol. 251, pp. 21–57, Jan. 1997.
- [28] H. Chen, R. Natsuaki, and A. Hirose, "Robust symbol detection based on quaternion neural networks in wireless polarization-shift-keying communications," *IEEE Transactions on Neural Networks and Learning Systems*, vol. 35, no. 11, pp. 16064–16075, Nov. 2023.
- [29] R. Zeng, J. Wu, Z. Shao, L. Senhadji, and H. Shu, "Quaternion softmax classifier," *Electron. Lett.*, vol. 50, no. 25, pp. 1929–1931, Dec. 2014.