

طبقه‌بندی خودکار مدولاسیون درون پالسی ترکیبی راداری

پوریا اعتضادی فر^{*۱}، غلامرضا گرمابداری^{*۲}

۱. استادیار، دانشکده مهندسی برق و کامپیوتر، دانشگاه جامع امام حسین (ع)، تهران، ایران

۲. کارشناسی ارشد مهندسی برق مخابرات، گرایش جنگ الکترونیک، دانشگاه امام حسین (ع)، تهران، ایران

تاریخ دریافت:

۱۱ تیر ماه ۱۴۰۳

تاریخ پذیرش:

۰۱ شهریور ماه ۱۴۰۳

چکیده

در این مقاله، طبقه‌بندی خودکار مدولاسیون‌های درون پالسی ترکیبی راداری با بهره‌گیری از ویژگی‌های مبتنی بر طیف در نسبت سیگنال به نویزهای مختلف و با استفاده از روش‌های مختلف یادگیری ماشین در حوزه طبقه‌بندی مدولاسیون انجام پذیرفته است. ابتدا به بیان اهمیت و بررسی مدولاسیون‌های ترکیبی راداری پرداخته شده است و در ادامه معرفی ویژگی‌های مبتنی بر طیف سیگنال و بررسی رفتار هریک از این ویژگی‌ها برای مدولاسیون‌های راداری پرداخته شده است. در گام بعدی، روش‌های طبقه‌بندی مدولاسیون برای سیگنال‌های ترکیبی راداری مورد بررسی و مقایسه قرار گرفته شده است و در انتها روش بهینه طبقه‌بندی خودکار برای مدولاسیون‌های ترکیبی انتخاب و به کار گرفته شده است. پس از ۱۰۰۰ بار آموزش هریک از روش‌های طبقه‌بندی خودکار، عملکرد سیستم تا حد خوبی بهبود می‌یابد. این طرح برای SNR بسیار پایین نیز عملکرد بسیار خوبی دارد و همچنین، در مقایسه با روش‌های بررسی شده دقت بسیار بالاتری را در خروجی طبقه‌بندی ارائه می‌دهد. مهم‌ترین ویژگی روش پیشنهادی این است که برخلاف روش‌های پیشین، در SNR بسیار پایین نیز کارایی مؤثری از خود نشان می‌دهد. نتایج حاصل از شبیه‌سازی نیز عملکرد بسیار خوب این روش را در شرایط مختلف تأیید می‌کند.

واژه‌های کلیدی: رادار پالسی، طبقه‌بندی خودکار مدولاسیون ترکیبی، ویژگی‌های مبتنی بر طیف.

Automatic Classification of Radar Hybrid IntraPulse Modulation

Pouriya Etezadifar^{*1}, Gholamreza Garmabdari²

1. Assistant Prof, Faculty of Electrical Engineering, Imam Hussain University of Tehran, Iran.

2. MSc, Electronic Warfare, Imam Hussain University of Tehran, Iran

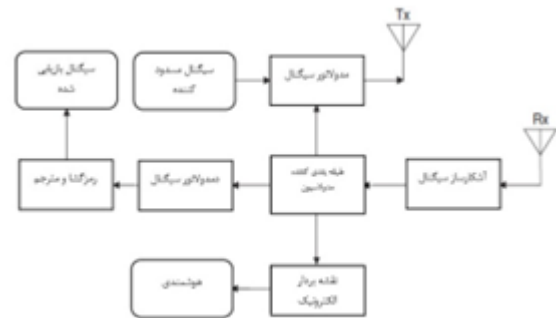
Abstract

In this paper, the automatic classification of radar hybrid intra-pulse modulations has been performed using spectrum-based characteristics in signal-to-noise ratio and using different methods in the field of modulation classification. First, the importance of combining radar modulations is discussed. Then the characteristics based on the signal spectrum and the behavior of each of these features for radar modulations are introduced. In the next step, the modulation classification methods for radar hybrid signals are examined and compared. At the end, the most optimal automatic classification method for combined modulations is selected and used. After 1000 trainings of each automatic classification method, the performance of the system improves to a great extent. This design also performs very well for very low SNRs and also offers much higher accuracy in that, unlike the previous methods, it shows effective efficiency in very low SNRs. The simulation result also confirms this method's very good performance in different conditions.

Key words: Pulse Radars, Hybrid Modulation Classification, Spectrum based features.

اطلاعات مدولاسیون برای شناسایی واحدهای دشمن و مکان احتمالی آنها استفاده می‌شود. بنابراین طبقه‌بندی پالس نقش مهمی را در گیرنده‌های جنگ الکترونیک مانند شناسایی و تحلیل تهدید، ساخت پاسخ اختلال‌های مؤثر و شناسایی فرستنده‌های رادار ایفا می‌کند [۲]. معمولاً، پالس‌های طولانی، از شکل موج‌های استاندارد موج پیوسته استفاده می‌کنند که نسبت تفکیک فاصله ای ضعیفی دارند پهنای باند پالس پهن را می‌توان از طریق مدولاسیون فاز یا فرکانس برابر پهنای باند پالس باریک نمود. تراکم پالس، با استفاده از مدولاسیون فاز و فرکانس، به یک رادار امکان می‌دهد تا به‌طور هم‌زمان از انرژی پالس پهن و قدرت تفکیک پالس باریک، برخوردار باشد. در واقع فشرده‌سازی پالس یک روش دستیابی به اکثر مزایای پالس کوتاه می‌باشد. ضمن اینکه محدودیت توان انتشاری و برد را نیز برطرف می‌سازد. فشرده‌سازی پالس عبارت است از فرآیندی که بر روی یک پالس پهن صورت می‌گیرد و این پالس به‌صورت یک پالس کوتاه درمی‌آید. پالس انتقال یافته به‌عنوان پالس بسط یافته و پالس حاصل از فرآیند فشرده‌سازی به‌عنوان پالس فشرده خوانده می‌شود. پالس‌های باریک تر، پهنای باند بیشتر و تفکیک بهتری دارند. تفکیک یک پالس باریک می‌تواند به‌وسیله مدوله کردن یک پالس پهن به دست آید که حاصل ضرب زمان-پهنای باند را افزایش می‌دهد. تکنیک‌های فشرده‌سازی پالس بر اساس مفهوم انتشار یک پالس پهن با به‌کارگیری از مدولاسیون‌های ویژه استوار است که این امکان را برای گیرنده فراهم می‌سازد که در زمان پردازش پالس دریافتی، ضمن پردازش جزء به‌جزء پالس، آن را به یک پالس باریک تبدیل نموده و تحت چنین شرایطی رادار کارایی مناسبی در تمامی زمینه‌ها داشته باشد. بر اساس روابط راداری، تفکیک برد برای هر میکروثانه برابر با ۱۵۰ متر می‌باشد. به‌عنوان مثال اگر تعدادی رادار پالس داپلر که فاصله زمانی پالس آن‌ها حدود ۱۰ میکروثانه بوده مقدار تفکیک برد فوق، فاصله ۱۵۰۰ متر است لذا این‌گونه رادارها نمی‌توانند در یک پرواز جمعی که فاصله دو هدف کمتر از ۱۵۰۰ متر می‌باشد را تفکیک نمایند و این اهداف به‌صورت یک هدف واحد در صفحه رادار ظاهر می‌گردند. کم کردن پهنای پالس موجب افزایش پهنای باند انرژی ارسالی می‌گردد و همچنین تعداد هماهنگ‌ها را افزایش می‌دهد و اثر نامطلوب در پردازش داپلری به وجود می‌آورد. بعلاوه اگر در یک راداری با پالس ۵ میکروثانه می‌توان ۱۰ کیلووات را به یک پالس نیم میکروثانه کاهش دهیم می‌بایست توان آن را به ۱۰۰ کیلووات افزایش داده تا همان مقدار توان میانگین را داشته باشیم که از مقدرات رادار نبوده و ممکن است به بخش‌های دیگر رادار آسیب برسانند. بنابراین می‌توان گفت که برای حفظ تفکیک برد بهتر، نیاز به پالس نیم میکروثانه می‌باشد، اما از جهاتی دیگر که اشاره شد به یک پالس ۵ میکروثانه نیاز است. روش فشرده‌سازی پالس به رادار این امکان را می‌دهد که دو تضاد فوق را برطرف نماید. SAWI بخش مهمی است که سبب عریض‌تر شدن

طبقه‌بندی خودکار مدولاسیون، اولین بار در سناریوهای نظامی مورد استفاده قرار گرفت؛ جایی که جنگ الکترونیک و مراقبت و تحلیل تهدیدها، نیاز به شناخت مدولاسیون سیگنال و تشخیص واحدهای فرستنده دشمن را، جهت ساخت سیگنال‌های اختلال‌کننده و بازیابی سیگنال‌های رهگیری شده، ایجاب می‌کند. واژه "خودکار"، در مقابل طبقه بندی مدولاسیون دستی قرار دارد، روشی که در اولین روزهای طبقه بندی مدولاسیون به کار می‌رفت، یعنی زمانی که سیگنال‌ها، توسط مهندسان و با کمک تجهیزات مشاهده و پردازش می‌شدند. اکثر طبقه‌بندی کننده‌های مدولاسیون، در طی ۲۰ سال اخیر ساخته شده‌اند و از طریق پردازنده های الکترونیکی پیاده‌سازی شده‌اند. در دهه های ۱۹۸۰ و ۱۹۹۰، تعداد قابل توجهی از محققان فعال در زمینه ی پردازش سیگنال و مخابرات، تمام وقت خود را وقف کار روی طبقه بندی خودکار مدولاسیون کردند. توجه به طبقه بندی خودکار مدولاسیون، به منظور تحقق اهداف نظامی تا همین امروز ادامه دارد. طبقه بندی خودکار مدولاسیون نقش بسیار مهمی در بسیاری از استراتژی های نظامی ایفا می‌کند. جنگ الکترونیک مدرن، سه مؤلفه اصلی دارد: پشتیبانی الکترونیکی، حمله الکترونیکی و حفاظت الکترونیکی در پشتیبانی الکترونیکی، هدف، جمع آوری اطلاعات از امواج منتشر شده با فرکانس رادیویی هست که این کار اغلب درجایی انجام می‌گیرد که بعد از تشخیص موفقیت آمیز سیگنال، به کار گرفته می‌شود. اطلاعاتی که در این مرحله در مورد مدولاسیون به دست می‌آید، می‌توانند چندین کاربرد داشته باشد و در همه مؤلفه‌های جنگ الکترونیکی گسترش یابد. شکل (۱) نحوه ادغام سیستم طبقه بندی مدولاسیون در سیستم‌های جنگ الکترونیک را نشان می‌دهد [۱].



شکل ۱- نحوه ادغام سیستم طبقه‌بندی مدولاسیون در سیستم‌های جنگ الکترونیک [۱]


علاوه بر پشتیبانی الکترونیکی، اطلاعات مدولاسیون را می‌توان برای مدولاسیون سیگنال رهگیری شده نیز به‌کاربرد. به این ترتیب می‌توان پیام منتقل شده میان واحدهای دشمن را بازیابی کرد. البته این فرآیند با کمک رمزگشایی و ترجمه سیگنال تکمیل می‌شود. از طرف دیگر اطلاعات مدولاسیون، به‌تنهایی، می‌توانند اطلاعاتی حیاتی برای سیستم‌های نقشه‌برداری الکترونیک باشند که در این سیستم‌ها، از

¹ Surface Wave Acoustic devices OR dispersive delay line

بیشتری را می‌توان منتقل کرد. [10] معادله (۱) بیانگر شکل زمانی سیگنال مدولاسیون ترکیبی FSK-LFM است:

$$s(t) = \sum_{m=1}^M A \exp \left\{ j2\pi f_m [t + [t - (m-1)T_m]^2 / 2] + \varphi \right\} \quad (1)$$

که A دامنه پالس، T_m عرض زیر پالس‌ها، m تعداد و φ فاز اولیه، f_m تابع FSK است که m تعداد زیر پالس‌ها است. ویژگی اصلی سیگنال مدولاسیون ترکیبی FSK-LFM این است که فرکانس به صورت خطی در سطح فرکانس‌های مختلف در هر یک از زیر پالس‌ها تنظیم می‌شود. در ضمن، پهنای باند مدولاسیون فرکانس و شیب مدولاسیون هر یک از زیر پالس‌ها یکسان هستند.



شکل ۲- نمایش فرکانس لحظه‌ای مدولاسیون ترکیبی FSK-LFM [10]

۲-۲- مدولاسیون ترکیبی FSK-BPSK

معادله (۲) بیانگر شکل زمانی سیگنال مدولاسیون ترکیبی FSK-BPSK است:

$$s(t) = \sum_{m=1}^M \sum_{n=1}^N A \exp \left\{ j2\pi f_m [t - (m-1)T_m] - (n-1)T_n + \varphi_{m,n} \right\} \quad (2)$$

جایی که $\varphi_{m,n} = (0, \pi)$ تابع فاز کد شده است و B_w پهنای باند زیر پالس‌ها و f_s فرکانس نمونه‌برداری شده و که فاصله نمونه‌برداری $T_s = \frac{1}{f_s}$ همچنین عرض کد $T_n = \frac{1}{B_w}$ و $n = \frac{T_m}{T_n}$ تعداد کد در زیر پالس می‌باشد. ویژگی اصلی سیگنال مدولاسیون ترکیبی FSK-BPSK این است که فرکانس هر زیر پالس در نقطه کدگذاری متفاوت است. درحقیقت، سیگنال دارای مدولاسیون دودویی فاز در زیر پالس‌هاست که در مجموع دارای سیگنال‌های مدولاسیون ترکیبی FSK است. همان‌طور که تابع مدولاسیون فرکانس مشتق تابع مدولاسیون فاز است، مکان تغییرات فاز باعث جهش فرکانس سیگنال

پالس در بخش فرستنده و همچنین بازسازی آن در قسمت گیرنده رادار می‌شود این قسمت وظیفه پهن نمودن پالس در بخش فرستنده و متراکم نمودن آن در قسمت گیرنده را به عهده دارد. بنابراین رادار درون پالسی به رادارهایی اطلاق می‌شود که در زمان انتشار، از یک پالس پهن کد شده استفاده می‌نماید و در زمان پردازش بازتاب‌های دریافت شده از هدف، از خصوصیات یک پالس نسبتاً باریک بهره می‌برد. در چنین شرایطی رادار مقدرات آشکارسازی یک پالس پهن را دارا بوده درحالی که مقدرات تفکیک هدف یک پالس باریک را حفظ می‌نماید. در جنگ الکترونیک، مدولاسیون در پالس‌های رادار به دو طبقه تقسیم می‌شوند: مدولاسیون عمدی در پالس 1 و مدولاسیون غیرعمدی در پالس 2. طبقه‌بندی مدولاسیون پالس که باهدف تشخیص مدولاسیون‌های درون پالسی سیگنال‌های راداری شناخته شده است و با توجه به تعداد روزافزون فرستنده‌ها و رادارهای با احتمال شنود کم^۳ باعث ایجاد محیط الکترومغناطیسی مدرن می‌شوند. [1]

سیستم‌های راداری نوظهور، مانند رادارهای شناختی^۴ [2] رادار با شکل موج چابک^۵ [3] و رادار چند ورودی چند خروجی^۶ [4-5] که حالت‌های عملیاتی خود را با شکل موج‌هایی با انواع مختلف مدولاسیون عمدی‌های پیچیده تغییر می‌دهند و جدا از این، برخی از این شکل موج‌ها با استفاده از مدولاسیون عمدی‌های ترکیبی مانند ترکیب مدولاسیون کدهای فازی گسسته^۷ و فرکانس خطی LFM [6-7]8 شکل موج‌هایی که با مدولاسیون فرکانسی^۹ FSK و فرکانسی خطی LFM بهتر می‌شوند [8] و ترکیبی از مدولاسیون فرکانسی FSK و تغییر فاز^{۱۰} PSK نیز گزارش شده است [9]. این مدولاسیون عمدی در پالس‌های پیچیده و ترکیبی تهدیدی جدی برای گیرنده‌های رهگیر جنگ الکترونیک مدرن هستند.

۲- مدولاسیون‌های ترکیبی راداری

در این زیر بخش به تشریح مدولاسیون‌های درون پالسی ترکیبی که موضوع اصلی این مقاله می‌باشد پرداخته خواهد شد.

۱-۱- مدولاسیون FSK-LFM

یک ویژگی معمول سیگنال مدولاسیون ترکیبی این است که یک سیگنال تک پالس به چند زیر پالس تقسیم می‌شود. هر زیر پالس فرکانس حامل متفاوت دارد. به عبارت دیگر، سیگنال FSK-LFM، یک مدولاسیون فرکانس خطی است که فرکانس‌های زیر پالس آن‌ها دارای سیگنال‌های مدولاسیون FSK است و سیگنال FSK-BPSK، یک سیگنال مدولاسیون ترکیبی^{۱۱} BPSK است که زیر پالس آن‌ها دارای سیگنال‌های مدولاسیون FSK است که از طریق این راه، اطلاعات

⁷ Discrete phase coded

⁸ Linear frequency modulation

⁹ frequency-shift keying

¹⁰ Phase-shift keying

¹¹ Binary Phase-shift keying

¹ Intentional modulation on pulse

² Unintentional modulation on pulse


³ Low probability of intercept

⁴ Cognitive radar

⁵ Waveform-agile radar

⁶ Multiple-input Multiple-output

می‌شود. در شکل ۳ نمایش فرکانس لحظه‌ای IF مدولاسیون ترکیبی بالا نشان داده شده است:



شکل ۳- نمایش فرکانس لحظه‌ای مدولاسیون ترکیبی FSK-BPSK [12].

Nandi و *Azzouz*، در دهه ۱۹۹۰، چند ویژگی کلیدی مبتنی بر طیف سیگنال را برای طبقه‌بندی مدولاسیون‌های آنالوگ و دیجیتال پیشنهاد کردند. [11] این ویژگی‌های کلیدی، با کارهای *Lopes*، *Fabrizi* و *Doroslovacki*، *Jovanovic* و *Gadbois* [12] و *Lockhart*، *Chan* و *Dragosevic* [13] تعمیم‌یافته و پیشرفته‌تر شدند. این محققان، روش‌های متفاوتی را برای استخراج ویژگی پیشنهاد کرده بودند. ویژگی‌ها، از خصوصیات طیفی منحصر به فرد مدولاسیون‌های سیگنال مختلف، در سه جنبه کلیدی سیگنال به دست آمده‌اند؛ یعنی جنبه‌های دامنه، فاز و فرکانس. از آنجایی که مدولاسیون‌های سیگنال مختلف، ویژگی‌های متفاوتی را در دامنه، فاز و فرکانس خود نشان می‌دهند، مجموعه کاملی از مدولاسیون‌های مورد نظر را می‌توان به مجموعه‌ها و زیرمجموعه‌هایی تقسیم کرد که بر اساس مؤثرترین ویژگی‌های خود از هم متمایز شده‌اند.

۳-۱- ویژگی‌های مبتنی بر طیف سیگنال

در این بخش به معرفی و بررسی ویژگی‌های مبتنی بر طیف سیگنال می‌پردازیم و رفتارهای هریک از مدولاسیون‌ها را برای هر ویژگی مشاهده خواهیم نمود.

۳-۱-۱- ویژگی بیشینه چگالی توان طیفی

اولین ویژگی، یعنی γ_{max} ، مقدار بیشینه چگالی توان طیفی دامنه لحظه‌ای متمرکز و نرمالیزه شده سیگنال دریافتی می‌باشد که اندازه‌ی خروجی این ویژگی برای مدولاسیون‌های دامنه و فاز خیلی بزرگ‌تر از مدولاسیون‌های فرکانسی به دست خواهد که این موضوع در ادامه با بررسی رفتار چند مدولاسیون بررسی خواهد شد.

$$\gamma_{max} = \max |DFT(A_{cn})|^2 / N \quad (4)$$

در معادله (۱۴)، $DFT(-)$ ، تبدیل فوریه گسسته بوده و A_{cn} ، دامنه لحظه‌ای متمرکز و نرمالیزه شده سیگنال دریافتی \mathbf{r} می‌باشد. N ، تعداد کل نمونه سیگنال‌ها را نشان می‌دهد. نرمالیزاسیون، با استفاده از معادله (۱۷) انجام می‌گیرد:

$$A_{cn}[n] = A_n[n] - 1. \quad A_n[n] = \frac{a[n]}{\mu_A} \quad (5)$$

در معادله بالا، μ_A ، میانگین دامنه لحظه‌ای یک بخش از سیگنال است که با معادله (۶) تعریف می‌شود:


$$\mu_A = \frac{1}{N} \sum_{n=1}^N A[n] \quad (6)$$

کمیت γ_{max} ، واریانس در دامنه لحظه‌ای سیگنال را اندازه می‌گیرد. برای مدولاسیون‌هایی که در آن‌ها، اطلاعات در دامنه سیگنال منتقل می‌شوند، γ_{max} مقدار غیر صفر را به خود اختصاص می‌دهد. از طرف دیگر، برای مدولاسیون‌هایی که دامنه ثابت دارند، مقدار γ_{max} مقدار نزدیک به صفر را اتخاذ می‌کند.

۳-۲- مدولاسیون ترکیبی LFM-BPSK

$$s(t) = \sum_{n=1}^N A \exp \{ j2\pi ft^2 + \varphi_n \} \quad (3)$$


که در اینجا $\varphi_n = [0, \pi]$ تابع فاز کد شده است که در این مقاله از مدولاسیون فازی بارکر با طول ۱۳ به عنوان مدولاسیون فازی استفاده شده است. شکل ۴ مدولاسیون ترکیبی LFM-BPSK نشان داده شده است.



شکل ۴- نمایش فرکانس لحظه‌ای مدولاسیون ترکیبی LFM-BPSK

۳- روش تحقیق

با تحلیل ماهیت این تکنیک مدولاسیون، می‌توان به راحتی ویژگی‌های کلیدی یک سیگنال که با استفاده از یک طرح مدولاسیون خاص مدوله شده را شناسایی کرد. در عین حال که طبقه‌بندی کننده‌های مبتنی بر اصول نظری، دقت فوق‌العاده بالایی در طبقه‌بندی‌ها دارند، اما پیچیدگی محاسباتی زیاد آن‌ها باعث شده محققان به دنبال ساخت طبقه‌بندی کننده‌های مبتنی بر ویژگی باشند. این طبقه‌بندی کننده‌ها، با نیاز به محاسبات بسیار کمتر، می‌توانند عملکرد تقریباً بهینه‌ای داشته باشند. در این بخش ویژگی‌های مبتنی بر طیف را بررسی می‌کنیم که از خصوصیات طیفی مؤلفه‌های مختلف سیگنال بهره می‌برند.



شکل ۶- ویژگی γ_{max} برای مدولاسیون‌های راداری

۳-۱-۳- تقارن طیف حول فرکانس حامل

چهارمین ویژگی، یعنی P ، تقارن طیف حول فرکانس حامل را ارزیابی می‌کند. معادله (۸) را ببینید:

$$P = \frac{P_L - P_U}{P_L + P_U} \quad (۸)$$

معادله‌های (۹) و (۱۰) در معادله بالا صدق می‌کنند:

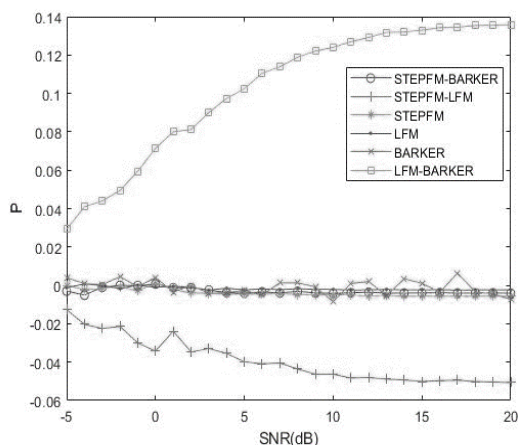
$$P_L = \sum_{n=1}^{f_{cn}} |X_c[n]|^2 \quad (۹)$$

$$P_U = \sum_{n=1}^{f_{cn}} |X_c[n + f_{cn} + 1]|^2 \quad (۱۰)$$

عبارت $X_c[n]$ ، تبدیل فوریه سیگنال $x_c[n]$ بوده و $f_{cn} + 1$ تعداد نمونه‌های متناظر با فرکانس حامل f_c می‌باشد. f_s ، نرخ نمونه‌برداری را نشان می‌دهد که در معادله (۱۱) تعریف شده است:


$$f_{cn} = \frac{f_c N}{f_s} - 1 \quad (۱۱)$$

در شکل زیر ویژگی P بر روی مدولاسیون‌های مختلف بررسی شده است:



شکل ۷- ویژگی γ_{max} برای مدولاسیون‌های راداری

طبق شکل ۷ استفاده از ویژگی P برای تفکیک مدولاسیون‌های STEPFM-LFM و LFM-BARKER از سایر مدولاسیون‌ها



شکل ۵- ویژگی γ_{max} برای مدولاسیون‌های راداری

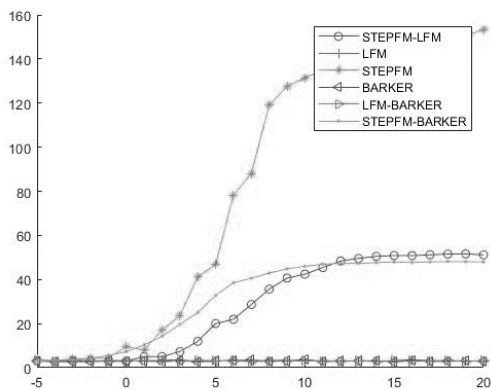
همان‌طور که اشاره شد ویژگی γ_{max} برای تفکیک مدولاسیون‌های فرکانس از سایر مدولاسیون‌ها می‌باشد و در شکل ۵ نیز مشاهده می‌شود که سه مدولاسیون فرکانسی یعنی مدولاسیون‌های LFM و STEPFM و ترکیب این دو یعنی مدولاسیون STEPFM-LFM نیز از سایر مدولاسیون‌ها به‌وضوح قابل جداسازی است.

۳-۱-۲- ویژگی انحراف استاندارد قدر مطلق مؤلفه غیرخطی فاز لحظه‌ای σ_{ap}

$$\sigma_{ap} = \frac{\frac{1}{N_c} \left(\sum_{A_n[n] > A_t} \phi_{NL}^2[n] \right) - \left(\frac{1}{N_c} \sum_{A_n[n] > A_t} |\phi_{NL}[n]| \right)^2}{2} \quad (۷)$$

در معادله (۷)، N_c ، تعداد نمونه‌هایی است که در شرط $A_n[n] > A_t$ صدق می‌کنند. متغیر A_t ، یک مقدار آستانه است که نمونه‌های سیگنال با دامنه کم را فیلتر می‌کند. زیرا آن‌ها در برابر نویزها بسیار حساس هستند. عبارت $\phi_{NL}[n]$ ، به مؤلفه غیرخطی فاز لحظه‌ای نمونه سیگنال n ام اشاره دارد. کمیت σ_{ap} ، واریانس در قدر مطلق فاز لحظه‌ای را اندازه می‌گیرد. مدولاسیون‌ها دو فازه مثل BPSK، هیچ اطلاعاتی در فاز لحظه‌ای مطلق (متمرکز) خود ندارد زیرا فقط دو حالت برای فاز لحظه‌ای وجود دارد وقتی فازهای لحظه‌ای در صفر متمرکز می‌شوند، قدر مطلق آن یکسان هستند. شکل ۶ رفتار σ_{ap} برای مدولاسیون‌های مختلف را نشان می‌دهد. با توجه به شکل ۶ و آنچه اشاره شد از ویژگی σ_{ap} برای تفکیک مدولاسیون BPSK از سایر مدولاسیون‌ها استفاده می‌گردد. برای مدولاسیون‌های راداری نیز این ویژگی برای تفکیک مدولاسیون BARKER که به‌نوعی از خانواده BPSK محسوب می‌شود، کاربرد دارد.

به خوبی قابل مشاهده و کارایی این ویژگی حتی برای SNR های پایین نیز مؤید این مطلب است.



شکل ۱۰ - ویژگی μ_{42}^{IFR} برای مدولاسیون های راداری

۴-۱- درخت تصمیم گیری

درخت تصمیم گیری یک ابزار برای پشتیبانی از تصمیم است که از درخت ها برای مدل کردن استفاده می کند. درخت تصمیم به طور معمول در تحقیق ها و عملیات مختلف استفاده می شود. به طور خاص در آنالیز تصمیم، برای مشخص کردن استراتژی که با بیشترین احتمال به هدف برسد بکار می رود. استفاده دیگر درختان تصمیم، توصیف محاسبات احتمال شرطی است. یکی دیگر از موارد استفاده از درخت تصمیم، در علم داده کاوی برای طبقه بندی است.

۴-۲- الگوریتم ساخت درخت تصمیم گیری

مجموع داده ها را با D نمایش می دهیم، یعنی $D = (x_1, y_1), \dots, (x_i, y_i), \dots, (x_n, y_n)$ ، به قسمی که $x_i \in R^d$ و $y_i \in R$. درخت تصمیم گیری سعی می کند به صورت بازگشتی داده ها را به قسمی از هم جدا کند که در هر گره متغیرهای مستقل y به هم نزدیک شده همسان شوند [14]. هر گره زیرمجموعه ای از داده ها است که به صورت بازگشتی ساخته شده است. به طور دقیق تر در گره m داده ما Q باشد می کنیم یک بعد از متغیرهایی وابسته را به همراه یک آستانه انتخاب کنیم و داده ها را برحسب این بعد و آستانه به دو نیم تقسیم کنیم، به قسمی که به طور متوسط در هر دو نیم متغیرهای مستقل y خیلی به هم نزدیک و همسان شده باشند. این بعد و آستانه $\theta = (j, t_m)$ را می نامیم. دامنه j برابر با $[1, \dots, d]$ و t_m یک عدد صحیح است. Q برحسب $\theta = (j, t_m)$ به دو بخش $Q_{left}(\theta)$ و $Q_{right}(\theta)$ به شکل پایین تقسیم می شود. [14]

$$Q_{left}(\theta) = \{(x_i, y_i) \in Q | x_{ij} \leq t_m\} \quad (13)$$


$$Q_{right}(\theta) = \{(x_i, y_i) \in Q | x_{ij} > t_m\} \quad (14)$$

حال سؤال اینجاست که کدام بعد از متغیرهای وابسته و چه آستانه ای را باید انتخاب کرد. به زبان ریاضی باید آن θ یی را انتخاب کرد که ناخالصی داده را کم کند. ناخالصی برحسب نوع مسئله تعریفی متفاوت خواهد داشت، مثلاً اگر مسئله یک طبقه بندی دوگانه است، ناخالصی


۳-۱-۴- ویژگی کشیدگی نقطه اوج نرخ فرکانس لحظه ای μ_{42}^{IFR}
نرخ فرکانس لحظه ای (IFR) مشتق دوم فاز سیگنال است که می تواند به صورت معادله (۱۲) بیان شود:

$$IFR(t) \triangleq \frac{1}{2\pi} \frac{d^2 \phi(t)}{dt^2} \quad (12)$$

در ادامه تغییرات IFR در مدولاسیون های مختلف مشاهده می شود:



شکل ۸- تغییرات IFR مدولاسیون Barker



شکل ۹- تغییرات IFR مدولاسیون STEPFM

طبق شکل های ۸ و ۹ تغییرات ناگهانی وقتی اتفاق خواهد افتاد که در طول یک پالس فرکانس های مختلف داشته باشند و دامنه تغییر ناگهانی بستگی به اختلاف دو فرکانس مجاور دارد. در ادامه مشاهده خواهد شد این ویژگی منجر به تفکیک با دقت خوب مدولاسیون های فرکانسی STEPFM و مدولاسیون های STEPFM-Barker و STEPFM-LFM از سایر مدولاسیون ها خواهد شد. شکل ۱۰ رفتار ویژگی μ_{42}^{IFR} برای هر یک از مدولاسیون های مورد مطالعه در این مقاله نشان می دهد.

۴- روش های طبقه بندی مدولاسیون

در ادامه ابتدا به مبانی هر یک از سه روش طبقه بندی خواهیم پرداخت و پس از آن به مقایسه هر سه روش در طبقه بندی مدولاسیون های راداری و بررسی نتایج خواهیم پرداخت.

می‌تواند آنتروپی داده باشد، کمترین ناخالصی زمانی است که هم $Q_{left}(\theta)$ و $Q_{right}(\theta)$ هم از یک طبقه داشته باشند، یعنی در هر کدام از این دو گره دو نوع طبقه وجود نداشته باشد. برای رگرسیون این ناخالصی می‌تواند واریانس متغیر وابسته باشد. از آنجاکه مقدار داده در و باهم متفاوت است میانگینی وزن دار از هر دو ناخالصی را به شکل پایین محاسبه می‌کنیم [26] در این معادله:

$$n_{right} = \left| Q_{right}(\theta) \right| \cdot n_{left} \left| Q_{left}(\theta) \right|$$

$$N_m = |Q|$$

$$G(Q, \theta) = \frac{n_{left}}{N_m} H(Q_{left}(\theta)) + \frac{n_{right}}{N_m} H(Q_{right}(\theta)) \quad (15)$$

هدف در اینجا پیدا کردن آن θ است که ناخالصی را کمینه کند، یعنی $\theta^* = \operatorname{argmin}_{\theta} G(Q, \theta)$ حال همین کار را به صورت بازگشتی برای $Q_{left}(\theta)$ و $Q_{right}(\theta)$ انجام می‌دهیم. بعضی از گره‌ها را باید به برگ تبدیل کنیم، معیاری که برای تبدیل یک گره به برگ از آن استفاده می‌کنیم می‌تواند مقداری حداقلی برای N_m (تعداد داده در یک گره) و یا عمق درخت باشد به قسمی که اگر با دونیم کردن گره یکی از معیارها عوض شود، گره را به دونیم نکرده آن را تبدیل به یک برگ می‌کنیم. معمولاً این دو پارامتر باعث تنظیم مدل می‌شوند [15] در ابتدای کار گره شامل تمام داده‌ها می‌شود یعنی $Q = D$.

۴-۳- طبقه‌بندی کننده K نزدیک‌ترین همسایه

طبقه‌بندی کننده نزدیک‌ترین همسایه (KNN)، یک الگوریتم غیر پارامتری است که با تحلیل k عدد از نزدیک‌ترین سیگنال‌های مرجعی که در فضای ویژگی‌ها وجود دارند، یک کلاس را به یک سیگنال آزمایشی اختصاص می‌دهد. این طبقه‌بندی کننده، برای حل بسیاری از مسائل طبقه‌بندی به کاررفته است [16-18]. سه مرحله اصلی در طبقه‌بندی کننده KNN وجود دارد.

۴-۴- فضای ویژگی مرجع

برای انجام طبقه‌بندی KNN، ابتدا باید یک فضای ویژگی مرجع ساخت. این فضای ویژگی، باید مقادیر مرجع M مربوط به هر ویژگی از هر کلاس مدولاسیون را در برگیرد. انتخاب M ، به مسئله بستگی دارد و طبیعتاً، با روش آزمون و خطا بهینه می‌شود. دلیل استفاده از مقادیر M بزرگ‌تر، آن است که فضای ویژگی مرجع، نمایش دقیق‌تری از توزیع احتمال ویژگی‌های سیگنال آزمایشی ما به دست دهد. از طرف دیگر، اگر مقدار M بزرگ‌تر باشد، پیچیدگی محاسباتی بیشتری در مراحل بدی طبقه‌بندی کننده KNN به وجود می‌آید. مزیت این روش، آن است که منبع سیگنال دنباله‌ای و سیگنال آزمایشی، یکسان است. بنابراین، فضای ویژگی مرجع، یک نمایش دقیق از توزیع ویژگی‌های سیگنال آزمایشی به دست می‌دهد. در عین حال، ساخت فضای ویژگی

مرجع، واقعاً آسان است. زیرا فقط کافی است مقادیر ویژگی‌ها برای سیگنال‌های دنباله‌ای، محاسبه شود. البته به دلیل ماهیت رندوم این سیگنال‌ها، نمی‌توان اطمینان یافت که دقت فضای ویژگی، به اندازه کافی بالاست. در طی ساخت فضای ویژگی مرجع، مقادیر مرجع ترکیبی را بهتر می‌توان تحت کنترل قرارداد در غیر این صورت، باید یک توزیع ویژگی فرضی وجود داشته باشد که اغلب هم غیرقابل اطمینان است.

۴-۴-۱- تعریف فاصله

از آنجایی که این طبقه‌بندی کننده به ارزیابی فواصل میان سیگنال آزمایشی و سیگنال‌های مرجع نیاز دارد، باید پیش از جستجوی سیگنال‌های مرجع همسایه، یک معیار برای فاصله تعریف کنیم. سیستم‌های متریک زیادی وجود دارند که می‌توانند برای اندازه‌گیری فاصله در طبقه‌بندی کننده KNN به کار روند. فاصله اقلیدسی، یکی از رایج‌ترین معیارهای فاصله است که در طبقه‌بندی کننده‌های KNN به کار می‌رود. اگر یک مجموعه ویژگی به صورت

$$\mathbb{F} = \{\mathbb{F}_1 - \mathbb{F}_2 - \dots - \mathbb{F}_L\}$$

داشته باشیم که L عدد ویژگی را در خود جای داده باشد، آنگاه فاصله اقلیدسی میان مجموعه ویژگی‌های سیگنال‌های A و B با معادله ۱۶ محاسبه می‌شود:

$$D(\mathbb{F}(A)\mathbb{F}(B)) = \sqrt{\sum_{l=1}^L [\mathbb{F}_l(A) - \mathbb{F}_l(B)]^2} \quad (16)$$

با اندازه‌گیری فاصل، پس از پیدا کردن k عدد از نزدیک‌ترین نمونه‌های مرجع و تحلیل دموگرافی حاصل از این k عدد نمونه، تصمیم‌گیری در مورد طبقه‌بندی انجام می‌شود.

۴-۴-۲- تصمیم‌گیری در مورد k نزدیک‌ترین همسایه

وقتی فواصل میان سیگنال آزمایشی و همه سیگنال‌های مرجع ارزیابی شد، تعداد k عدد سیگنال مرجع را به عنوان k نزدیک‌ترین همسایه ثبت می‌کنیم - انتخاب مقدار k باید از قوانین زیر پیروی کند:

- این مقدار باید به شکل ایده آلی یک عدد اول باشد؛ تا به این ترتیب، مجموعه k همسایه، از تعداد برابری سیگنال مرجع از کلاس‌های متفاوت تشکیل نشود.
- این مقدار باید کمتر از تعداد کل سیگنال‌های مرجع به دست آمده از یک کلاس سیگنال باشد.
- مقدار k باید به اندازه کافی بزرگ باشد تا از طبقه‌بندی نادرست ناشی از طرح‌ها، جلوگیری شود.

بهینه‌سازی واقعی مقدار k ، از طریق آزمون و خطا انجام می‌شود. زیرا اگر مقدار k در یک طیف معقول و منطقی قرار بگیرد، نتیجه طبقه‌بندی،


$$g(x) = x^T w + w_0 \quad (17)$$

تفاوت چندانی نخواهد داشت. نتیجه نهایی طبقه‌بندی، با پیدا کردن اکثر k نزدیک‌ترین همسایه‌ای که به یک کلاس تعلق دارند، به دست

کننده SVM، همین فرآیند طبقه‌بندی و دنباله را طی می‌کند؛ با این تفاوت که در آن، هسته به کاررفته برای هایپرپلان، با یک هسته غیرخطی جایگزین شده است. هسته چندجمله‌ای را با معادله زیر مشخص می‌کنیم:

$$K(x, w) = (x^T w)^d \quad (22)$$

در این معادله، d ، درجه چندجمله‌ای هاست.



شکل ۱۱- فضای ویژگی دو کلاسی، با ماشین برداری پشتیبانی خطی

اگر طبقه‌بندی کننده SVM را با طبقه‌بندی کننده KNN مقایسه کنیم، می‌بینیم که مورد اول، در هنگام تشکیل یک هایپرپلان جداکننده، فقط به استفاده از سیگنال دنباله نیاز دارد. زمانی که این هایپرپلان بهینه شد، هیچ نیازی به استفاده از سیگنال دنباله در هیچ بخشی از محاسبات بعدی وجود ندارد. مزیت طبقه‌بندی کننده SVM، آن است که محاسبات موردنیاز در مرحله آزمایشی، در مقایسه با طبقه‌بندی کننده KNN نسبتاً کم‌هزینه می‌باشد. طبقه‌بندی کننده SVM، طبیعی‌ترین مورد برای طبقه‌بندی دو کلاسی است. مواردی هم مشاهده شده که در آن‌ها، از SVM برای طبقه‌بندی چند کلاسی استفاده می‌شود.

۴-۶- مقایسه روش‌های طبقه‌بندی مدولاسیون و بررسی نتایج در این بخش با به‌کارگیری هر سه روش فوق و مقایسه آن‌ها در طبقه‌بندی شش مدولاسیون موردبحث در این مقاله می‌پردازیم. روش کار بدین گونه است که با ساخت هر سیگنال به‌صورت آزمایشگاهی با پارامترهایی که قبلاً به آن اشاره شده است و در جدول ۲ قابل مشاهده می‌باشد و با استفاده از هر سه روش طبقه‌بندی مدولاسیون به تعیین سطوح آستانه می‌پردازیم. با تکرار ۱۰۰۰ آزمایش به ازای هر مدولاسیون در هر سطح SNR دقت فرآیند طبقه‌بندی بالا رفته است. در ادامه نتایج آزمایش‌ها به‌طور کامل قابل مشاهده می‌باشد.

جدول ۱ - مدولاسیون‌های مورد آزمایش در این مقاله

نام مدولاسیون	خانواده مدولاسیون‌ها
LFM, STEPFM	فرکانسی
BARKER	فازی
LFM-BARKER LFM-STEPFM STEPFM-BARKER	ترکیبی

می‌آید. این کلاس، به‌عنوان نتیجه طبقه‌بندی، به سیگنال آزمایشی نسبت داده می‌شود. KNN، یک طبقه‌بندی کننده غیر پارامتری است که توانایی طبقه‌بندی چند کلاس را دارد. اما از افزایش تعداد ویژگی‌های رنج می‌برد! این امر باعث می‌شود ابعاد فضای ویژگی افزایش یابد و پیچیدگی محاسبه فاصله بیشتر شود. بنابراین، لازم است ابعاد فضای ویژگی به نحوی کاهش یابد تا این روش، به روشی مناسب تبدیل گردد. یکی دیگر از نقطه‌ضعف‌های طبقه‌بندی کننده KNN، آن است که سهم ویژگی‌ها در تصمیم‌گیری در مورد طبقه‌بندی، توزین نشده است. بنابراین، یک ویژگی با توزیع نسبتاً پراکنده میان مدولاسیون‌های مختلف، ممکن است در فرآیند ارزیابی فاصله غالب باشد و به‌این ترتیب، ممکن است طبقه‌بندی برخی از مدولاسیون‌ها که انجام آن به ویژگی‌های دیگر متکی است، تحت تأثیر این غلبه قرار بگیرد.

۴-۵- طبقه‌بندی کننده ماشین بردار پشتیبانی

ماشین بردار پشتیبانی SVM راه دیگری برای طبقه‌بندی در فضای ویژگی چندبعدی است. این روش، برای طبقه‌بندی مجموعه داده‌های متعدد و مختلفی به کاررفته است [19-20]. روش SVM با یافتن هایپرپلانی که داده‌های مربوط به کلاس‌های مختلف را از هم جدا می‌کند، به طبقه‌بندی می‌پردازد. درعین حال، با حداکثر سازی فاصله این هایپرپلان تا نمونه‌های سیگنالی که در هر طرف آن قرار دارند، آن را بهینه می‌کند. بسته به ماهیت سیگنالی که باید طبقه‌بندی شود، طبقه‌بندی کننده‌های SVM را می‌توان به دو نسخه خطی و غیرخطی تقسیم کرد. طبقه‌بندی کننده SVM خطی، دارای هسته‌های خطی است. این هسته‌ها، با معادله (۱۸) تعریف می‌شوند:

$$K(x, w) = x^T w \quad (18)$$

در این معادله، $x = [x_1, x_2, \dots, x_K]$ ، بردار ویژگی ورودی \mathbb{F} و $\{w_1, w_2, \dots, w_K\}$ بوده و $w = [w_1, w_2, \dots, w_K]$ بردار وزنی است که باید بهینه شود. این هسته، یک هایپرپلان خطی جداکننده تعریف می‌کند [22]

که w_0 یک ثابت است. طبقه‌بندی یک مسئله دو کلاسی (بین مدولاسیون‌های کاندیدی $\mathcal{M}(a)$ و $\mathcal{M}(b)$)، تنها با استفاده از علامت $g(x)$ و به‌صورت که در معادله (۳۱) می‌بینید، به دست می‌آید:

$$\hat{\mathcal{M}} = \begin{cases} \mathcal{M}(a), & g(x) = x^T w + w_0 \geq 0 \\ \mathcal{M}(b), & g(x) = x^T w + w_0 < 0 \end{cases} \quad (19)$$

اگر بخواهیم از طریق دنباله، وزن‌ها را به دست آوریم، فرآیند بهینه‌سازی زیر را دنبال می‌کنیم:

$$\text{Max } J(w, w_0) = \frac{2}{\|w\|^2} \quad (20)$$

به طوری که داشته باشیم:

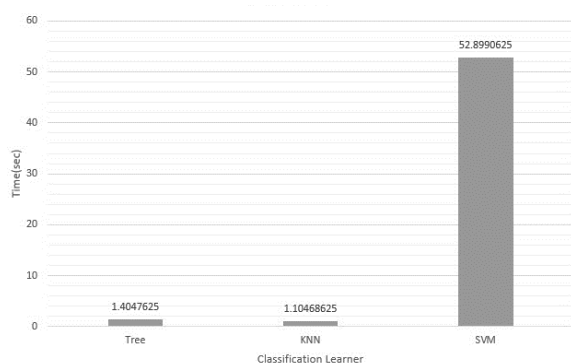
$$y_i (w^T x_i + w_0) \geq 1, \quad i = 1, 2, \dots, N \quad (21)$$

در این معادله، y_i نشانگر کلاس مربوط به بردار ویژگی i ام است (+1) برای $\mathcal{M}(a)$ و -1 برای $\mathcal{M}(b)$ نمایش SVM مربوط به یک مسئله دو کلاسی، در شکل ۱۱ ارائه شده است. نسخه غیرخطی طبقه‌بندی


جدول ۲ - مدولاسیون‌های مورد آزمایش در این مقاله

تکرار آزمایش به ازای هر مدولاسیون	1000
فرکانس نمونه‌برداری	1 MHz
فرکانس حامل	250KHz
پهنای باند	200KHz
طول فرکانس فازی	13
سیگنال به نویز	[-5, 10] db
k-Fold Cross Validation	30

بالاتری در مرحله تشخیص و آزمون مدولاسیون‌ها در مقایسه با روش‌های دیگر می‌باشد.



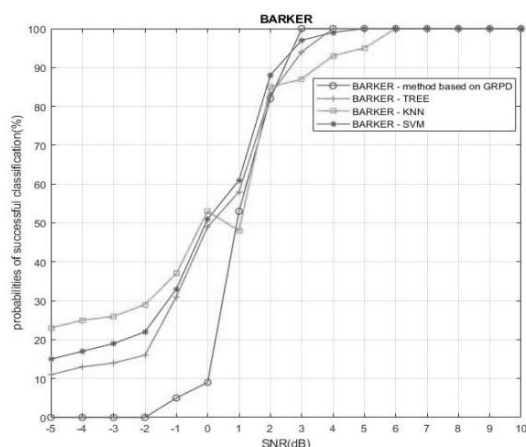
شکل ۱۳- عملکرد کلی هر سه روش طبقه‌بندی از نظر زمان یادگیری



شکل ۱۴- عملکرد کلی هر سه روش طبقه‌بندی از نظر سرعت آزمون و تشخیص


۴-۷- ارزیابی بر اساس احتمال طبقه‌بندی موفقیت‌آمیز مدولاسیون

در این مرحله از ارزیابی، به مقایسه هر سه روش مورد مطالعه در این مقاله و مقاله [23] خواهیم پرداخت. به این صورت که برای هر شش مدولاسیون راداری و در ۱۶ حالت نویزی مختلف $SNR = [-5, 10]$ هر سه روش مورد بحث این مقاله و روش GRPD با یکدیگر مقایسه گردیده و نتایج آن به صورت نمودارهای ذیل آورده شده است.



شکل ۱۵-مقایسه روش پیشنهادی مقاله و مقاله [23] احتمال طبقه‌بندی موفقیت‌آمیز در مدولاسیون BARKER

در این مقاله ارزیابی روش‌های پیشنهادی به دو صورت خواهد بود ارزیابی اول بر اساس مدت‌زمان طبقه‌بندی خواهد بود به این صورت که هر سه روش طبقه‌بندی بر اساس مدت‌زمان طبقه‌بندی با یکدیگر مقایسه خواهند که کدام روش از نظر مدت‌زمان یادگیری و آزمون بهینه خواهد بود. بدیهی است که در این مرحله از ارزیابی اطلاعات سه روشی که در این مقاله مورد بحث قرار گرفته موجود می‌باشد و اطلاعات زمانی مقاله [23] که مرجع قابل مقایسه با روش‌های این مقاله می‌باشد وجود ندارد. ارزیابی دوم، ارزیابی بر اساس احتمال طبقه‌بندی موفقیت‌آمیز مدولاسیون^۱ خواهد بود. در ادامه به هر دو روش ارزیابی خواهیم پرداخت. نتایج ارزیابی زمانی طبق شرایط ارزیابی جدول ۱ و جدول ۲ به ازای هر شش مدولاسیون راداری به صورت زیر دست آمده است:




شکل ۱۲-مقایسه مدت‌زمان یادگیری جهت طبقه‌بندی با هر سه روش Tree, KNN, SVM در $SNR = [-5, 10]$


طبق شکل ۱۲ هر شش مدولاسیون مورد مطالعه با هر سه روش طبقه‌بندی مورد ارزیابی زمانی قرار گرفتند که مشاهده شد که مدت‌زمان یادگیری مورد نیاز برای طبقه‌بندی با روش SVM بسیار بیشتر از دو روش KNN و Tree خواهد بود و در نتیجه روش SVM از نظر زمانی بهینه و مورد مطلوب ما نخواهد بود. عملکرد کلی این سه روش از نظر زمانی در شکل زیر قابل مشاهده می‌باشد. طبق شکل ۱۳ مشاهده می‌کنیم که روش KNN با اختلاف زیادی از روش SVM و با اختلاف کمی از روش Tree روشی بهینه‌تر از نظر زمانی خواهد بود. در شکل ۱۴ عملکرد هر سه روش طبقه‌بندی بر اساس سرعت آزمون طبقه‌بندی مشاهده می‌شود. طبق شکل بالا روش TREE دارای سرعت بسیار

¹ probabilities of successful modulation classification

موفقیت‌آمیز بهتری نسبت به سایر روش‌ها خصوصاً روش GRPD می‌باشد.

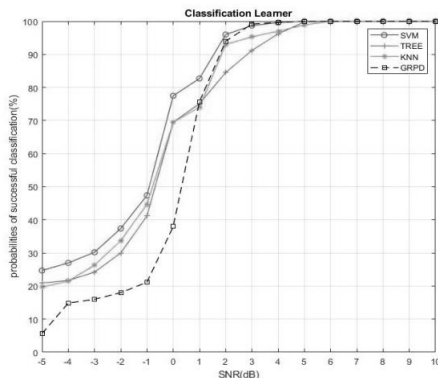


شکل ۱۸- مقایسه روش پیشنهادی مقاله و مقاله [23] احتمال طبقه‌بندی موفقیت‌آمیز در مدولاسیون STEPFM-BARKER




شکل ۱۹- مقایسه روش پیشنهادی مقاله و مقاله [23] احتمال طبقه‌بندی موفقیت‌آمیز در مدولاسیون STEPFM-LFM

طبق شکل ۱۹ احتمال طبقه‌بندی موفقیت‌آمیز در مدولاسیون STEPFM-LFM برای هر چهار روش قابل مشاهده است. همان‌طور که می‌بینیم در این شکل طبقه‌بندی با روش SVM در SNR های پایین‌تر دارای احتمال طبقه‌بندی موفقیت‌آمیز بهتری نسبت به سایر روش‌ها خصوصاً روش GRPD می‌باشد. در ادامه عملکرد کلی هر چهار روش طبقه‌بندی از نظر احتمال طبقه‌بندی موفقیت‌آمیز در شکل ۲۰ قابل مشاهده می‌باشد.



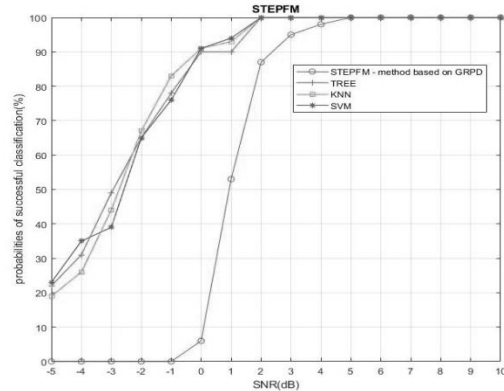
شکل ۲۰ - عملکرد کلی هر چهار روش طبقه‌بندی مدولاسیون‌های راداری از نظر احتمال طبقه‌بندی موفقیت‌آمیز

طبق شکل بالا احتمال طبقه‌بندی موفقیت‌آمیز در مدولاسیون BARKER برای هر چهار روش قابل مشاهده است. همان‌طور که می‌بینیم در این شکل طبقه‌بندی با روش KNN در SNR های پایین‌تر دارای احتمال طبقه‌بندی موفقیت‌آمیز بهتری است.



شکل ۱۶- مقایسه روش پیشنهادی مقاله و مقاله [23] احتمال طبقه‌بندی موفقیت‌آمیز در مدولاسیون LFM-BARKER

طبق شکل ۱۶ احتمال طبقه‌بندی موفقیت‌آمیز در مدولاسیون LFM-BARKER برای هر چهار روش قابل مشاهده است. همان‌طور که می‌بینیم در این شکل طبقه‌بندی با روش SVM در SNR های پایین‌تر دارای احتمال طبقه‌بندی موفقیت‌آمیز بهتری نسبت به سه روش دیگر خصوصاً روش GRPD است.



شکل ۱۷- مقایسه روش پیشنهادی مقاله و مقاله [23] احتمال طبقه‌بندی موفقیت‌آمیز در مدولاسیون STEPFM

طبق شکل ۱۷ احتمال طبقه‌بندی موفقیت‌آمیز در مدولاسیون STEPFM برای هر چهار روش قابل مشاهده است. همان‌طور که می‌بینیم در این شکل طبقه‌بندی با روش SVM در SNR های پایین‌تر دارای احتمال طبقه‌بندی موفقیت‌آمیز بهتری نسبت به هم می‌باشند ولی در مقایسه با روش GRPD عملکرد بسیار بهتر و بهینه‌تری هستند. طبق شکل ۱۸ احتمال طبقه‌بندی موفقیت‌آمیز در مدولاسیون STEPFM-BARKER برای هر چهار روش قابل مشاهده است. همان‌طور که می‌بینیم در این شکل طبقه‌بندی با روش SVM در SNR های پایین‌تر دارای احتمال طبقه‌بندی

۵- نتیجه گیری

مسئله اصلی در این مقاله طبقه‌بندی خودکار مدولاسیون‌های ترکیبی راداری بود که برای نیل به پاسخ این مسئله ابتدا به چپستی و تشریح روابط ریاضی و نموداری مدولاسیون‌های ترکیبی پرداخته شد در ادامه به‌طور مفصل به بیان و پیاده‌سازی ویژگی‌های مبتنی بر طیف که جهت طبقه‌بندی مدولاسیون‌های مخبراتی مورد استفاده قرار گرفته است [11] پرداختیم. ویژگی‌های مذکور در مورد مدولاسیون‌های راداری به کار گرفته شد و با مشاهده اثرات هر یک از این ویژگی‌ها منتج به معرفی یک ویژگی جدید برای طبقه‌بندی مدولاسیون‌های ترکیبی راداری شد. برای انتخاب روش بهینه جهت طبقه‌بندی مدولاسیون‌های ترکیبی از یادگیری ماشین و طبقه‌بندهای KNN و Tree و SVM استفاده شد که در ارزیابی زمانی Tree روشی بهینه و در بحث دقت و احتمال طبقه‌بندی موفق، روش SVM به مراتب بهتری می‌باشد. برای محیط‌های نویزی با $SNR = -5$ احتمال طبقه‌بندی در مدولاسیون LFM-BARKER و با روش SVM به بالای ۳۵ درصد رسیده است که این مقدار در روش مقاله [23] برابر با صفر می‌باشد. به‌طور مشابه در مدولاسیون STEPFM-LFM در $SNR = -1$ احتمال طبقه‌بندی و تشخیص صحیح حدوداً ۲۰ درصد می‌باشد که این مقدار در روش مقاله [23] برابر صفر می‌باشد. همچنین برای مدولاسیون STEPFM-BARKER نیز در $SNR = -1$ احتمال طبقه‌بندی و تشخیص صحیح حدوداً ۵۰ درصد می‌باشد که این مقدار در روش مقاله [23] برابر ۱۰ درصد می‌باشد. برای مدولاسیون BARKER در $SNR = -5$ احتمال طبقه‌بندی و تشخیص صحیح در روش SVM به مقدار ۱۵ درصد و با روش KNN به مقدار ۲۳ درصد و با روش Tree نیز این مقدار ۱۱ درصد می‌باشد و این مقدار در روش مقاله [23] این مقدار برابر صفر است برای مدولاسیون STEPFM در $SNR = 0$ احتمال طبقه‌بندی و تشخیص صحیح در روش SVM به مقدار ۹۱ درصد و با روش KNN نیز به مقدار ۹۱ درصد و با روش Tree نیز این مقدار ۹۰ درصد می‌باشد و این مقدار در روش مقاله [23] این مقدار برابر ۱۰ درصد است در سایر شرایط نیز نتایج به مقدار قابل قبولی از مقاله مذکور بهتر می‌باشد. به‌طور کلی نتایج به دست آمده با روش‌های این مقاله در مقایسه با مقاله [23] خصوصاً در محیط‌های نویزی قوی‌تر، نتایج این پژوهش بهتر است.

۶- مراجع

- [4] Q. H. Z. H. S Wang, "LFM-based waveform design for cognitive MIMO radar with constrained bandwidth," EURASIP J. Adv. Signal Process, no. 89 (2014), 2014.
- [5] J. T. R. S. W Huleihel, "Optimal adaptive waveform," IEEE Trans. Signal Process, vol. 61(20), p. 5075–5089, 2013.
- [6] J. W. M Ngwar, "Phase Coded Linear Frequency Modulated Waveform for Low Cost Marine Radar System," IEEE Washington DC, p. pp.1044–1049, 2010.
- [7] D. Lynch, Introduction to RF Stealth, Releigh: SciTech Publishing, 2004.
- [8] H. R. M Kronauge, "New chirp sequence radar waveform," IEEE Trans, p. 2870–2877, 2014.
- [9] F. I. JA Lemieux, "Analysis of FSK/PSK Modulated Radar Signals Using Costas Arrays and Complementary Welfti Code," IEEE, p. pp. 589–594, 1990.
- [10] L.-L. W. X.-H. R. Q. H. Z. L. a. W.-L. J. Peng Xiong1, "A Novel Recognition Method For Hybrid Modulation Radar Signals," College of Electronic Science and Engineering, Vols. Changsha, Hunan, P.R. China, pp. 2-3, 2010.
- [11] A.-a.-. E.-E.-. N.-. A-K, "Procedure for automatic recognition of analogue and digital modulations," IEE Proceedings – Communications, vol. 143 (5), p. 259–266, 1996.
- [12] L. L. Fabrizi. P.M, " Receiver Recognition of Analogue Modulation Types," Proceedings of the IERE Conference on Radio Receiver and Associated Systems.IERE, pp. 135-140, 1986.
- [13] G. Chan.Y.T, "Identification of the modulation type of a signal," Signal Processing, vol. 1 (4), p. 838–841, 1989.
- [14] T. Hastie, R. Tibshirani and J. Friedman, "The Elements of Statistical Learning: Data Mining, Inference, and Prediction, Second Edition,," Springer Series in Statistics (2 ed.), 2009.
- [15] R. L. M. Oded, "Data Mining With Decision Trees: Theory and Applications," World Scientific Publishing Co., Inc., 2014.
- [16] H. a. N. A. Guo, "Breast cancer diagnosis using genetic programming generated features," Pattern Recognition, pp. 980-987, 2006.
- [17] H. Z. Q. a. N. A. Guo, "Feature Generation Using Genetic Programming Based on Fisher Criterion," European Signal Processing Conference, p. 1867–1871, 3 September 2007.
- [18] P. V. S. a. H. F. Espejo, "A survey on the application of genetic programming to classification," IEEE Transactions on Systems, Man, and Cybernetics, p. 121–144, 2010.
- [19] H. a. D. M. Mustafa, "Digital Modulation Recognition Using Support Vector," IEEE . Asilomar Conference on Signals, Systems and Computers, p. 2238–2242, 2004.
- [20] K. a. G. S. Polat, "Breast cancer diagnosis using least square support vector machine," Digital Signal Processing, pp. 694-701, 2007.
- [21] M. Akay, "Support vector machines combined with feature selection for breast cancer diagnosis," Expert Systems with Applications, p. 3240–3247, 2009.
- [22] S. Theodoridis, Pattern Recognition.4th edn, Boston: Academic Press, 2008.
- [23] Z. Q. J. Z. B. T. Pei Wang, "Autonomous radar pulse modulation classification using modulation components analysis," EURASIP Journal on Advances in Signal Processing, vol. 98, 2016.
- [1] P. Pace, Detecting and Classifying Low Probability of Intercept Radar, Norwood: Artech House, 2009.
- [2] S. Haykin, "Cognitive radar: a way of the future," IEEE Signal Process, no. 23(1), pp. 30-40, 2006.
- [3] Y. L. A. S. D. M. D. C. M. R. SP Sira, "Waveform-agile sensing for tracking," IEEE Signal Process. Mag, vol. 26(1), p. 53–64, 2009.