



Intelligent Recognition and Classification of Interferers in DVB-S2 Satellite Signals

Mohyeddin Karamali¹, Hossein Khaleghi Bizaki^{2*}, Hossein Bahramgiri³

¹ M.Sc. Student, Malek-Ashtar University of Technology, Tehran, Iran, Email Address: hkaramali@gmail.com

²Correspondence: Professor, Malek-Ashtar University of Technology, Tehran, Iran, Email Address: bizaki@yahoo.com

³Assistant Professor, Malek-Ashtar University of Technology, Tehran, Iran. Email Address: h_bahramgiri@yahoo.com

ARTICLE INFO

Article history:

Article Type: Research paper

Received: 25 September 2025

Received in revised form: 8 November 2025

Accepted: 13 July 2026

Available online: 21 August 2026

Keywords:

Satellite Communications

DVB-S2 Standard

Pattern Recognition

Radio Frequency Interference (RFI)

Statistical and Spectral Features

Machine Learning

ABSTRACT

With the rapid growth of satellite communications in various fields, particularly in military applications, and the high importance of communication security, the use of artificial intelligence-based methods to prevent the interception of communication signals and mitigate interference has become increasingly important. This paper proposes a multilayer perceptron (MLP) neural network-based method for the detection and identification of interference in the DVB-S2 satellite communication standard. The dataset used in this study includes modulated signals (QPSK and APSK with orders 8, 16, and 32) and various types of radio-frequency interference, including chirp interference (CI), continuous-wave interference (CWI), and multiple continuous-wave interference (MCWI). In the proposed method, a large number of statistical and spectral features are initially extracted from the signals. Then, the ten best features are selected using the Mahalanobis distance, Euclidean distance, chi-square, and variance-to-mean ratio (VdM) criteria to optimize the model performance. Numerical results demonstrate the improved accuracy of the VdM criterion in identifying interference, particularly under low signal-to-noise ratio (SNR) conditions. At SNR = 0 dB, the proposed method provides an accuracy improvement of up to 6% compared with previous methods, while at SNR = 9 dB, the accuracy of the proposed method reaches 99.74%.

Cite this article: M. Karamali, H. Khaleghi Bizaki, and H. Bahramgiri, "Intelligent Recognition and Classification of Interferers in DVB-S2 Satellite Signals," Journal of Passive Defence, vol. 17, no. 2, pp. 59-74, 2026.

DOI: <https://doi.org/10.47176/pd.2026.1579>



OPEN ACCESS

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

Publisher: Imam Hossein University.

Introduction

With the rapid development of radio communications and the increasing demand for reliable and sustainable connectivity, satellite communication systems have become an important component of modern communication infrastructures, particularly in military applications. In this context, the Digital Video Broadcasting–Satellite Second Generation (DVB-S2) standard is considered one of the widely used standards due to its high bandwidth efficiency, support for advanced modulation schemes, and capability to transmit large volumes of data. However, radio-frequency interference (RFI), particularly interferences such as Chirp Interference (CI), Continuous Wave Interference (CWI), and Multiple Continuous Wave Interference (MCWI), represents a major challenge threatening the performance of these systems. Conventional interference detection methods, including Cyclostationary Feature Detection (CFD), time–frequency analysis, energy detection, and matched filtering, face limitations such as high computational complexity and dependence on prior knowledge of the signal. Therefore, this study aims to develop an artificial intelligence-based approach by extracting statistical and spectral features and selecting the ten most informative features using the Mahalanobis, Euclidean, Chi-square, and Variance-to-Mean (VdM) criteria. The performance of MLP, SVM, and KNN classifiers is then investigated for interference identification in DVB-S2 systems.

Research Objectives and Questions

This research seeks to answer the following main question:

How can statistical and spectral features be effectively selected and combined with machine learning classifiers to improve the detection and identification of interference in DVB-S2 satellite communication systems, particularly under low-SNR conditions?

The objectives of the research are:

- To extract and analyze 33 statistical and spectral features from DVB-S2 signals containing different types of interference.
- To select and compare the 10 best features using the Mahalanobis, Euclidean, Chi-square, and VdM criteria.
- To improve interference detection performance compared with existing methods, particularly under low-SNR conditions.
- To evaluate and compare the performance of SVM, KNN, and MLP classifiers using the selected features and determine the most effective method for interference detection in DVB-S2 systems.

Methodology

This study aims to detect and identify radio-frequency interference in DVB-S2 systems using a quantitative and simulation-based approach. The proposed method is implemented in four main stages:

Signal and Interference Modeling: The received signal is modeled as the sum of the desired DVB-S2 signal, interference, and additive white Gaussian noise. In this study, QPSK- and APSK-modulated signals with orders 8, 16, and 32 are considered, and three types of interference, including CWI, MCWI, and CI, are investigated. Consequently, four classes, including the Signal of Interest (SOI), SOI with CI, SOI with CWI, and SOI with MCWI, are considered for detection and classification.

Feature Extraction: To extract discriminative information from the received signals, a set of 33 statistical and spectral features is extracted. The objective of this stage is to construct a comprehensive feature set for evaluating the discriminative capability of different signals and interference types.

Feature Selection: To reduce the feature dimensionality and improve classification efficiency, the discriminative capability of each of the 33 features is evaluated using four criteria: Euclidean distance, Mahalanobis distance, Chi-square criterion, and VdM ratio. In this stage, each criterion independently ranks the available features and selects the 10 best features from the 33 initial features. Accordingly, the feature sets selected by the different criteria are compared, and the effect of each feature selection method on interference detection performance is evaluated.

Classification and Performance Evaluation: In the final stage, three classifiers, namely SVM, KNN, and MLP, are employed to investigate the effect of the selected features on interference detection. The performance of these classifiers is evaluated using the feature sets selected by each of the four criteria and is compared with previous methods. Furthermore, the performance of the proposed method is investigated at different SNR levels, particularly under low-SNR conditions.

The main objective of employing the four feature selection criteria in this study is to investigate which 10 features each criterion selects from the 33 initial features as the most discriminative features and to determine the extent to which this selection can improve classifier performance. Finally, by comparing the results obtained using different criteria and the three classifiers, namely SVM, KNN, and MLP, the most effective combination for interference detection and identification in DVB-S2 systems is determined. In addition, the results of the proposed method are compared with existing methods to determine the improvement in detection accuracy, particularly under noisy and low-SNR conditions.

Discussion

The results of this study demonstrate that selecting features with high statistical discriminative power plays an important role in improving the identification and classification of radio-frequency interference, particularly under low-SNR conditions. Among the evaluated criteria, the VdM-based feature selection method achieved the best performance in distinguishing the SOI, CI, CWI, and MCWI classes. The results indicate that selecting different feature subsets according to the noise level can significantly improve classification accuracy. In particular, the proposed method achieved a notable improvement in accuracy at SNR = 0 dB compared with the method presented in [5] and reached an accuracy of 99.74% at high SNR levels. Furthermore, the use of features extracted under low-SNR conditions for SNR values below 3 dB and features extracted under high-SNR conditions for higher SNR values highlights the importance of adapting the feature selection process to the prevailing noise conditions. In contrast, the Euclidean, Mahalanobis, and chi-square criteria generally resulted in lower classification performance. However, by accounting for the correlations among features, the Mahalanobis criterion achieved better performance than the other two methods.

The results further demonstrate that reducing the number of features from 33 to 10 does not cause a significant degradation in classification performance while substantially reducing the computational complexity of the model. The proposed MLP architecture, with only 454 parameters and an average inference time of approximately 27 μ s per sample, provides an appropriate balance between classification accuracy and computational complexity. Therefore, it is well suited for real-time applications and potential implementation on FPGA and DSP platforms. Moreover, the comparison of the SVM, KNN, and MLP classifiers indicates that classifier performance is strongly dependent on the noise level. Under severe noise conditions, SVM achieves better performance, whereas as the SNR increases, the performance of MLP approaches that of SVM and consistently outperforms KNN. Overall, the results indicate that combining adaptive VdM-based feature selection with a neural classifier can provide an effective and computationally efficient solution for radio-frequency interference classification in DVB-S2 communication systems.

Conclusions

In this paper, an efficient method for detecting and classifying radio-frequency interferences in the DVB-S2 standard was presented using statistical and spectral features and an MLP neural network. The Euclidean, Mahalanobis, Chi-square, and VdM metrics were compared, and the VdM metric achieved higher detection accuracy at different SNRs. The results showed a 6% accuracy improvement at SNR = 0 dB using features extracted by VdM at low SNR and a 3% improvement at the same SNR using features extracted at high SNR, while achieving 99.74% accuracy at SNR = 9 dB. These results confirm the effectiveness of the proposed method under different noise conditions. Moreover, among the classifiers using VdM-based features, SVM performed better under severe noise, whereas at higher SNRs, MLP and SVM showed similar performance and outperformed KNN.

تشخیص و دسته‌بندی هوشمند اخلال‌گرها در سیگنال‌های ماهواره‌ای DVB-S2

محیی‌الدین کرمعلی^۱، حسین خالقی بیزکی^{۲*}، حسین بهرامگیری^۳

^۱ دانشجوی کارشناسی ارشد مخابرات سیستم، مجتمع دانشگاهی برق و کامپیوتر، دانشگاه صنعتی مالکاشتر، تهران، ایران. hkaramali@gmail.com

^۲ استاد، گروه مخابرات سیستم، مجتمع دانشگاهی برق و کامپیوتر، دانشگاه صنعتی مالکاشتر، تهران، ایران (نویسنده مسئول). bizaki@yahoo.com

^۳ استادیار، گروه مخابرات سیستم، مجتمع دانشگاهی برق و کامپیوتر، دانشگاه صنعتی مالکاشتر، تهران، ایران. h_bahramgiri@yahoo.com

چکیده

با توجه به رشد روزافزون مخابرات ماهواره‌ای در حوزه‌های مختلف به‌ویژه کاربردهای نظامی و اهمیت بالای امنیت ارتباطات، استفاده از روش‌های مبتنی بر هوش مصنوعی برای جلوگیری از شنود سیگنال‌های مخابراتی و مقابله با تداخل اهمیت ویژه‌ای پیدا کرده است. این مقاله یک روش مبتنی بر شبکه عصبی پرسپترون چندلایه (MLP) را برای تشخیص و شناسایی تداخل در استاندارد مخابرات ماهواره‌ای DVB-S2 پیشنهاد می‌دهد. مجموعه داده‌های استفاده شده در این تحقیق شامل: سیگنال‌های مدوله شده (QPSK و APSK با مراتب ۸، ۱۶ و ۳۲) و انواع تداخل‌های رادیویی نظیر تداخل چرپ (CI)، تداخل موج پیوسته (CWI) و تداخل موج پیوسته چندگانه (MCWI) می‌باشند. در روش پیشنهادی، ابتدا تعداد زیادی ویژگی‌های آماری و طیفی سیگنال‌ها استخراج می‌شوند. سپس، ده ویژگی برتر با استفاده از معیارهای فاصله مالهالانوبیس، فاصله اقلیدوسی، کای-دو و نسبت واریانس به میانگین (VdM) برای بهینه‌سازی عملکرد مدل انتخاب می‌گردند. نتایج عددی نشان‌دهنده بهبود دقت معیار VdM در شناسایی تداخل‌ها، به‌ویژه در شرایطی با نسبت توان سیگنال به نویز (SNR) پایین می‌باشد. این روش در نسبت SNR=0 dB، بهبود دقتی تا ۶ درصد نسبت به روش‌های پیشین فراهم می‌کند و در SNR=9 dB، دقت روش پیشنهادی به ۹۹/۷۴٪ می‌رسد.

مشخصات مقاله

تاریخچه مقاله:

نوع مقاله: علمی پژوهشی

دریافت: ۱۴۰۴/۰۷/۰۳

بازنگری: ۱۴۰۴/۰۸/۱۷

پذیرش: ۱۴۰۵/۰۴/۲۲

ارائه آنلاین: ۱۴۰۵/۰۵/۳۰

کلیدواژه‌ها:

مخابرات ماهواره‌ای

استاندارد ماهواره‌ای DVBS2

شناسایی الگو

شناسایی تداخل فرکانس رادیویی

(RFI)

ویژگی‌های آماری و طیفی

یادگیری ماشین

استناد: کرمعلی، محیی‌الدین، خالقی بیزکی، حسین، بهرامگیری، حسین، "تشخیص و دسته‌بندی هوشمند اخلال‌گرها در سیگنال‌های ماهواره‌ای

DVB-S2"، نشریه پدافند غیرعامل، دوره ۱۷، شماره ۲، صفحات ۷۴-۵۹، ۱۴۰۵. DOI: <https://doi.org/10.47176/pd.2026.1579>

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



ناشر: دانشگاه جامع امام حسین (ع).



۱- مقدمه

با پیشرفت روزافزون ارتباطات رادیویی و افزایش تقاضا برای ارتباطات پایدار و قابل اعتماد، سامانه‌های مخابرات ماهواره‌ای به یکی از ارکان کلیدی زیرساخت‌های ارتباطی مدرن و به‌ویژه در حوزه نظامی تبدیل شده‌اند. این سامانه‌ها با ارائه خدماتی نظیر پخش تصاویر، دسترسی به اینترنت در مناطق دورافتاده و انتقال داده‌ها در مقیاس جهانی، نقشی مهم ایفا می‌کنند. توانایی پوشش‌دهی گسترده جغرافیایی، انعطاف‌پذیری در برابر محدودیت‌های زمینی و عملکرد مؤثر در شرایط بحرانی یا مناطق فاقد زیرساخت‌های کابلی، این فناوری را به ابزاری حیاتی تبدیل کرده است [۱].

در این راستا، استاندارد پخش ویدئوی دیجیتال - ماهواره - نسل دوم^۱ (DVB-S2) به دلیل بهره‌وری بالاتر در استفاده از پهنای باند، پشتیبانی از مدولاسیون‌های پیشرفته مانند کلیدزنی فاز چهارگانه (QPSK) و کلیدزنی دامنه و فاز (APSK ۸/۱۶/۳۲) و کاهش ضریب فرود^۲ نسبت به نسل نخست (DVB-S)، به یکی از پرکاربردترین استانداردها در این حوزه تبدیل شده است [۲]. این استاندارد، امکان انتقال حجم بالای داده‌ها، از جمله ویدئوهای باکیفیت بالا و خدمات چندرسانه‌ای را فراهم کرده و در طیف وسیعی از کاربردهای تجاری به کار گرفته شده است [۳].

با این حال، یکی از مهم‌ترین چالش‌هایی که عملکرد این سامانه‌ها را تهدید می‌کند، تداخل فرکانس رادیویی^۳ (RFI) است. این تداخل‌ها می‌توانند کیفیت سیگنال را کاهش، نرخ خطای بیت را افزایش داده و حتی منجر به قطع کامل ارتباط شوند. براساس ماهیت ایجاد، تداخل‌ها به دو دسته، غیرعمدی و عمدی تقسیم می‌شوند. تداخل‌های غیرعمدی معمولاً ناشی از اثرات محیطی، نویز حرارتی، تداخل میان‌کانالی و خطاهای انسانی هستند. در مقابل، تداخل‌های عمدی که با نام جَمینگ نیز شناخته می‌شوند، به‌صورت عمدانه با هدف ایجاد اختلال در ارتباطات رادیویی اعمال می‌شوند. در این نوع تداخل، یک سیگنال با توان بالا به‌گونه‌ای ارسال می‌شود که دریافت و آشکارسازی سیگنال اصلی را با مشکل مواجه کند [۴].

در استاندارد DVB-S2 تداخل‌های عمدی متعددی وجود

دارد که بر کیفیت سیگنال و عملکرد گیرنده تأثیر منفی می‌گذارند. از جمله این تداخل‌ها می‌توان به تداخل چِرپ^۴ (CI) ناشی از تغییرات سریع فرکانس، تداخل موج پیوسته^۵ (CWI) و تداخل موج پیوسته چندگانه^۶ (MCWI) اشاره کرد که با ایجاد اعوجاج در طیف فرکانسی و کاهش SNR، منجر به افت کیفیت سیگنال، افزایش نرخ خطای بیت و کاهش ظرفیت کانال می‌شوند [۵]. با توجه به این چالش‌ها، توسعه روش‌های مؤثر برای شناسایی و مقابله با این نوع تداخل، امری ضروری محسوب می‌شود.

روش‌های تشخیص تداخل عمدتاً در دو دسته کلی قرار می‌گیرند: روش‌های مبتنی بر احتمال^۷ (LB) و روش‌های مبتنی بر ویژگی^۸ (FB). روش‌های مبتنی بر احتمال به دلیل نیاز به مدل‌سازی توزیع سیگنال و نویز، از پیچیدگی محاسباتی بالاتری برخوردار هستند [۶]. در مقابل، روش‌های مبتنی بر ویژگی، با استخراج ویژگی‌های کلیدی از سیگنال و استفاده از تحلیل‌های آماری یا الگوریتم‌های مبتنی بر هوش مصنوعی، امکان شناسایی تداخل را فراهم می‌کنند.

در میان روش‌های متداول مبتنی بر ویژگی برپایه سنجش طیف، روش‌هایی مانند آشکارسازی مبتنی بر ویژگی ایستادن چرخشی^۹ (CFD) [۷-۸]، تحلیل زمان-فرکانس [۹-۱۰]، آشکارساز انرژی^{۱۰} (ED) [۱۱-۱۲] و فیلتر منطبق^{۱۱} [۱۱-۱۳] مورد استفاده قرار گرفته‌اند. با این حال، هر یک از این روش‌ها محدودیت‌هایی دارند. برای مثال، تبدیل فوری زمان کوتاه^{۱۲} (STFT) در تحلیل سیگنال‌های غیرایستادن عملکرد ضعیفی دارد [۱۴]. آشکارساز انرژی در حضور تداخلات درون‌بندی کارایی محدودی دارد. از سوی دیگر، در روش CFD اگرچه در نسبت سیگنال به نویز پایین عملکرد مناسبی داشته، اما پیچیدگی محاسباتی بالایی دارند [۱۵]. یکی از کارهای صورت گرفته برای کاهش این پیچیدگی، استفاده از مجموع دامنه چگالی طیف چرخشی در بعد فرکانس است تا نمایش تنها در بعد فرکانس چرخشی محاسبه شود [۱۶]. از سوی دیگر، آشکارسازهای مبتنی

^۴ Chirp Interference

^۵ Continuous Wave Interference

^۶ Multiple Continuous Wave Interference

^۷ Likelihood-Based

^۸ Feature-Based

^۹ Cyclo-Stationary Feature Detection

^{۱۰} Energy Detection

^{۱۱} Matched Filter

^{۱۲} short-time Fourier transform

^۱ Digital Video Broadcasting — Satellite — Second

^۲ Roll-off factor

^۳ Radio Frequency Interference

استخراج ویژگی‌های کلیدی، عملکرد سامانه‌ها را بهبود داده‌اند که در ادامه به بررسی برخی از آن‌ها پرداخته می‌شود.

در حوزه مخابرات ماهواره‌ای، یک روش کارآمد مبتنی بر طبقه‌بندی سلسله‌مراتبی با استفاده از شبکه عصبی MLP، الگوریتم ژنتیک، تحلیل مؤلفه‌های اصلی^۳ (PCA) و ویژگی‌های آماری برای شناسایی و طبقه‌بندی تداخل فرکانس رادیویی ارائه شده است [۵]. در [۱۹] برای شناسایی و طبقه‌بندی تداخل رویکردی مبتنی بر الگوریتم یادگیری متریک فاصله متغیر استاندارد^۴ (SVD) معرفی شده است، سپس با استفاده از تقسیم‌بندی تطبیقی حوزه طیفی و انتخاب بخش‌های متمایز با الگوریتم شناسایی نقاط خارج از محدوده انجام شده و عملکرد الگوریتم SVD با الگوریتم‌های درخت تصمیم^۵ (DT) و K-نزدیک‌ترین همسایه^۶ (KNN) مقایسه شده است.

در حوزه شناسایی مدولاسیون در استاندارد ماهواره‌ای DVBS2، یک روش مبتنی بر ماشین بردار پشتیبان دو به دو پیشنهاد شده است [۲۰]. در این رویکرد، کومولانت‌های مرتبه چهارم و ششم از سیگنال دریافتی به‌عنوان ویژگی استخراج شده و برای طبقه‌بندی استفاده می‌شوند. طبقه‌بندی با استفاده از انتخاب بر اساس بیشترین تصمیم میان SVMهای دودویی انجام می‌شود. در [۲۱] با بهره‌گیری از ویژگی‌های آماری مرتبه بالا و یک چارچوب کارآمد انتخاب ویژگی، دقت طبقه‌بندی سیگنال‌های M-PSK و M-QAM به طور قابل توجهی بهبود یافته است.

در حوزه شبکه‌های بی‌سیم، یک رویکرد مبتنی بر شبکه عصبی MLP برای شناسایی تداخل در GPS ارائه شده است و الگوریتم‌های مختلف یادگیری ماشین شامل مدل‌های عصبی، مدل‌های درختی، مدل‌های رگرسیونی، طبقه‌بندهای بی‌زی، مدل‌های مبتنی بر فاصله و طبقه‌بندهای تصادفی ارزیابی شده‌اند. در نهایت، MLP بهترین عملکرد را نشان داده است [۲۲]. در [۲۳] روشی مبتنی بر جنگل تصادفی^۷ برای شناسایی جیمینگ صورت گرفته در شبکه‌های بی‌سیم ارائه شده است. الگوریتم‌های مختلف یادگیری ماشین، از جمله جنگل تصادفی، ماشین بردار پشتیبان^۸ (SVM) با کرنل‌های متنوع و شبکه عصبی، مورد

بر فیلتر منطبق به فرآیند دم‌دولاسیون سیگنال کاربر اولیه وابسته هستند که این امر به نوبه خود منجر به طراحی یک گیرنده اختصاصی برای هر مأموریت به‌طور جداگانه می‌شود [۱۷]. در حالی که در سناریوهای تشخیص کور، که هیچ دانش قبلی از سیگنال وجود ندارد، ابزارهای یادگیری ماشین و یادگیری عمیق با استخراج الگوهای پنهان در داده، نقش مهمی در شناسایی مؤثر سیگنال‌ها ایفا می‌کنند [۱۸].

در سال‌های اخیر، روش‌های مبتنی بر هوش مصنوعی به دلیل توانایی در استخراج ویژگی‌های مناسب و بهبود دقت تشخیص، مورد توجه قرار گرفته‌اند. در مقاله حاضر، یک روش نوین مبتنی بر شبکه عصبی پرسپترون چندلایه^۱ (MLP) برای شناسایی تداخل‌ها در DVB-S2 پیشنهاد شده است و در نهایت به بررسی سه طبقه‌بند MLP، SVM و KNN پرداخته می‌شود. در این روش، ابتدا مجموعه‌ای از ویژگی‌های آماری و طیفی از سیگنال‌ها استخراج می‌گردد. سپس، با استفاده از چهار معیار (ماهالانویس، اقلیدسی، کای-دو و نسبت واریانس به میانگین^۲ (VdM)) ده ویژگی برتر به‌منظور بهینه‌سازی عملکرد مدل انتخاب می‌شوند. نتایج تجربی نشان می‌دهند که معیار VdM در شرایط SNR=9 dB به دقت ۹۹/۷۴٪ دست یافته و در SNR=0 dB نیز بهبود دقتی معادل ۶ درصد نسبت به روش‌های پیشین ارائه داده است. این نتایج، کارایی بالای روش پیشنهادی را در شرایط نویزی تأیید می‌کند که به نوبه خود می‌تواند به افزایش امنیت و پایداری ارتباطات در استانداردهای DVB-S2 کمک کند. ساختار مقاله به صورت زیر تنظیم شده است: در بخش ۲ پژوهش‌های مرتبط با شناسایی و طبقه‌بندی تداخل‌های فرکانس رادیویی مرور می‌شوند. بخش ۳ و ۴ به ارائه مدل سیستم و روش پیشنهادی می‌پردازد، در بخش ۵ نتایج آزمایش‌ها و تحلیل‌ها ارائه شده و در نهایت در بخش ۶ نتیجه‌گیری تحقیق بیان می‌شود.

۲- مرور مقالات

در یک دهه گذشته، با پیچیده‌تر شدن تداخل‌های فرکانس رادیویی در سامانه‌های ارتباطی، توجه زیادی به روش‌های مبتنی بر هوش مصنوعی برای شناسایی و طبقه‌بندی تداخل‌ها شده است. این روش‌ها به دلیل توانایی در تحلیل داده‌های پیچیده و

^۳ Principal Component Analysis

^۴ Standardized Variable Distances

^۵ Decision Tree

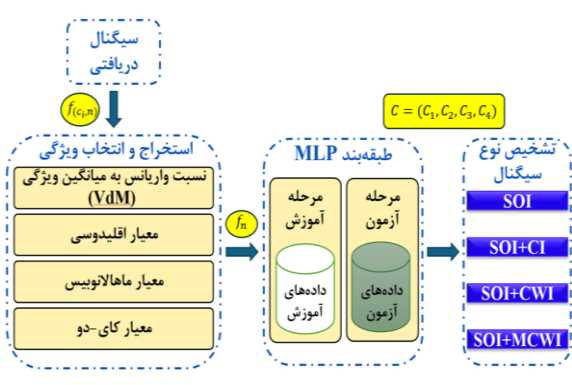
^۶ K-Nearest Neighbors

^۷ Random Forest

^۸ Support Vector Machine

^۱ Multilayer perceptron

^۲ Variance divided by Mean



شکل (۱): روش پیشنهادی برای تشخیص و طبقه‌بندی تداخل فرکانس رادیویی

مطابق شکل (۱)، سیگنال دریافتی $y(t)$ به صورت زیر در نظر گرفته می‌شود:

$$y(t) = x(t) + j(t) + n(t) \quad (۱)$$

که در آن، $x(t)$ سیگنال ارسالی مطابق با استاندارد DVB-S2، $n(t)$ بیانگر نویز سفید جمع شونده با توزیع نرمال با میانگین صفر و واریانس σ^2 ، یعنی $n(t) \sim N(0, \sigma^2)$ ، در نظر گرفته شده است. همچنین، $j(t)$ نمایانگر تداخلات درون‌بندی بوده که به صورت رابطه (۲) مدل می‌شود و شامل سه تداخل زیر می‌باشد:

الف- تداخل موج پیوسته (CWI): یک موج سینوسی تک فرکانسی با فرکانس f_{CW} است.

ب- تداخل موج پیوسته چندگانه (MCWI): ترکیبی از چند موج سینوسی با فرکانس‌های متفاوت است که در این‌جا به‌طور خاص شامل ترکیب دو موج سینوسی با فرکانس‌های متفاوت f_{CW1} و f_{CW2} است.

ج- تداخل چرپ (CI): یک سیگنال با فرکانس لحظه‌ای متغیر است که شامل نرخ تغییرات $k = \frac{f_1 - f_0}{T}$ است که از فرکانس اولیه f_0 تا f_1 با دوره جاروب T افزایش می‌یابد.

بنابراین، جمر $j(t)$ را می‌توان به صورت زیر مدل نمود:

$$j(t) = \begin{cases} \exp(j2\pi f_{CW}t) & ; CWI \\ \exp(j2\pi f_{CW1}t) + \exp(j2\pi f_{CW2}t) & ; MCWI \\ \exp(2\pi(\frac{K}{2}t^2 + f_0t)) & ; CI \end{cases} \quad (۲)$$

مطابق شکل (۱)، به منظور تشخیص و طبقه‌بندی تداخل از سیگنال دریافتی $y(t)$ ، مراحل زیر باید انجام گیرد:

الف- استخراج ویژگی

در ابتدا ویژگی آماری و طیفی پرکاربرد با توجه به مراجع قاضون و خالقی [۲۷]، اوجان و همکاران [۵]، وانگ و همکاران [۲۸] و

ارزیابی قرار گرفته‌اند و نتایج نشان می‌دهند که این روش عملکرد مطلوبی در تشخیص حملات جمینگ دارد.

در کاربردهای دیگر مانند پردازش تصویر، [۲۴] یک الگوی پیشرفته مبتنی بر مدل Stacking برای شناسایی تداخل موجود در تصاویر ارائه شده است. این مدل از سه الگوریتم یادگیری ماشین شامل KNN، جنگل تصادفی و LGB^1 استفاده کرده و با استفاده از LGB به عنوان روش فرایادگیری^۲ برای ترکیب نتایج به کار گرفته شده است. علاوه بر این، از الگوهای باینری محلی^۳ (LBP) و هیسستوگرام گرادیان‌های جهت‌دار^۴ (HOG) برای استخراج ویژگی و بهبود عملکرد مدل استفاده شده است.

در حوزه تشخیص حملات سایبری به‌منظور بررسی سامانه‌های تشخیص نفوذ (IDS) در شبکه‌های کامپیوتری، مدلی مبتنی بر ترکیب سلسله‌مراتبی شبکه‌های عصبی MLP با استفاده از مجموعه داده‌های KDD99 ارائه شده است [۲۵]. در [۲۶] از شبکه عصبی MLP برای شناسایی نفوذ و حملات DoS در ترافیک شبکه استفاده شده است. در این رویکرد، از روش انتخاب ویژگی مبتنی بر همبستگی^۵ (CFS) با ضریب همبستگی پیرسون^۶ (PCC) با آستانه بهینه ۰/۴ برای انتخاب ویژگی‌ها بهره گرفته شده است.

به‌طور کلی، پژوهش‌های پیشین نشان می‌دهند که روش‌های مبتنی بر هوش مصنوعی به‌ویژه شبکه‌های عصبی (MLP)، در شناسایی تداخل عملکرد مناسبی دارند. با این حال، در حوزه مخابرات ماهواره‌ای، بهینه‌سازی انتخاب ویژگی‌ها به‌ویژه در شرایط نویزی شدید، کمتر مورد توجه قرار گرفته است. در پاسخ به این شکاف، مقاله حاضر یک چارچوب نوین مبتنی بر MLP ارائه می‌دهد که با بهره‌گیری از معیارهای چهارگانه برای انتخاب ویژگی‌های بهینه از شماری از ویژگی‌ها، موجب بهبود چشمگیر دقت شناسایی تداخل در استاندارد مخابراتی DVB-S2 می‌شود.

۳- مدل سیستم

ساختار کلی سامانه پیشنهادی به‌منظور شناسایی تداخل فرکانس رادیویی سامانه DVB-S2 در شکل (۱) نشان داده شده است.

¹ Light GBM

² Meta Learning

³ Local Binary Patterns

⁴ Histogram of Oriented Gradients

⁵ Correlation-based Feature Selection

⁶ Pearson Correlation Coefficient

f_{15}	$f_{(c_i,15)} = M_{42} - 2M_{21} - M_{21} ^2$
f_{16}	$f_{(c_i,16)} = M_{60} - 15M_{20}M_{40} + 30M_{20}^3$
f_{17}	$f_{(c_i,17)} = M_{60} - 9 M_{20} $
f_{18}	$f_{(c_i,18)} = M_{63} + 18(M_{20}M_{21}M_{22}) + 12M_{21}^3 - 9(M_{21}M_{42}) - 3(M_{20}M_{43}) - 3(M_{22}M_{41})$
f_{19}	$f_{(c_i,19)} = M_{80} - 35(M_{40}^2) - 28(M_{60}M_{20}) + 420(M_{40}M_{20}^2) - 630(M_{20}^4)$
f_{20}	$f_{(c_i,20)} = \mu'_5 - 5\mu\mu'_4 + 10\mu^2\mu'_3 - 10\mu^3\mu'_2 + 4\mu^5$
f_{21}	$f_{(c_i,21)} = \mu'_6 - 6\mu\mu'_5 + 15\mu^2\mu'_4 - 20\mu^3\mu'_3 + 15\mu^4\mu'_2 - 5\mu^6$
f_{22}	$f_{(c_i,22)} = \mu'_7 - 7\mu\mu'_6 + 21\mu^2\mu'_5 - 35\mu^3\mu'_4 + 35\mu^4\mu'_3 - 21\mu^5\mu'_2 + 6\mu^7$
f_{23}	$f_{(c_i,23)} = \mu'_8 - 8\mu\mu'_7 + 28\mu^2\mu'_6 - 56\mu^3\mu'_5 + 70\mu^4\mu'_4 - 56\mu^5\mu'_3 + 28\mu^6\mu'_2 - 7\mu^8$
f_{24}	$f_{(c_i,24)} = \frac{ C_{20} }{ C_{21} }$
f_{25}	$f_{(c_i,25)} = \frac{ C_{40} }{ C_{21} ^2}$
f_{26}	$f_{(c_i,26)} = \frac{ C_{41} }{ C_{21} ^2}$
f_{27}	$f_{(c_i,27)} = \frac{ C_{42} }{ C_{21} ^2}$
f_{28}	$f_{(c_i,28)} = \frac{ C_{60} }{ C_{21} ^3}$
f_{29}	$f_{(c_i,29)} = \frac{ C_{63} }{ C_{21} ^3}$
f_{30}	$f_{(c_i,30)} = \frac{ C_{20} ^2}{ C_{41} }$
f_{31}	$f_{(c_i,31)} = 7 M_{40} + 7 M_{44} $
f_{32}	$f_{(c_i,32)} = -3 M_{40} M_{42} ^2 - 3 M_{44} M_{42} ^2 + 6 M_{40} M_{42} + 6 M_{44} M_{42} $
f_{33}	$f_{(c_i,33)} = M_{84} ^4 - 4 M_{84} ^3 M_{83} + 4 M_{84} ^3 M_{82} - 3 M_{84} ^3 M_{80} + 3 M_{84} ^2 M_{83} ^2$

همچنین میرعرب و سبحانی [۲۹] و برخی از ویژگی‌های تجربی از سیگنال $y(t)$ استخراج می‌گردد. مجموعه ویژگی‌های به‌دست‌آمده مطابق رابطه (۳) تعریف می‌شود:

$$F = \{f_{(c_i,n)} | i = 1, 2, \dots, I; n = 1, 2, \dots, N\} \quad (۳)$$

به طوری که $f_{(c_i,n)}$ بیانگر ویژگی n ام کلاس c_i می‌باشد. مجموعه ویژگی‌های فوق را می‌توان به صورت رابطه (۴) بیان نمود:

$$F = \begin{Bmatrix} f_{(c_1,1)}, f_{(c_1,2)}, \dots, f_{(c_1,N)} \\ f_{(c_2,1)}, f_{(c_2,2)}, \dots, f_{(c_2,N)} \\ f_{(c_3,1)}, f_{(c_3,2)}, \dots, f_{(c_3,N)} \\ \vdots \\ f_{(c_I,1)}, f_{(c_I,2)}, \dots, f_{(c_I,N)} \end{Bmatrix} \quad (۴)$$

روابط ریاضی توصیف‌کننده هر کدام از N ویژگی مورد استفاده در جدول (۱) بیان شده است.


جدول (۱): روابط ریاضی ویژگی‌ها

روابط	ویژگی‌ها
f_1	$f_{(c_i,1)} = \mathbb{E}[y] = \frac{1}{n} \sum_{j=1}^n y(j)$
f_2	$f_{(c_i,2)} = \sqrt{\frac{1}{n} \sum_{j=1}^n y(j) - \mathbb{E}[y] }$
f_3	$f_{(c_i,3)} = \frac{E(y - \mathbb{E}[y])^3}{\sigma^3}$
f_4	$kurtosis = \frac{E(y - \mathbb{E}[y])^4}{\sigma^4}$ $f_{(c_i,4)} = \frac{ kurtosis_I + kurtosis_Q }{2}$
f_5	$f_{(c_i,5)} = \frac{1}{n} \sum_{j=1}^n y(i) ^2$
$f_6, f_7, f_8, f_9, f_{10}$	توان متوسط ضرایب ویولت (تجزیه سیگنال با استفاده از ویولت (db10) تا چهار سطح و محاسبه توان متوسط تقریب سطح چهارم و جزئیات سطوح اول تا چهارم) $f_{(c_i,6)}, f_{(c_i,7)}, f_{(c_i,8)}, f_{(c_i,9)}, f_{(c_i,10)}$
f_{11}	$f_{(c_i,11)} = M_{20}$
f_{12}	$f_{(c_i,12)} = M_{40} - 3M_{20}^2$
f_{13}	$f_{(c_i,13)} = M_{40} - 2 M_{20} ^2$
f_{14}	$f_{(c_i,14)} = M_{41} - 3(M_{21}M_{20})$

دارند، مطابق با روش توصیف شده در ادامه، استخراج می‌شوند.

۴-۱- روش انتخاب ویژگی مبتنی بر معیارهای اقلیدوسی، مالهالانوبیس و کای دو

در روش انتخاب ویژگی مبتنی بر معیارهای اقلیدوسی، مالهالانوبیس و کای دو مطابق شکل (۲) عمل می‌شود.



شکل (۲): روش مبتنی بر معیار اقلیدوسی، مالهالانوبیس و کای دو مطابق شکل (۲)، در ابتدا برای ارزیابی میزان تمایز هر ویژگی، فاصله بین مقدار ویژگی n ام در زوج کلاس‌های مختلف محاسبه می‌گردد؛ تعداد این زوج‌ها برای C کلاس برابر با $\frac{C(C-1)}{2} = \binom{C}{2}$ است. فاصله بین ویژگی $f_{(c_i,n)}$ در کلاس c_i و ویژگی $f_{(c_j,n)}$ در کلاس c_j به صورت رابطه (۷) تعریف می‌شود:

$$d_s(n) = \text{dist}_{i \neq j} (f_{(c_i,n)}, f_{(c_j,n)}) \quad (7)$$

برای ارزیابی تفکیک‌پذیری هر ویژگی، مجموعه‌ای از معیارها که به صورت مجموعه‌ای شامل S مؤلفه می‌باشد مطابق رابطه (۸) تعریف می‌شود:

$$\text{dist} \in D = \{d_1(n), d_2(n), \dots, d_s(n), \dots, d_S(n)\} \quad (8)$$

که در آن $d_s(n)$ بیانگر میزان تفکیک‌پذیری ویژگی n ام براساس معیار s ام می‌باشد. با در نظر گرفتن $S=3$ مجموعه معیارهای مورد استفاده شامل موارد زیر است:

$$\text{dist} \in D = \{d_e, d_m, d_{x^2}\} \quad (9)$$

ب- انتخاب ویژگی

با هدف کاهش ابعاد و بهبود عملکرد طبقه‌بند، مجموعه‌ای از ویژگی‌های مناسب شامل $N' > N$ ویژگی از بین ویژگی‌های اولیه F به صورت مجموعه زیر انتخاب می‌شود.

$$F'_S = \{f'_{n'} | n' = 1, 2, \dots, N'\} \quad (5)$$

به طوری که $f'_{n'}$ بیانگر ویژگی n' ام جدید است.

ج- طبقه‌بند

به منظور طبقه‌بندی تداخل‌ها از یک طبقه‌بند شبکه عصبی MLP استفاده شده است به گونه‌ای که براساس ویژگی‌های انتخابی از فضای F' بتوان نوع تداخل را تشخیص داد.

د- تشخیص نوع تداخل

در نهایت، کلاس‌ها که در اینجا چهار کلاس سیگنال مطلوب (SOI)، تداخل چرپ (CI)، تداخل موج پیوسته (CWI) و تداخل چندگانه موج پیوسته (MCWI) می‌باشد، مطابق رابطه (۶) تشخیص داده می‌شوند:

$$C = \begin{cases} SOI & ; c_1 \\ SOI + CI & ; c_2 \\ SOI + CWI & ; c_3 \\ SOI + MCWI & ; c_4 \end{cases} \quad (6)$$

۴- روش پیشنهادی

تشخیص و شناسایی دقیق تداخل نیازمند بهره‌گیری از ویژگی‌های کلیدی با کارایی بالا است. یکی از راهکارهای مؤثر برای بهبود کارایی مدل، کاهش تعداد ویژگی‌هاست. این اقدام می‌تواند زمان پردازش را کاهش دهد اما اگر این عمل با دقت انجام نگیرد، ممکن است بر دقت طبقه‌بندی تأثیر منفی بگذارد [۳۰]. برای انتخاب ویژگی‌های مناسب در فرآیند طبقه‌بندی، روشی مبتنی بر چارچوب ارائه‌شده در شکل (۱) پیاده‌سازی شده است.

برای این منظور از میان $N = 33$ ویژگی آماری و طیفی اولیه مطابق با رابطه (۳) و جدول (۱)، استفاده شده است. این ویژگی‌ها به صورت $f_{(c_i,n)}$ تعریف شده‌اند، که در آن i نمایانگر شماره کلاس و n شماره ویژگی را نشان می‌دهد. در گام بعد، به منظور ارزیابی میزان تفکیک‌پذیری هر ویژگی، از چهار معیار مختلف اقلیدوسی، مالهالانوبیس، کای دو و VdM استفاده می‌شود و در نهایت N' ویژگی که بیشترین قدرت تفکیک بین کلاس‌ها را

$$f_n^S = D(n, d_S), \forall n \in \{1, 2, \dots, 33\}, S \in \{m, k, x^2\} \quad (13)$$


f_n^S نشان دهنده میزان تفکیک پذیری ویژگی n ام براساس معیار S است.

در نهایت، برای هر معیار $S \in \{e, m, x^2\}$ ، تعداد $N' = 10$ ویژگی با بالاترین میزان تفکیک پذیری براساس مقادیر f_n^S به صورت زیر انتخاب می شوند:

$$F'_S = \arg \max_{n \in \{1, 2, \dots, 33\}} (f_n^S) \quad (14)$$

۴-۲- معیار نسبت واریانس به میانگین (VdM)

در روش پیشنهادی مبتنی بر معیار VdM که در شکل (۳) نمایش داده شده است، از این نسبت به عنوان یک معیار آماری نرمال شده با میانگین برای انتخاب ویژگی استفاده شده است.



شکل (۳): روش مبتنی بر معیار VdM

مطابق شکل (۳)، این نسبت، میزان پراکندگی مقادیر ویژگی را نسبت به مقدار میانگین آن می سنجد. هرچه میزان پراکندگی بیشتر باشد، آن ویژگی، اطلاعات بیشتری در خود داشته و توانایی بالاتری در تفکیک کلاس ها خواهد داشت. به عنوان مثال، همان طور که در شکل (۴) مشاهده می شود، بعضی از ویژگی ها همانند f_2 و f_5 ویژگی های نسبتاً ضعیف تری در تفکیک بین کلاس ها محسوب می شوند، در حالی که ویژگی هایی نظیر f_7 و

که در آن:

- d_e : فاصله اقلیدوسی
- d_m : فاصله ماهالانوبیس
- d_{x^2} : فاصله کای-دو می باشد.

برای هر ویژگی n و هر معیار $d_S \in D$ ، میانگین فاصله بین تمام زوج کلاس ها به منظور ارزیابی تفکیک پذیری ویژگی ها به صورت رابطه (۱۰) محاسبه می شود.

$$D(n, d_S) = \sum_{j=l+1}^C \sum_{i=1}^{C-1} \frac{2}{C(C-1)} \text{dist}_S(f_{(c_i,n)}, f_{(c_j,n)}), \quad (10)$$

$S \in \{e, m, x^2\}$

$f_{(c_i,n)}$ مقدار ویژگی n ام در کلاس C_i می باشد که فاصله (dist) برای معیارهای اقلیدوسی، ماهالانوبیس و کای دو به صورت رابطه (۱۱) محاسبه می شود:

$$\begin{cases} d_e(f_{(c_i,n)}, f_{(c_j,n)}) = \sqrt{\sum_{i,j=1}^m (f_{(c_i,n)} - f_{(c_j,n)})^2} \\ d_m(f_{(c_i,n)}, f_{(c_j,n)}) = \frac{\sqrt{\Sigma^{-1} (f_{(c_i,n)} - f_{(c_j,n)})^T (f_{(c_i,n)} - f_{(c_j,n)})}}{\sqrt{\sum_{i,j=1}^m \frac{(f_{(c_i,n)} - f_{(c_j,n)})^2}{f_{(c_i,n)} + f_{(c_j,n)}}}} \\ d_{x^2}(f_{(c_i,n)}, f_{(c_j,n)}) = \sqrt{\sum_{i,j=1}^m \frac{(f_{(c_i,n)} - f_{(c_j,n)})^2}{f_{(c_i,n)} + f_{(c_j,n)}}} \end{cases} \quad (11)$$

در معیار ماهالانوبیس، برخلاف فاصله اقلیدوسی، فاصله همبستگی بین ویژگی ها نیز در محاسبات لحاظ می شود و Σ ماتریس کوواریانس ویژگی ها می باشد.

با فرض وجود چهار کلاس مختلف شامل سیگنال مطلوب (SOI)، تداخل چرپ (CI)، تداخل موج پیوسته (CWI) و تداخل موج پیوسته چندگانه (MCWI)، تعداد زوج کلاس ها مطابق رابطه ترکیبی $6 = \binom{4}{2}$ محاسبه می شود. در نتیجه رابطه (۱۲) برای ۴ کلاس به صورت زیر بازنویسی می شود:

$$D(n, d_S) = \frac{1}{6} (\text{dist}_S(f_{(c_1,n)}, f_{(c_2,n)}) + \text{dist}_S(f_{(c_1,n)}, f_{(c_3,n)}) + \text{dist}_S(f_{(c_1,n)}, f_{(c_4,n)}) + \text{dist}_S(f_{(c_2,n)}, f_{(c_3,n)}) + \text{dist}_S(f_{(c_2,n)}, f_{(c_4,n)}) + \text{dist}_S(f_{(c_3,n)}, f_{(c_4,n)})) \quad (12)$$

مقدار $D(n, d_S)$ برای هر ویژگی n و معیار d_S به عنوان ویژگی تحت آن معیار خاص در نظر گرفته می شود به طوری که:

ویژگی‌های انتخاب‌شده با استفاده از معیارهای معرفی‌شده و ارزیابی عملکرد آن‌ها در شرایط محیطی مختلف است. درضمن، مقایسه‌ای با روش ارائه‌شده در مرجع [۵] انجام شده است. نتایج به‌دست‌آمده نشان می‌دهد که روش پیشنهادی توانایی بهبود دقت طبقه‌بندی را در شرایط نویزی مختلف تأیید می‌کند.

در این مقاله از مجموعه پایگاه داده ارائه‌شده در مرجع [۵] استفاده شده است این مجموعه داده شامل جریان ویدئویی بلادرنگ استاندارد DVB-S2 بوده که شامل ۴۸۰۰ نمونه سیگنال با مدولاسیون‌های QPSK و APSK ۸/۱۶/۳۲ (به همراه تداخل‌های فرکانس رادیویی CI - CWI - MCWI) در کانال AWGN می‌باشد. هر نمونه سیگنال دارای طول ۳۲۴۸۸ نقطه و با فرکانس نمونه‌برداری ۴۰ مگاهرتز ثبت شده است. جدول (۳) مشخصات پایگاه داده بلادرنگ مورد استفاده را نشان می‌دهد.

جدول (۳): مشخصات مجموعه داده DVBS2

مقدار	مشخصات
۴۸۰۰	تعداد کل نمونه‌ها
۳۲۴۸۸	طول سیگنال‌های تولید شده
۴۰ MHz	فرکانس نمونه‌برداری
APSK۸-QPSK, APSK۳۲-APSK, ۱۶-	انواع مدولاسیون
۹ دسی‌بل	نسبت سیگنال به نویز
۳۰۰	تعداد نوع سیگنال در هر نوع مدولاسیون

برای شبیه‌سازی شرایط مختلف نویزی، نویز گوسی جمع‌شونده سفید (AWGN) با توان‌های متفاوت به سیگنال‌های اصلی اضافه شده است. به این صورت که ابتدا پایگاه داده با SNR برابر با ۹ دسی‌بل در نظر گرفته شدند. با تنظیم توان نویز افزوده شده، نسبت سیگنال به نویز (SNR) در بازه ۰ تا ۹ دسی‌بل تغییر داده شد تا عملکرد مدل پیشنهادی در شرایط نویزی مختلف ارزیابی گردد. هدف از این کار، بررسی دقت مدل در شناسایی و طبقه‌بندی تداخل‌های رادیویی در نسبت سیگنال به نویزهای مختلف است.

به منظور اعمال نویز و کنترل مقدار نسبت سیگنال به نویز به این صورت عمل می‌شود که در ابتدا سیگنال دریافتی شامل نویز واقعی کانال مرجع [۵] لحاظ شده، به صورت زیر مدل می‌شود:


$$y_1 = x + n_1 \quad n_1 \sim CN(0, \sigma_1^2) \quad (16)$$

که x سیگنال ارسالی و y_1 سیگنال دریافتی است. نسبت سیگنال به نویز در این مرحله برابر است با:

$$SNR_1 = \frac{P_x}{\sigma_1^2} \quad (17)$$

که P_x توان سیگنال ارسالی است، حال برای مدل‌سازی اضافه

f_{17} از قدرت تفکیک بیشتری برای تمایز کلاس‌ها برخوردار بوده و به‌عنوان ویژگی‌های مناسب انتخاب می‌شوند.



شکل (۴): مقایسه تفکیک کلاس‌ها با ۴ ویژگی f_2, f_5, f_7 و f_{17} جدول (۲) مقایسه‌ای برای چهار ویژگی بیان شده برای شکل (۴) نشان داده شده است. همانطور که ملاحظه می‌شود علی‌رغم اینکه مقادیر میانگین دو ویژگی f_2 و f_5 بیشتر بوده اما میزان پراکندگی اطلاعات در آن دو ویژگی کمتر است در صورتی که هرچه میزان پراکندگی بیشتر باشد، آن ویژگی اطلاعات بیشتری در خود دارد و توانایی بالاتری در تفکیک کلاس‌ها خواهد داشت. به همین دلیل ویژگی‌های f_7 و f_{17} توانسته‌اند تفکیک بهتری در بین کلاس‌ها ایجاد کنند.

جدول (۲): مقایسه تفکیک کلاس‌ها با ۴ ویژگی f_2, f_5, f_7 و f_{17}

ویژگی‌ها	f_2	f_5	f_7	f_{17}
میانگین	۰/۸۰۳۲	۰/۶۴۸۸	۰/۳۵۱۳	۰/۳۶۱۱
واریانس	۰/۰۰۰۱	۰/۰۰۰۴	۰/۰۳۰۶	۰/۰۶۱۵
واریانس به میانگین	۰/۰۰۰۲	۰/۰۰۰۶	۰/۰۸۷۱	۰/۱۷۰۳

برای انتخاب ویژگی‌ها با این معیار از نسبت واریانس بر میانگین ویژگی به صورت رابطه (۱۵) استفاده می‌شود:

$$d_c = \frac{\mathbb{E}[(f_{(c_1,n)}, \dots, f_{(c_4,n)})^2] - \mathbb{E}[f_{(c_1,n)}, \dots, f_{(c_4,n)}]^2}{\mathbb{E}[f_{(c_1,n)}, \dots, f_{(c_4,n)}]} \quad (15)$$

در نهایت ده ویژگی برتر مطابق رابطه (۱۴)، که پیش‌تر گفته شد، انتخاب می‌شوند. در بخش نتایج و بحث، به ویژگی‌های انتخاب شده برحسب هر معیار و ارزیابی معیارها پرداخته می‌شود.


۵- نتایج و بحث

در این بخش، نتایج حاصل از ارزیابی کارایی معیارهای گفته شده در شناسایی و طبقه‌بندی تداخل‌های رادیویی (CI, CWI, MCWI و SOI) در نسبت سیگنال به نویزهای ۰ تا ۹ دسی‌بل مورد بحث و تحلیل قرار می‌گیرد. هدف اصلی این بخش، مقایسه

جدول (۴): مقادیر ویژگی‌های منتخب در معیار VdM در SNR بالا

ویژگی‌ها	f7	f8	f9	f13	f15	f17	f18	f22	f27	f29
میانگین	۰/۲۵۱۳	۰/۲۷۳۹	۰/۲۳۷۶	۰/۲۱۲۱	۰/۲۴۴۴	۰/۲۶۱۱	۰/۱۸۳۴	۰/۰۷۸۹	۰/۲۴۵۹	۰/۲۰۴۶
واریانس	۰/۰۳۰۶	۰/۰۲۶۹	۰/۰۳۳۰	۰/۰۳۱۱	۰/۰۰۶۶	۰/۰۶۱۵	۰/۰۱۶۸	۰/۰۰۲۱	۰/۰۰۹۴	۰/۰۲۵۶
واریانس به میانگین	۰/۰۸۷۱	۰/۰۹۸۲	۰/۰۹۷۸	۰/۰۶۷۷	۰/۰۲۶۸	۰/۱۷۰۳	۰/۰۹۱۸	۰/۰۲۶۹	۰/۰۳۸۲	۰/۱۱۶۹

با اعمال معیار VdM در شرایط SNR پایین، که شبیه‌سازی محیطی با نویز بسیار شدید است، ده ویژگی متفاوت شناسایی شد. مطابق با شکل (۶) ویژگی‌های منتخب به صورت زیر می‌باشد.



شکل (۶): مقایسه ویژگی‌ها با معیار VdM در SNR پایین

شکل‌های (۷) تا (۹) نتایج ارزیابی ویژگی‌ها با استفاده از سه معیار فاصله اقلیدوسی، ماهالانوبیس و کای-دو را نشان می‌دهند. محور عمودی فاصله لگاریتمی برای هر ویژگی را نمایش می‌دهد؛ طول بیشتر میله‌ها بیانگر توان تفکیک‌پذیری بهتر آن ویژگی است. همان‌طور که مشاهده می‌شود، معیارهای اقلیدوسی و کای-دو مجموعه‌ای تقریباً مشابه از ویژگی‌های برتر را انتخاب کرده‌اند. در مقابل، معیار ماهالانوبیس مجموعه‌ای متفاوت از ویژگی‌های منتخب ارائه کرده است. این تفاوت ناشی از ماهیت این معیار است که علاوه بر فاصله، ساختار همبستگی بین ویژگی‌ها را نیز در نظر می‌گیرد. در واقع، با لحاظ کردن ماتریس کوواریانس، ماهالانوبیس توانسته ویژگی‌هایی را انتخاب کند که نه تنها به صورت جداگانه، بلکه در ترکیب با سایر ویژگی‌ها قدرت تفکیک بیشتری داشته باشند. این نکته اهمیت توجه به همبستگی بین ویژگی‌ها را در فرآیند انتخاب ویژگی نشان می‌دهد.

شدن نویز با واریانس کنترل‌شده σ_2^2 ، سیگنال دریافتی را به صورت زیر بیان می‌کنیم:


$$y_2 = y_1 + n_2 = x + n_1 + n_2, n_2 \sim CN(0, \sigma_2^2) \quad (18)$$

در نتیجه نسبت سیگنال به نویز پس از اضافه شدن نویز دوم به صورت زیر محاسبه می‌شود:

$$SNR_2 = \frac{P_x}{\sigma_1^2 + \sigma_2^2} = \frac{1}{\frac{1}{SNR_1} + \frac{\sigma_2^2}{P_x}} \quad (19)$$

مطابق چارچوب ارائه‌شده در روش پیشنهادی، در این بخش تمرکز بر انتخاب ده ویژگی برتر برای ایجاد بیشترین تمایز بین کلاس‌ها با استفاده از معیارهای اقلیدوسی، ماهالانوبیس، کای دو و VdM می‌باشد. برای استخراج ده ویژگی برتر با استفاده از معیار VdM، این معیار به طور جداگانه در شرایط SNR پایین و SNR بالا اعمال شد. شکل (۵) و جدول (۴) به ترتیب تمایز بین کلاس‌ها برای هر ویژگی و نسبت واریانس به میانگین ده ویژگی دارای بیشترین توان تفکیک کلاس‌ها در شرایط SNR بالا را نشان می‌دهند. همان‌گونه که مشاهده می‌شود، این ده ویژگی در مقایسه با سایر ویژگی‌ها بالاترین مقادیر نسبت واریانس به میانگین را داشته‌اند که بیانگر قدرت بالای آن‌ها در تشخیص و تفکیک‌پذیری کلاس‌های SOI، CI، CWI و MCWI است.

$$f_{VdM} = \{f_7, f_8, f_9, f_{13}, f_{15}, f_{17}, f_{18}, f_{22}, f_{27}, f_{29}\} \quad (20)$$



شکل (۵): مقایسه ویژگی‌ها با معیار VdM در SNR بالا

۵-۱- مقایسه میزان دقت معیارهای چهارگانه

(اقلیدوسی، ماهالانوبیس، کای-دو و VdM)

برای انجام فرآیند طبقه‌بندی، از یک شبکه MLP با ۱۰ نورون در لایه ورودی (متناظر با $N' = 10$ ویژگی انتخاب‌شده) و ۴ نورون در لایه خروجی (نمایانگر ۴ کلاس CI، CWI، MCWI و SOI) استفاده شده است. تعداد نورون‌های لایه مخفی برابر ۳۰ و حالت یادگیری آنلاین با اندازه دسته‌ای^۱ (BS) برابر یک تنظیم گردید. در این مدل، تابع فعال‌ساز لایه پنهان از نوع Logarithmic Sigmoid انتخاب شده و برای لایه خروجی از تابع Softmax استفاده گردیده است. الگوریتم بهینه‌سازی مورد استفاده SGD بوده و آموزش شبکه با نرخ یادگیری ۰.۰۱ انجام شده است. علاوه بر این، برای ارزیابی پایداری مدل، از اعتبارسنجی متقاطع ۱۰ بخشی^۲ استفاده شده و تعداد کل تکرارهای آموزشی برابر ۵۸ تعیین شده است.

به‌منظور ارزیابی کارایی انتخاب ویژگی‌های مؤثر برای طبقه‌بندی سیگنال‌ها، نرخ دقت^۳ طبقه‌بندی براساس چهار معیار مختلف اقلیدوسی، ماهالانوبیس، کای-دو و VdM محاسبه و مقایسه گردید. مطابق شکل (۱۰) و جدول (۵)، دقت طبقه‌بندی مدل در نسبت‌های مختلف سیگنال به نویز ارائه شده است. دقت طبقه‌بندی به‌صورت نسبت تعداد نمونه‌های درست طبقه‌بندی‌شده به کل نمونه‌ها تعریف می‌شود که رابطه آن به شرح زیر است:

$$accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (25)$$

که در آن:

- TP: تعداد نمونه‌های مثبت که درست شناسایی شده‌اند.
- TN: تعداد نمونه‌های منفی که درست شناسایی شده‌اند.
- FP: تعداد نمونه‌های منفی که به اشتباه مثبت شناسایی شده‌اند.
- FN: تعداد نمونه‌های مثبت که به اشتباه منفی شناسایی شده‌اند.

نتایج نشان می‌دهد که استخراج و انتخاب ویژگی‌های آماری و

معیار اقلیدوسی:


$$f_e = \{f_{16}, f_{17}, f_{18}, f_{19}, f_{21}, f_{22}, f_{23}, f_{31}, f_{32}, f_{33}\} \quad (22)$$

معیار ماهالانوبیس:


$$f_m = \{f_4, f_5, f_6, f_9, f_{13}, f_{15}, f_{19}, f_{20}, f_{29}, f_{33}\} \quad (23)$$

معیار کای-دو:


$$f_{\chi^2} = \{f_{15}, f_{16}, f_{18}, f_{19}, f_{21}, f_{22}, f_{23}, f_{31}, f_{32}, f_{33}\} \quad (24)$$



شکل (۷): مقایسه ویژگی‌ها با معیار اقلیدوسی



شکل (۸): مقایسه ویژگی‌ها با معیار ماهالانوبیس



شکل (۹): مقایسه ویژگی‌ها با معیار کای-دو

¹ Batch Size

² 10-fold cross-validation


³ Accuracy

۵-۲- مقایسه ۳۳ ویژگی با ۱۰ ویژگی منتخب روش

VdM در مدل MLP

حال به عملکرد شبکه عصبی MLP با مجموعه ویژگی‌های کامل (۳۳ ویژگی) و ۱۰ ویژگی منتخب حاصل از روش VdM در شرایط SNR بالا و SNR پرداخته می‌شود. نتایج جدول (۶) و شکل (۱۱) نشان می‌دهد، که مدل MLP مبتنی بر استفاده از مجموعه ویژگی‌های کامل در تمامی محدوده‌های SNR، به‌طور پیوسته عملکرد بهتری نسبت به ۱۰ ویژگی استخراج شده مبتنی بر VdM دارد؛ هرچند اختلاف دقت در نسبت سیگنال به نویزهای متوسط و بالا بسیار اندک و قابل اغماض است. در شرایط نویز شدید (SNR پایین)، کاهش تعداد ویژگی‌ها در روش VdM موجب افت محسوس دقت می‌شود، اما در SNRهای بالا این کاهش تأثیر معناداری بر عملکرد مدل ندارد. این روند بیانگر آن است که با بهبود شرایط نویزی، اهمیت کاهش ویژگی‌ها در روش VdM کاهش یافته و مدل، حتی با زیرمجموعه‌ای از ویژگی‌ها، می‌تواند بازدهی مشابه مدل کامل را حفظ کند.

جدول (۶): میزان دقت مدل MLP با استفاده از مجموعه کامل



شکل (۱۱): مقایسه دقت طبقه‌بندی مدل MLP به ازای مجموعه


ویژگی‌های کامل و روش VdM در شرایط SNR بالا و SNR پایین

جدول (۷) زمان‌های محاسباتی، حجم مدل و قابلیت پیاده‌سازی روش پیشنهادی برای شناسایی و طبقه‌بندی تداخل‌های فرکانسی را بر اساس شبیه‌سازی‌های انجام شده در نرم‌افزار MATLAB (نسخه R2024b) و با استفاده از رایانه با پردازنده Core i7-13700H و حافظه RAM با ظرفیت ۳۲ گیگابایت و حافظه گرافیک ۸ گیگابایت نشان می‌دهد. بر اساس نتایج، زمان کل آموزش برابر با ۱۲،۶۹ ثانیه بوده و میانگین زمان استنتاج


طیفی مبتنی بر معیار VdM، عملکرد مدل را به‌طور قابل توجهی در تفکیک کلاس‌ها در شرایط SNR بالا بهبود بخشیده و در محیط‌های دارای نویز شدید، نسبت به سایر معیارها برتری آماری معناداری دارد. این معیار با استفاده از ویژگی‌های استخراج شده در SNR بالا و SNR پایین توانست در SNR=0 dB نسبت به روش مرجع [۵] به ترتیب حدود ۳ و ۶ درصد دقت طبقه‌بندی را بهبود بخشد که بیانگر اثربخشی انتخاب ویژگی‌های تفکیک‌پذیرتر در شرایط نویزی است. درضمن، استفاده از ویژگی‌های استخراج شده در SNR پایین برای مقادیر نسبت سیگنال به نویز کمتر از ۳ دسیبل و بهره‌گیری از ویژگی‌های استخراج شده در SNR بالا برای مقادیر بالاتر از این نسبت، عملکرد بهتری نشان داده است و توانسته است به دقت ۹۹/۷۴٪ برسد. در مقابل، سایر معیارهای فاصله ماه‌الانوبیس، اقلیدوسی و کای-دو در شرایط نویزی عملکرد ضعیف‌تری نسبت به معیار VdM نشان دادند. معیار VdM با تمرکز بر سنجش تفکیک‌پذیری آماری ویژگی‌ها، توانست اطلاعات دقیق‌تری از سیگنال‌های دچار تداخل استخراج کرده و پایداری مدل را در شرایط نویزی ارتقا دهد. این تفاوت عملکرد، اهمیت انتخاب معیار مناسب برای استخراج ویژگی‌ها در سناریوهای مختلف SNR را برجسته می‌سازد.

جدول (۵): میزان دقت به ازای نسبت سیگنال به نویزهای مختلف

SNR (dB)	۰	۱	۲	۳	۴	۵	۶	۷	۸	۹
روش مرجع [۵]	۵۶/۸۹	۸۵/۳۷	۹۱/۴۵	۹۴/۲۱	۹۵/۴۱	۹۶/۳۲	۹۷/۳۸	۹۸/۲۲	۹۸/۷۴	۹۹/۵۸
معیار ماه‌الانوبیس	۵۱/۳۳	۸۰/۴۹	۸۷/۰۷	۹۰/۲۴	۹۲/۲۶	۹۳/۱۲	۹۳/۸۱	۹۴/۴۲	۹۵/۱۶	۹۵/۸۸
معیار اقلیدوسی	۶۶/۲۱	۷۷/۳۲	۸۴/۵۷	۸۷/۱۶	۸۷/۶۸	۸۸/۵۷	۸۹/۱۳	۸۹/۷۴	۹۰/۱۲	۹۰/۶۶
معیار کای-دو	۴۴/۱۳	۷۳/۸۴	۸۱/۴۲	۸۵/۰۷	۸۵/۷۳	۸۶/۳۲	۸۶/۸۴	۸۷/۴۲	۸۸/۰۳	۸۸/۶۲
روش VdM در SNR بالا	۵۹/۲۳	۸۸/۴۱	۹۳/۳۵	۹۶/۶۱	۹۷/۲۴	۹۷/۷۵	۹۸/۴۲	۹۸/۹۱	۹۹/۴۲	۹۹/۷۴
روش VdM در SNR پایین	۶۲/۷۵	۹۰/۱۸	۹۴/۳۷	۹۶/۱۵	۹۶/۵۳	۹۶/۸۲	۹۷/۲۲	۹۷/۷۴	۹۸/۰۸	۹۸/۴۲



شکل (۱۰): میزان دقت به ازای نسبت سیگنال به نویزهای متفاوت



شکل (۱۲): میزان دقت به ازای نسبت سیگنال به نویزهای متفاوت در

مدل‌های KNN و SVM و MLP

۶- نتیجه‌گیری

در این مقاله، روشی کارآمد برای تشخیص و طبقه‌بندی تداخل‌های فرکانس رادیویی در استاندارد DVB-S2 با بهره‌گیری از ویژگی‌های آماری و طیفی و با استفاده از شبکه عصبی MLP ارائه شد و عملکرد معیارهای اقلیدوسی، ماهالانوبیس، کای-دو و VdM با یکدیگر مقایسه گردید. معیار VdM توانست دقت تشخیص را در SNRهای مختلف نسبت به دیگر معیارها بهبود دهد. بهبود ۶ درصدی دقت در SNR=0 dB با استفاده از ویژگی‌های استخراج شده با معیار VdM در SNR پایین و همچنین بهبود ۳ درصدی در این SNR با استفاده از ویژگی‌های استخراج شده با این معیار در SNR بالا و دست یافتن به دقت ۹۹/۷۴٪ در SNR=9 dB توانایی این روش را در تشخیص تداخل‌های رادیویی در شرایط مختلف نویزی را تأیید می‌کند. همچنین، ارزیابی مدل‌های SVM و KNN با استفاده از ویژگی‌های مبتنی بر معیار VdM نشان داد که در شرایط نویز شدید، SVM عملکرد بهتری نسبت به دو مدل دیگر ارائه می‌دهد، در حالی که با افزایش SNR، مدل MLP و SVM عملکرد نزدیک و تقریباً یکسانی داشته و هر دو بر KNN برتری دارند.

۷- مراجع

- [1] G. Maral, M. Bousquet, and Z. Sun, Satellite communications systems: systems, techniques and technology. John Wiley & Sons, 2020. <https://doi.org/10.1002/9781119673811>
- [2] E. Standard, "Digital Video Broadcasting (DVB), Second generation framing structure, channel coding and modulation systems for broadcasting, interactive services, news gathering and other broadband satellite applications (DVB-S2)." Eur. Telecommun. Stand. Inst. ETSI EN, vol. 302, no. 307, p. V1, 2014.
- [3] A. Morello and V. Mignone, "DVB-S2: The second generation standard for satellite broad-band services," Proc. IEEE, vol. 94, no. 1, pp. 210–227, 2006. doi: [10.1109/JPROC.2005.861013](https://doi.org/10.1109/JPROC.2005.861013)

برای هر نمونه حدود ۲۷ میکروثانیه به دست آمده است. نتایج بیانگر آن است که مدل پیشنهادی با توجه به حجم بسیار کم پارامترها و معماری مبتنی بر عملیات ضرب و جمع، از نظر سخت‌افزاری به‌خوبی قابلیت پیاده‌سازی بر روی سامانه‌های بلادرنگ و پردازنده‌های FPGA و DSP دارد. ساختار مدل همچنین با پیاده‌سازی در معماری‌های نقطه‌ثابت^۱ کاملاً سازگار است.

جدول (۷): پارامترهای ساختاری و زمان‌های اجرای مدل MLP

مشخصات	مقادیر
تعداد پارامترها	۴۵۴
حجم مدل	۱/۷۷ (KB)
زمان کل آموزش	۱۲/۶۹ (s)
میانگین به ازای یک نمونه	۲۷ (us)

۵-۳- مقایسه مدل‌های MLP، SVM و KNN بر

اساس ۱۰ ویژگی انتخابی

عملکرد مدل MLP با دو مدل SVM (با هسته کرنل از نوع چندجمله‌ای (Polynomial) مرتبه سوم) و KNN (با تعداد همسایگان برابر ۴)، با استفاده از ویژگی‌های استخراج شده بر اساس معیار VdM در SNR بالا و در گستره‌ای از مقادیر مختلف SNR مورد ارزیابی قرار گرفت. نتایج شکل (۱۲) و جدول (۸) نشان می‌دهد که با افزایش نسبت سیگنال به نویز، دقت طبقه‌بندی در هر سه مدل KNN، SVM و MLP به‌طور پیوسته افزایش می‌یابد. در شرایط نویز شدید (SNR پایین)، مدل SVM با دقت حدود ۶۳/۹۴٪ عملکرد بهتری نسبت به MLP با دقت ۵۹/۲۳٪ و KNN با دقت ۴۳/۴۴٪ دارد. در محدوده SNRهای متوسط، اختلاف عملکرد میان مدل‌های SVM و MLP کاهش یافته و هر دو مدل رفتار مشابهی از خود نشان می‌دهند. به‌طور کلی، در محیط‌های پرنویز، SVM عملکرد بهتری را از خود نشان داده است؛ اما با کاهش نویز، عملکرد MLP و SVM تقریباً یکسان و هر دو به مراتب بهتر از KNN هستند.

جدول (۸): مقایسه میزان دقت در مدل‌های MLP، SVM و KNN

SNR (dB)	۹	۸	۷	۶	۵	۴	۳	۲	۱	۰
MLP	۹۹/۷۴	۹۹/۴۲	۹۸/۹۱	۹۸/۴۲	۹۷/۷۵	۹۷/۲۴	۹۶/۶۱	۹۳/۳۵	۸۸/۴۱	۵۹/۲۳
SVM	۹۹/۹۳	۹۹/۷۸	۹۹/۴۷	۹۹/۰۶	۹۸/۵۳	۹۸/۱۷	۹۷/۳۷	۹۴/۸۲	۹۰/۲۱	۶۳/۹۴
KNN	۹۹/۲۷	۹۹/۰۷	۹۸/۵۸	۹۷/۵۴	۹۶/۳۲	۹۵/۴۷	۹۲/۲۶	۸۱/۹۲	۶۷/۷۵	۴۳/۴۴

^۱ Fixed-Point

- [18] M. Aghalari and H. Khaleghi Bizaki, "Spectrum Anomaly Detection: A Deep Learning Approach," *Comput. Knowl. Eng.*, Oct. 2025, doi: 10.22067/cke.2025.91456.1144.
- [19] G. Baldini, "Wireless Interference Classification in Satellite Communications with the Standardized Variable Distances Learning Algorithm and Adaptive Spectral Domain Segmentation," in 2024 First International Conference on Electronics, Communication and Signal Processing (ICECSP), IEEE, 2024, pp. 1–6. doi:10.1109/ICECSP61809.2024.10698261
- [20] M. Farhang, A. Ghaleh, and H. Dehghani, "Modulation recognition for DVB-S2 standard using pairwise support vector machines," *J. Electron. Cyber Def.*, vol. 1, no. 1, pp. 15–21, 2013. doi:10.1504/IJAACS.2018.092020 (in Persian)
- [21] I. Kadoun and H. K. Bizaki, "Discriminative estimated cumulants-based automatic modulation classification over multipath fading channels," July 28, 2022, In Review. doi: 10.21203/rs.3.rs-1867152/v1.
- [22] A. R. Ramchandra, A. Skurdal, P. Ranganathan, and W. Semke, "Detecting GPS Interference Using Automatic Dependent Surveillance-Broadcast Data," *Electronics*, vol. 13, no. 16, p. 3145, 2024. <https://doi.org/10.3390/electronics13163145>
- [23] Y. Arjoun, F. Salahdine, Md. S. Islam, E. Ghribi, and N. Kaabouch, "A Novel Jamming Attacks Detection Approach Based on Machine Learning for Wireless Communication," in 2020 International Conference on Information Networking (ICOIN), Barcelona, Spain: IEEE, Jan. 2020, pp. 459–464. doi: 10.1109/ICOIN48656.2020.9016462.
- [24] J. Zhao, T. Zhang, T. Gao, and Z. Luo, "Interference Range-Doppler Image Detection by Stacking Classifier Design for Over-the-Horizon Radar," in 2024 6th International Conference on Electronic Engineering and Informatics (EEI), IEEE, 2024, pp. 52–57. Accessed: Mar. 23, 2025. [Online]. Available: <https://ieeexplore.ieee.org/abstract/document/10696114/> doi: 10.1109/EEI63073.2024.10696114
- [25] A. Maroosi, I. Zabbah, and H. Ataei Khabbaz, "Network Intrusion Detection using a Combination of Artificial Neural Networks in a Hierarchical Manner," *J. Electron. Cyber Def.*, vol. 8, no. 1, pp. 89–99, 2020. doi: 10.1001.1.23224347.1399.8.1.8.8 (in Persian)
- [26] M. Idhammad, K. Afdel, and M. Belouch, "Dos detection method based on artificial neural networks," *Int. J. Adv. Comput. Sci. Appl.*, vol. 8, no. 4, 2017. doi: 10.14569/IJACSA.2017.080461
- [27] I. Kadoun and H. K. Bizaki, "Advanced features generation algorithm for MPSK and MQAM classification in flat fading channel," *Radioengineering*, vol. 31, no. 1, p. 127, 2022. doi: 10.13164/re.2022.0127
- [28] Y. Wang et al., "An improved modulation recognition algorithm based on fine-tuning and feature re-extraction," *Electronics*, vol. 12, no. 9, p. 2134, 2023. doi: 10.3390/electronics12092134
- [29] M. Mirarab and M. Sobhani, "Robust modulation classification for PSK/QAM/ASK using higher-order cumulants," in 2007 6th International Conference on Information, Communications & Signal Processing, IEEE, 2007, pp. 1–4. doi: 10.1109/ICICS.2007.4449591
- [30] B. Samanta, K. R. Al-Balushi, and S. A. Al-Araimi, "Artificial neural networks and genetic algorithm for bearing fault detection," *Soft Comput.*, vol. 10, pp. 264–271, 2006. doi: 10.1007/s00500-005-0481-0
- [4] K. Grover, A. Lim, and Q. Yang, "Jamming and anti-jamming techniques in wireless networks: a survey," *Int. J. Ad Hoc Ubiquitous Comput.*, vol. 17, no. 4, pp. 197–215, 2014. doi: 10.1504/IJAHUC.2014.066419
- [5] S. Ujan, N. Navidi, and R. J. Landry, "Hierarchical classification method for radio frequency interference recognition and characterization in satcom," *Appl. Sci.*, vol. 10, no. 13, p. 4608, 2020. doi:10.3390/app10134608
- [6] O. A. Dobre, A. Abdi, Y. Bar-Ness, and W. Su, "A Survey of Automatic Modulation Classification Techniques: Classical Approaches and New Trends". doi:10.1049/iet-com:20050176
- [7] S. Haykin, D. J. Thomson, and J. H. Reed, "Spectrum sensing for cognitive radio," *Proc. IEEE*, vol. 97, no. 5, pp. 849–877, 2009. doi:10.1109/JPROC.2009.2015711
- [8] J. Hofmann, T. Delamotte, and A. Knopp, "Cyclostationarity-based signal detection in multi-satellite systems," in 2022 56th Asilomar Conference on Signals, Systems, and Computers, IEEE, 2022, pp. 877–880. doi:10.1109/IEEECONF56349.2022.10051820
- [9] H. Huang and K. Sun, "Interference detection and suppression based on time-frequency analysis," *Adv. Aerosp. Sci. Technol.*, vol. 7, no. 2, pp. 97–111, 2022. <https://doi.org/10.4236/aast.2022.72006>
- [10] J. Su, M. Xi, Y. Gong, M. Tao, Y. Fan, and L. Wang, "Time-varying wideband interference mitigation for SAR via time-frequency-pulse joint decomposition algorithm," *IEEE Trans. Geosci. Remote Sens.*, vol. 60, pp. 1–16, 2022. doi:10.1109/TGRS.2022.3213318
- [11] A. Brito, P. Sebastião, and F. J. Velez, "Hybrid matched filter detection spectrum sensing," *IEEE Access*, vol. 9, pp. 165504–165516, 2021. doi:10.1109/ACCESS.2021.3134796
- [12] T. M. Getu, W. Ajib, and R. Landry, "Energy-based RFI detection: Theory and results," in 2018 14th International Conference on Wireless and Mobile Computing, Networking and Communications (WiMob), IEEE, 2018, pp. 161–168. doi:10.1109/WIMOB.2018.8589089
- [13] F. Salahdine, H. El Ghazi, N. Kaabouch, and W. F. Fihri, "Matched filter detection with dynamic threshold for cognitive radio networks," in 2015 international conference on wireless networks and mobile communications (WINCOM), IEEE, 2015, pp. 1–6. doi:10.1109/WINCOM.2015.7381345
- [14] S. Djukanović, M. Daković, T. Thayaparan, and L. Stanković, "Interference suppression in noise radar systems," in *Radar Sensor Technology XV*, SPIE, 2011, pp. 424–431. Accessed: Mar. 22, 2025. [Online]. doi:10.1117/12.884682 Available: <https://www.spiedigitallibrary.org/conference-proceedings-of-spie/8021/80211M/Interference-suppression-in-noise-radar-systems/10.1117/12.884682.short>
- [15] H. Alizadeh, M. Babaei, and M. Rezaei Kheir Abadi, "Detection of Interfering Signals and Estimation of Their Carrier Frequency in CNC Satellite Communications using Cyclic Spectrum Density," *Sci. J. Electron. Cyber Def.*, vol. 11, no. 2, pp. 91–101, 2023. (in Persian)
- [16] D. Cabric, S. M. Mishra, and R. W. Brodersen, "Implementation issues in spectrum sensing for cognitive radios," in *Conference Record of the Thirty-Eighth Asilomar Conference on Signals, Systems and Computers*, 2004., Ieee, 2004, pp. 772–776. doi:10.1109/ACSSC.2004.1399240
- [17] T. Nawaz, D. Campo, M. O. Mughal, L. Marcenaro, and C. S. Regazzoni, "Jammer detection algorithm for wide-band radios using spectral correlation and neural networks," in 2017 13th International Wireless Communications and Mobile Computing Conference (IWCMC), IEEE, 2017, pp. 246–251. doi:10.1109/IWCMC.2017.7986294