

جداسازی کور مدولاسیون‌های مخابراتی با استفاده از بردارهای ماشین تکیه‌گاه

سعید شعراف تبریزی، مرتضی خادمی و محمد مولوی کاخکی

اطلاعات از فرستنده سیگنال و غیره دخیل می‌باشند که نقش اساسی در عملکرد این سیستم ایفا می‌کنند. به همین دلیل است که مقایسه نتایج الگوریتم‌های مختلف تنها در شرایط کاملاً مشابه محیطی امکان‌پذیر است.

روش‌های تشخیص مدولاسیون را می‌توان به دو گروه عمده تقسیم کرد. در تکنیک اول که موسوم به روش‌های تصمیم‌گیری نظری^۱ است، اغلب برای طبقه‌بندی مدولاسیون از معیارهای آماری چون تخمین گر بیز [۱]، تخمین گر بیشترین شباهت [۲] و یا سطوح آستانه ثابت و متغیر بهره گرفته می‌شود [۳]. اما در تکنیک دوم، با نگاشت سیگنال به فضای ویژگی و با بهره‌گیری از مزایای الگوریتم‌های تشخیص الگو^۲ چون شبکه عصبی [۴]، عملیات تشخیص مدولاسیون صورت می‌گیرد.

در این مقاله هدف این است که با استفاده از ۹ ویژگی استخراج شده از سیگنال، بر مبنای تکنیک تشخیص الگوی آماری و بدون نیاز به هیچ‌گونه شناخت اولیه از پارامترهای فرستنده، ۹ مدولاسیون پرکاربرد مخابراتی شامل ۵ مدولاسیون دیجیتال ASK-۲، PSK-۲، FSK-۲، PAM-۴ و QAM-۱۶ و ۴ مدولاسیون آنالوگ AM، FM، DSB و SSB شناسایی شوند.

عملیات تشخیص در دو فاز صورت می‌گیرد. در مرحله اول، ۴ مدولاسیون دیجیتال ASK-۲، PSK-۲، PAM-۴ و QAM-۱۶ تنها با استفاده از یک ویژگی استخراجی از پوش سیگنال، توسط طبقه‌بندی‌کننده SVM از هم جدا می‌شوند و نتایج کار با طبقه‌بندی‌کننده بسیار متداول و پرکاربرد سطح آستانه‌ای [۵] مقایسه می‌گردد. در انتهای این مرحله، ساختار طبقه‌بندی‌کننده SVM با استفاده از الگوریتم ژنتیک و با دو معیار متفاوت بهینه‌شده و نتایج با ساختار اولیه غیر بهینه مقایسه می‌شود. ساختار معرفی شده در این مرحله در مقایسه با سایر روش‌های تشخیص مدولاسیون و در شرایط مشابه (که در آنها نیز از فرستنده هیچ شناختی نداریم) دقت تشخیص بالاتری داشته و برتری قابل توجهی بر این‌گونه تکنیک‌ها از خود نشان داده است.

در فاز دوم، تمامی ۹ مدولاسیون موجود در محیط، به وسیله ساختارهای سلسله مراتبی و غیر سلسله مراتبی از طبقه‌بندی‌کننده SVM تشخیص داده می‌شوند. در انتهای این مرحله نیز با انتخاب بهینه ویژگی در ساختار سلسله مراتبی با استفاده از الگوریتم ژنتیک، عملکرد طبقه‌بندی‌کننده و به تبع آن درصد تشخیص مدولاسیون‌ها بهبود می‌یابد. بلاک دیاگرام کلی نحوه عملکرد در شکل ۱ آمده است که در ادامه هر یک از بلوک‌ها جداگانه مورد بررسی قرار گرفته و به جزئیات شبیه‌سازی آنها اشاره خواهد شد.

چکیده: در این مقاله سیستمی برای تشخیص نوع مدولاسیون پیشنهاد می‌شود که قادر است بدون شناخت اولیه از پارامترهای سیگنال ارسالی، ۹ مدولاسیون از خانواده مدولاسیون‌های فاز، دامنه و فاز-دامنه را شناسایی کند. برای تشخیص، طبقه‌بندی‌کننده SVM پیشنهاد شده است. پیچیدگی محاسباتی کم، سرعت آموزش بالا و درصد تشخیص بالاتر نسبت به سایر روش‌های تشخیص مدولاسیون مانند سطوح آستانه ثابت و متغیر و شبکه‌های عصبی، از مزایای روش پیشنهادی به شمار می‌آیند. نتایج شبیه‌سازی نشان می‌دهد که استفاده از ساختارهای سلسله مراتبی از طبقه‌بندی‌کننده SVM نیز می‌تواند به بهبود عملکرد بیانجامد. در این مقاله، استفاده از الگوریتم ژنتیک در بهینه‌سازی ساختار طبقه‌بندی‌کننده و نیز انتخاب بهینه ویژگی‌های مورد استفاده در ساختار سلسله مراتبی، سبب افزایش قابل ملاحظه دقت تشخیص مدولاسیون‌ها گردیده است.

کلید واژه: الگوریتم ژنتیک، بردار ماشین تکیه‌گاه، تشخیص مدولاسیون، تشخیص الگو.

۱- مقدمه

شناسایی خودکار نوع مدولاسیون، مرحله‌ای بین آشکارسازی سیگنال و دمدولاسیون آن می‌باشد. این بخش، می‌تواند نوع مدولاسیون سیگنال دریافتی را در بین تعدادی مدولاسیون از پیش فرض شده، تشخیص دهد. شناسایی نوع مدولاسیون، کاربردهای فراوانی در زمینه‌های نظامی و غیر نظامی دارد که با گسترش حوزه مدولاسیون‌ها، به ویژه مدولاسیون‌های دیجیتال، اهمیت روزافزونی نیز یافته است. در بعد نظامی، تشخیص مدولاسیون می‌تواند در حالت کلی برای اهداف یک سیستم جنگ الکترونیک مفید باشد. کاربردهایی چون سیستم‌های تشخیص و تعیین هشدارهای الکترونیکی (به عنوان مثال سیگنال رادار موشک دشمن) و نیز طراحی سیستم‌های ایجاد تداخل، تنها گوشه‌ای از کاربردهای این دانش است. در بعد غیر نظامی می‌توان به کاربردهایی چون تأیید سیگنال، تأیید تداخل، مدیریت طیف، تشخیص فرستنده‌های غیر مجاز و سیستم‌های رادیویی نرم‌افزاری اشاره کرد.

در بررسی عملکرد یک سیستم شناساگر مدولاسیون، پارامترهای زیادی چون درصد موفقیت عملیات تشخیص، شرایط و نوع کانال، مجموعه مدولاسیون‌های موجود در محیط، وجود و یا عدم وجود

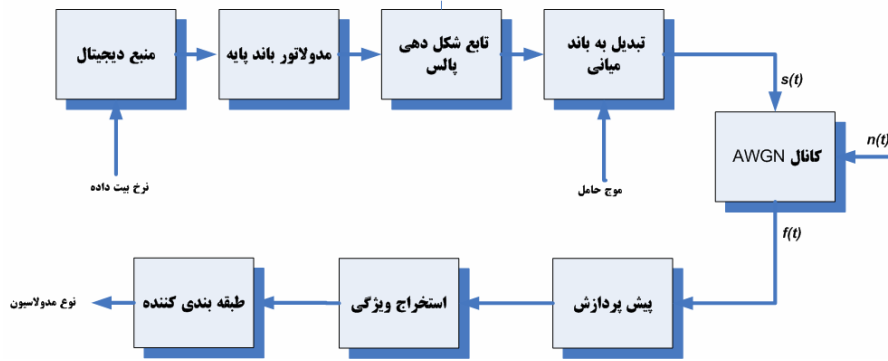
این مقاله در تاریخ ۱۰ مرداد ماه ۱۳۸۵ دریافت و در تاریخ ۳۱ مرداد ماه ۱۳۸۶ بازنگری شد.

سعید شعراف تبریزی، دانشکده مهندسی، دانشگاه فردوسی مشهد، مشهد (email: sa_sh13@um.ac.ir)

مرتضی خادمی، دانشکده مهندسی، دانشگاه فردوسی مشهد، مشهد (email: khademi@um.ac.ir)

محمد مولوی کاخکی، دانشکده مهندسی، دانشگاه فردوسی مشهد، مشهد (email: molavi@um.ac.ir)

1. Decision Theoretic
2. Pattern Recognition



شکل ۱: بلاک دیاگرام مراحل شبیه‌سازی الگوریتم تشخیص مدولاسیون.

است. سیگنال باند میانی $s(t)$ را در حالت کلی می‌توان با (۲) مدل‌سازی کرد

$$s(t) = A(t) \cos(\Phi(t)) \quad (2)$$

که در آن $A(t)$ دامنه لحظه‌ای، $\Phi(t) = 2\pi f_c t + \varphi(t) + \theta$ فاز اولیه حامل لحظه‌ای، f_c فرکانس حامل، $\varphi(t)$ زاویه لحظه‌ای و θ فاز اولیه حامل می‌باشد. در این مقاله تمامی پارامترهای ذکر شده از سیگنال ارسالی نامعلوم بوده و در صورت نیاز می‌بایست از روی سیگنال دریافتی $f(t)$ تخمین زده شوند.

۳- استخراج ویژگی

در همه مسائل مبتنی بر تشخیص الگو ابتدا می‌بایست عملیات استخراج ویژگی صورت پذیرد. ویژگی‌های استخراج شده باید نسبت به تغییرات سیگنال به نویز و اثرات ناشی از کانال کمترین حساسیت را دارا بوده و حتی‌الامکان از پیچیدگی محاسباتی کمی نیز برخوردار باشند. در این مقاله در فاز اول از یک ویژگی برای انجام عملیات تشخیص استفاده شده است. این ویژگی که به صورت مستقیم از روی پوش سیگنال استخراج می‌شود، دارای پیچیدگی محاسباتی بسیار کم بوده و به تنهایی توانایی جداسازی هر ۴ مدولاسیون مرحله اول را دارا می‌باشد. تعریف این ویژگی عبارتست از [۵]

$$J = \frac{E\{A^*(t)\} - 2E^*\{A^*(t)\}}{4s^2} \quad (3)$$

که در آن $A(t)$ دامنه لحظه‌ای سیگنال باند میانی دریافتی و s توان سیگنال ارسالی شده می‌باشد. مزیت اصلی این ویژگی این است که با توجه به نحوه تعریف آن، اثر نویز به صورت نظری کاملاً حذف شده و در عملیات تشخیص اثری نخواهد داشت. البته در شبیه‌سازی‌ها، فرض‌های نظری کاملاً برقرار نبوده و از همین رو نویز عامل مهمی در محاسبه دقت تشخیص و عملکرد سیستم خواهد بود.

برای محاسبه J به توان سیگنال ارسالی شده نیاز می‌باشد که با توجه به فرض مقاله در نامعلوم بودن پارامترهای سیگنال، می‌بایست از روی سیگنال دریافتی تخمین زده شود. برای تخمین توان سیگنال ارسالی از روش تجزیه مقدار تکین (SVD) ماتریس خودهمبستگی سیگنال استفاده شده است [۶]. این روش بر خلاف اغلب الگوریتم‌های موجود برای تخمین توان، نیازی به دانستن پارامترهای سیگنال ارسالی ندارد و می‌تواند برای تخمین توان هر سیگنال دارای پوش غیر ثابت در کانال AWGN به کار رود.

۲- مدل سیگنال

به منظور تحلیل عملکرد سیستم تشخیص مدولاسیون، به طور طبیعی نیازمند سیگنال‌هایی هستیم که از پیش نوع مدولاسیون آنها را می‌دانیم. این سیگنال‌ها می‌توانند به عنوان داده‌های آموزشی مورد استفاده قرار گیرند یا به عنوان داده‌های آزمایش، معیاری از عملکرد سیستم را به ما نشان دهند. عملیات تولید سیگنال به صورت مصنوعی و با استفاده از جعبه ابزار مخابرات نرم‌افزار MATLAB صورت گرفته است، اگرچه در برخی مقالات از منابع سیگنال آزمایشگاهی یا منابع سیگنال موجود در سایت‌های اینترنتی نیز استفاده شده است.

در این مقاله، شرایط تولید سیگنال و مقادیر پارامترهایی چون نرخ بیت، فرکانس نمونه‌برداری، فرکانس حامل، طول فریم ورودی و غیره را کاملاً مشابه [۵] انتخاب می‌کنیم تا امکان مقایسه عادلانه در فاز اول فراهم شود. برای شبیه‌سازی مدولاسیون‌های دیجیتال از یک رشته بیت تصادفی با نرخ بیت ۱۲/۵ کیلوهرتز مشابه [۵] استفاده شده است. رشته بیت مزبور به صورت تصادفی یکنواخت بوده و در مورد هر فریم مدوله‌شده حاوی پیام متفاوتی می‌باشد که کاملاً با کاربردهای عملی تطابق دارد. از آنجا که همواره در شرایط واقعی و نیز در شبیه‌سازی سیگنال‌ها با نمونه‌های گسسته سر و کار داریم، بنابراین مجبور به انجام عملیات نمونه‌برداری می‌باشیم. فرکانس نمونه‌برداری برابر ۱/۲ مگاهرتز می‌باشد [۵].

با وجود اینکه در اکثر مقالات تشخیص مدولاسیون، سیگنال‌های مدوله‌شده در باند پایه تولید و بررسی شده‌اند و بنابراین فرض دانستن فرکانس حامل به صورت ضمنی در همه آنها وجود دارد، در این مقاله به منظور تحقق فرض کوربودن اطلاعاتی، سیگنال‌ها را در باند میانی تولید نموده‌ایم. فرکانس حامل انتخاب شده، ۱۵۰ کیلوهرتز برای کلیه مدولاسیون‌ها بوده که منطبق با شرایط تولید سیگنال در [۵] می‌باشد.

کانال مخابراتی به صورت AWGN یعنی کانال حاوی نویز سفید گوسی جمع‌شونده، مدل شده که نسبت سیگنال به نویز کانال در همه شبیه‌سازی‌ها از ۵ dB تا ۲۰ dB متغیر فرض شده است. به این ترتیب، سیگنال تولیدشده نهایی، سیگنالی در باند میانی خواهد بود که با نویز گوسی سفید مخلوط شده و در حالی که هیچ اطلاعاتی از فرستنده آن در دست نیست، وارد بلاک گیرنده می‌گردد. هر سیگنال تولیدشده به صورت یک فریم زمانی با ۲۰۴۸ نمونه می‌باشد [۵].

سیگنال دریافتی باند میانی در حالت کلی به صورت (۱) است

$$f(t) = s(t) + n(t) \quad (1)$$

که $s(t)$ سیگنال ارسالی با مدولاسیون نامشخص و $n(t)$ نویز سفید گوسی جمع‌شونده با واریانس σ_n^2 و ناهمبسته با سیگنال فرض شده

جدول ۱: مقادیر تئوریک ویژگی استخراج‌شده اول.

۱	مدولاسیون	۲ASK	۴PAM	۱۶QAM	۲PSK
۲	J	۰	-۰.۳۷	-۰.۶۸	-۱

جدول ۲: ویژگی‌های استخراج‌شده برای فاز دوم.

ویژگی	توضیحات
R	نسبت واریانس دامنه لحظه‌ای به مجذور میانگین آن
P	تفاضل نرمال‌شده توان در کنار باندهای بالا و پایین سیگنال
r_{max}	ماکزیمم مقدار چگالی طیف توان در دامنه لحظه‌ای نرمال
r_{max-r}	ماکزیمم مقدار چگالی طیف توان در دامنه لحظه‌ای
σ_{aa}	انحراف معیار دامنه لحظه‌ای نرمال‌شده
$\sigma_{ aa }$	انحراف معیار مقدار مطلق دامنه لحظه‌ای نرمال
σ_{aa-th}	انحراف معیار دامنه لحظه‌ای نرمال داده‌های غیر ضعیف
$\sigma_{ aa -th}$	انحراف معیار مقدار مطلق دامنه نرمال داده‌های غیر ضعیف

اگر R_{ff} ماتریس خودهمبستگی سیگنال دریافتی با ابعاد $m \times m$ (مقدار m با توجه به طول پنجره ورودی و تعداد نمونه‌های موجود در فرآیند میانگین‌گیری به دست می‌آید)، R_{ss} ماتریس خودهمبستگی سیگنال ارسالی و R_{nn} ماتریس خودهمبستگی نویز کانال فرض شود، SVD ماتریس R_{ff} به صورت زیر خواهد بود

$$R_{ff} = R_{ss} + R_{nn} = V(\Lambda_s + \Lambda_n)V^T = V\Lambda_f V^T \quad (۴)$$

در این رابطه V ماتریسی است که در آن $V^T V = I_{m \times m}$ بوده و $\Lambda_s = \text{diag}(D_1, D_2, \dots, D_p, 0, \dots, 0)_{m \times m}$ یک ماتریس قطری با p عنصر غیر صفر و $m-p$ صفر در قطر اصلی می‌باشد. $\Lambda_n = \text{diag}(\sigma_n^2, \sigma_n^2, \dots, \sigma_n^2)_{m \times m}$ نیز یک ماتریس قطری با عناصر مساوی با واریانس نویز و $\Lambda_f = \Lambda_s + \Lambda_n$ برابر با $\Lambda_f = \text{diag}(D_1 + \sigma_n^2, \dots, D_p + \sigma_n^2, \sigma_n^2, \dots, \sigma_n^2)_{m \times m}$ خواهد بود. برای تخمین توان، ابتدا ماتریس خودهمبستگی سیگنال دریافتی و سپس SVD این ماتریس محاسبه می‌شود. از عناصر ماتریس قطری Λ_f ، p عنصر مربوط به زیرفضای سیگنال و $m-p$ عنصر انتهای متعلق به زیرفضای نویز می‌باشند. برای جداسازی این دو زیرفضا، برداری تعریف می‌شود که عناصر آن از تفاضل دو مقدار مجاور قطر Λ_f تشکیل شده است.

با توجه به ماتریس Λ_f در حالت ایده‌آل، بردار تفاضلی تعریف‌شده در عنصر p تغییر ناگهانی خواهد داشت که می‌توان از طریق آن به مقدار p پی برد. در این صورت داریم

$$\sigma_n^2 = \frac{1}{m-p} \sum_{i=p+1}^m \Lambda_f(i, i) \quad (۵)$$

$$s = \frac{1}{m} \sum_{i=1}^p (\Lambda_f(i, i) - \sigma_n^2) \quad (۶)$$

پس از تخمین توان سیگنال ارسالی (s) و با محاسبه مقدار دامنه لحظه‌ای از روی سیگنال دریافتی، ویژگی تعریف‌شده قابل محاسبه است. از آنجا که برای طراحی طبقه‌بندی‌کننده‌های مبتنی بر سطح آستانه از مقادیر ایده‌آل ویژگی‌ها استفاده می‌شود، نیاز به محاسبه دقیق این مقادیر وجود دارد. جدول ۱ مقادیر نظری ویژگی J را برای ۴ نوع مدولاسیون این مقاله مشخص می‌کند. این مقادیر با توجه به معادلات مربوط به هر یک از مدولاسیون‌ها و در شرایط کاملاً ایده‌آل یعنی خطای تخمین توان صفر و سیگنال به نویز بی‌نهایت به دست آمده است [۵]. همان‌طور که در جدول دیده می‌شود، این مقادیر برای ۴ کلاس این مسأله کاملاً متفاوت بوده که این تفاوت می‌تواند برای عملیات جداسازی مدولاسیون‌های مختلف و در نتیجه تشخیص نوع مدولاسیون سیگنال دریافتی به کار رود.

از آنجا که در فاز دوم مقاله بنا داریم تا ۹ مدولاسیون را از هم جداسازی کنیم، بنابراین ناگزیر به استفاده از ویژگی‌های دیگری نیز در این مرحله می‌باشیم. بدین منظور، ۸ ویژگی دیگر که همه آنها به سادگی قابل استخراج از پوش سیگنال می‌باشند، مورد استفاده قرار گرفته است [۷]. جدول ۲ ویژگی‌های استفاده‌شده در این مرحله را نمایش می‌دهد.

۴- پیش‌پردازش

امروزه، طراحان سیستم‌های تشخیص الگو، تکنیک‌های زیادی برای بهینه‌سازی عملیات طبقه‌بندی پیشنهاد می‌کنند. یکی از تکنیک‌های بسیار متداول، انجام پیش‌پردازش‌هایی چون فیلترینگ به منظور بهبود عملکرد سیستم تشخیص مدولاسیون و بالابردن دقت تشخیص آن می‌باشد.

یک ویژگی ایده‌آل دارای دو خصوصیت مهم است. اول آنکه مقدار ویژگی به ازای سیگنال به نویزهای مختلف تغییری نمی‌کند و دوم آنکه مقدار ویژگی برای هر یک از کلاس‌ها (انواع مدولاسیون) با کلاس دیگر کاملاً متفاوت است. البته موارد دیگری چون پیچیدگی محاسباتی کم و استقلال ویژگی‌ها نیز در کیفیت یک ویژگی مؤثر است. در عمل هرچه ویژگی‌های استخراج‌شده به این حالت ایده‌آل نزدیک‌تر باشند، مستقل از نوع طبقه‌بندی‌کننده‌ای که استفاده می‌شود، قطعاً دقت عملیات تشخیص بالاتر خواهد بود. بدین منظور اگر میانگین مقدار یک ویژگی را بر حسب SNR در کلاس‌های مختلف رسم کنیم تا حد زیادی به کیفیت ویژگی تعریف‌شده پی خواهیم برد. به منظور اینکه ویژگی انتخاب‌شده عملکرد مناسبتری در جداسازی مدولاسیون‌ها داشته باشد، می‌بایست تا حد امکان فاصله کلاس‌ها در فضای ویژگی از یکدیگر بیشتر شود. برای نیل به این مقصود، روش‌های مختلفی پیشنهاد می‌شود که ساده‌ترین و کاربردی‌ترین راه، فیلتر کردن سیگنال دریافتی به منظور کاهش اثر نویز می‌باشد.

برای انجام عملیات فیلترینگ می‌بایست پنجره ورودی از سیگنال باند میانی، قبل از عملیات استخراج ویژگی از یک فیلتر باند میانی عبور کند. به هر میزان که در عملیات فیلترینگ توان نویز کم شود، می‌توان امیدوار بود که درصد تشخیص به همان نسبت افزایش یابد. متأسفانه انتخاب دقیق محدوده فیلتر شدن نیاز به پارامترهایی چون پهنای باند سیگنال ارسالی و فرکانس حامل دارد که باز هم طبق فرض مسأله در دست نیست. بدین منظور سعی شده است تا با تخمین فرکانس حامل، محدوده تقریبی فیلتر شدن را مشخص کنیم. انتخاب صحیح پارامترهای فیلتر نقش اساسی در این کار دارد زیرا در صورت انتخاب اشتباه محدوده فیلتر شدن، امکان دارد سیگنال اصلی نیز حذف شود که قطعاً مضر خواهد بود. از آنجا که به طور معمول فرکانس حامل بسیار بیشتر از دو برابر پهنای باند سیگنال ارسالی می‌باشد، بنابراین بازه $(f_c - 0.5f_c, f_c + 0.5f_c)$ به عنوان محدوده فیلترینگ انتخاب شده که قطعاً از پهنای باند سیگنال‌های دریافتی بیشتر است و خطر حذف سیگنال وجود ندارد.

برای تخمین فرکانس حامل از روی سیگنال دریافتی، از تخمین LSE^1 فاز لحظه‌ای استفاده کرده‌ایم [۷]. اگر $f(t)$ سیگنال نویزی دریافت‌شده

1. Least Square Estimation

۵- طبقه‌بندی کننده

بردار ماشین تکیه‌گاه یک الگوریتم مدل‌سازی قدرتمند است که می‌تواند در مسائل تشخیص الگو مورد استفاده قرار گیرد. این الگوریتم بر مبنای تکنیک SRM^1 به حل مسائل می‌پردازد [۸]. در این تکنیک، هدف این است که با ثابت نگاه‌داشتن میزان ریسک خطا، فاصله بین کلاس‌ها در فضای ویژگی حداکثر گردد. در این الگوریتم برای داده‌هایی که امکان جداسازی خطی وجود دارد، یک فوق صفحه در فضای ویژگی تعریف می‌شود و سپس پارامترهای آن بر مبنای تکنیک مذکور بهینه می‌گردند. در مسائل غیر خطی، ایده اولیه به این قرار است که بردارهای ورودی تحت یک نگاشت از قبل تعیین شده (با استفاده از یک تابع غیر خطی) به فضای ویژگی^۲ با ابعاد بالا انتقال یابند. برای داده‌های خطی، ابرصفحه در فضای ورودی ساخته می‌شود، اما در اینجا برای آنکه ابرصفحه را در فضای ویژگی بسازیم، لازم است ابتدا بردارهای ورودی را با استفاده از یک تابع کرنل^۳ به فضای N بعدی (فضای ویژگی) ببریم $\phi: \mathcal{X}^n \rightarrow \mathcal{X}^N$. اکنون یک ابرصفحه N بعدی خطی تفکیک‌کننده (مشابه روش خطی) ساخته می‌شود. با استفاده از کرنل‌های مختلف می‌توان روش‌های فراگیری ماشینی مختلفی با انواع سطوح تصمیم‌گیری دلخواه ساخت. SVM همواره به یک مینیمم مطلق همگرا می‌شود و بر خلاف سایر طبقه‌بندی‌کننده‌های هوشمند چون شبکه‌های عصبی، همواره دارای جواب یکتا خواهد بود.

دو پارامتر اصلی یک طبقه‌بندی‌کننده SVM، مقدار فاصله اطمینان بین کلاس‌ها و نوع کرنل استفاده شده می‌باشد. در این مقاله تابع کرنل از بین سه تابع خطی، چندجمله‌ای و گوسی انتخاب شده است که متداول‌ترین توابع کرنل می‌باشند. توابع کرنل چندجمله‌ای و گوسی هر کدام یک پارامتر مشخص کننده دارند که به ترتیب درجه چندجمله‌ای و میانگین تابع گوسی می‌باشد، اما کرنل خطی به هیچ پارامتری نیاز ندارد. نوع تابع کرنل، پارامتر مشخص کننده هر یک از توابع و نیز فاصله اطمینان بین کلاس‌ها با توجه به شرایط مسأله و با سعی و خطا انتخاب می‌شوند که در فاز اول مقاله سعی شده است با بهینه‌کردن ساختار طبقه‌بندی‌کننده، انتخاب این مقادیر نیز به صورت هوشمندانه باشد.

۶- بهینه‌سازی عملکرد طبقه‌بندی کننده

روش‌های متعددی برای بهینه‌سازی عملکرد طبقه‌بندی‌کننده‌ها پیشنهاد شده است که یکی از روش‌های مرسوم، بهینه‌سازی ساختار طبقه‌بندی‌کننده با استفاده از انتخاب هوشمندانه پارامترهای ساختاری آن می‌باشد و روش دیگر مبتنی بر انتخاب بهینه ویژگی‌های مورد استفاده در عملیات جداسازی است که در این مقاله از هر دوی این روش‌ها برای بهبود عملکرد استفاده شده است. در فاز اول از روش اول و در فاز دوم از روش دوم بهره گرفته‌ایم.

در روش اول ابتدا لازم است یک تابع هدف برای الگوریتم ژنتیک مشخص گردد که معمولاً در این گونه مسائل خطای تشخیص است. پس از آن الگوریتم با تغییر مداوم پارامترهای ساختاری طبقه‌بندی‌کننده، ساختاری را معرفی می‌کند که دارای کمترین مقدار در تابع هدف است. در انتخاب مقادیر مربوط به پارامترهای ساختاری SVM، مقدار فاصله اطمینان به صورت عددی حقیقی در بازه $(-۸, ۰)$ متغیر فرض شده است.

1. Structural Risk Minimization
2. Feature Space
3. Kernel Function

در باند میانی باشد، طبق تعریف سیگنال تحلیلی $z(t)$ و فاز لحظه‌ای $\phi(t)$ به صورت (۷) قابل محاسبه است

$$\begin{aligned} Z(t) &= f(t) + j\dot{f}(t) \\ \phi(t) &= \arg(Z(t)) \end{aligned} \quad (7)$$

فاز لحظه‌ای سیگنال دریافتی در حالت کلی شامل دو بخش خطی و غیر خطی می‌باشد. بخش خطی فاز به دلیل فرکانس حامل و بخش غیر خطی به دلیل تغییرات فاز در سیگنال مدوله‌شده به وجود می‌آید. با توجه به اینکه فرکانس حامل در عمل عدد بسیار بزرگی است، بنابراین بخش خطی فاز کاملاً بر بخش غیر خطی آن که حاصل از سیگنال پیام است غلبه دارد. اگر $\phi(k)$ بردار فاز لحظه‌ای استخراج شده از سیگنال ورودی باشد، طبق نکات گفته شده داریم

$$\begin{aligned} \phi(k) &= \phi_{NL}(k) + \left(\frac{\sqrt{\pi} f_c}{f_s}\right)k = C_v + C_s k + v(k) \\ k &= 0, 1, \dots, N-1 \end{aligned} \quad (8)$$

که در آن $\phi_{NL}(k)$ بخش غیر خطی فاز، f_s فرکانس نمونه‌برداری سیگنال ورودی و C_s و C_v پارامترهای مدل خطی انتخاب شده می‌باشند. $v(k)$ به صورت بردار نویز مدل شده که در واقع نمایشگر ماهیت تصادفی بخش غیر خطی فاز می‌باشد. N نیز تعداد نمونه‌های زمانی پنجره دریافتی از سیگنال باند میانی است. مدل خطی تعریف شده برای فاز لحظه‌ای دریافتی به صورت ماتریسی در (۹) بیان شده است

$$\begin{aligned} \Phi &= Hc + v \\ \Phi &= \begin{bmatrix} \phi(0) \\ \phi(1) \\ \vdots \\ \phi(N-1) \end{bmatrix} \quad H = \begin{bmatrix} \cdot & 1 \\ 1 & \cdot \\ \cdot & \cdot \\ \cdot & \cdot \\ (N-1) & 1 \end{bmatrix} \\ c &= \begin{bmatrix} C_s \\ C_v \end{bmatrix} \quad v = \begin{bmatrix} v(0) \\ v(1) \\ \cdot \\ \cdot \\ v(N-1) \end{bmatrix} \end{aligned} \quad (9)$$

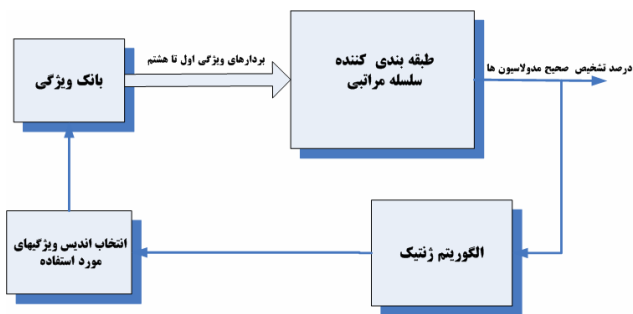
می‌دانیم که جواب تخمین LSE با داشتن ماتریس‌های H و ϕ به صورت (۱۰) خواهد بود [۷]

$$c = [H^T H]^{-1} H^T \Phi \quad (10)$$

پس از تعریف مسأله به صورت یک مدل خطی از تخمین LSE برای محاسبه $c = \begin{bmatrix} C_s \\ C_v \end{bmatrix}$ و در نتیجه فرکانس حامل که از روی C_s و از (۱۱) قابل محاسبه است، استفاده می‌کنیم

$$f_c = \frac{C_s f_s}{\sqrt{\pi}} \quad (11)$$

با تخمین فرکانس حامل، امکان انجام عملیات فیلترینگ روی سیگنال باند میانی دریافتی به وجود می‌آید. با انجام فیلترینگ در باند میانی، وضعیت ویژگی‌های استخراج شده از حیث توانایی در تفکیک کلاس‌ها بسیار بهبود می‌یابد. با توجه به نتایج بسیار خوب و نقش تأثیرگذار فیلترکردن سیگنال در کیفیت ویژگی، در این مقاله نتایج شبیه‌سازی طبقه‌بندی‌کننده پیشنهادی با ویژگی‌های استخراجی از سیگنال فیلتر شده ارائه می‌شود.



شکل ۳: بلاک دیاگرام نحوه عملکرد بهینه‌سازی طبقه‌بندی کننده در فاز دوم.

می‌توانند شامل یک یا چند عدد بین ۱ تا ۹ باشند که هر یک از اعداد بین ۱ تا ۹، اندیس ویژگی‌های مورد نیاز می‌باشند. مسأله اصلی در این فاز پیدا کردن ۸ بردار ویژگی است که با اعمال آنها به طبقه‌بندی‌کننده‌های موجود در ساختار، میانگین خطای تشخیص حداقل شود. به صورت تئوریک اگر بخواهیم تک‌تک جواب‌های ممکن این مسأله را آزمایش کنیم با کامپیوترهای موجود به سال‌ها زمان نیاز داریم که به همین دلیل به الگوریتم‌های جستجوی تصادفی چون الگوریتم ژنتیک پناه می‌بریم.

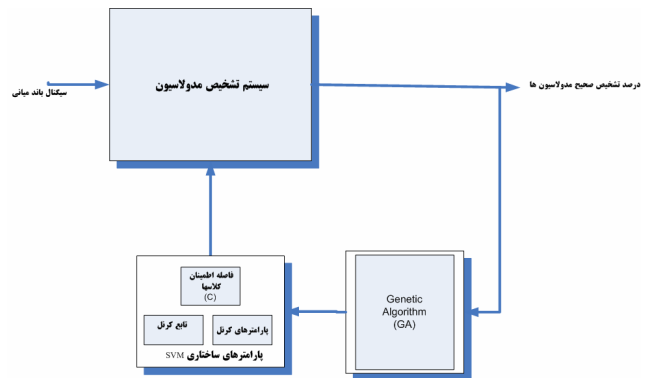
در شکل ۳ بلاک دیاگرام نحوه بهینه‌سازی عملیات انتخاب ویژگی در این فاز دیده می‌شود. برای انجام عملیات بهینه‌سازی، ابتدا یک بانک ویژگی تشکیل می‌شود. بانک ویژگی شامل همه ویژگی‌های استخراج شده از سیگنال می‌باشد که در این بخش از مقاله شامل ۹ ویژگی است. در ابتدای کار، هشت بردار تصادفی از عناصر موجود در بانک ویژگی انتخاب می‌شوند و با اعمال آنها به ساختار سلسله مراتبی، عملیات تشخیص مدولاسیون صورت می‌پذیرد. پس از انجام این عملیات، میانگین خطای تشخیص مدولاسیون‌ها محاسبه و به عنوان تابع هدف به الگوریتم ژنتیک وارد می‌شود. الگوریتم ژنتیک با هدف حداقل کردن تابع هدف، اندیس ویژگی‌های پیشنهادی برای هشت بردار نسل بعد را تولید کرده و آن ویژگی‌ها از بانک ویژگی انتخاب می‌گردند. عملیات تشخیص مدولاسیون با بردارهای جدید صورت می‌گیرد و این چرخه تا رسیدن به یک حداقل قابل قبول در تابع هدف ادامه می‌یابد.

برای تضمین عملکرد صحیح الگوریتم ژنتیک، انتخاب مناسب پارامترهای ساختاری آن چون تعداد نسل، جمعیت هر نسل، نحوه و سرعت انجام عملیات Cross-Over و غیره، امری ضروری است. انتخاب دقیق پارامترهای ساختاری الگوریتم ژنتیک در سرعت همگرایی و نیز مقدار همگرایی تأثیر بسزایی دارد. در عمل این پارامترها با سعی و خطا تعیین می‌گردند اما در این مقاله سعی شده است تا با استفاده از مقادیر معمول این پارامترها که از مثال‌های چیه ابزار بهینه‌سازی نرم‌افزار MATLAB استخراج شده است، عملیات بهینه‌سازی صورت پذیرد. اندازه جمعیت ۲۰ فرد و تعداد تولید نسل به ۵۰ نسل محدود شده است.

۷- نتایج شبیه‌سازی

۷-۱ نتایج فاز اول

برای شبیه‌سازی تکنیک‌های پیشنهادی در فاز اول، ابتدا ۴ دسته سیگنال با مدولاسیون دیجیتال ASK-۲، PSK-۲، QAM-۱۶ و PAM-۴ در باند میانی تولید می‌گردند. پس از آن سیگنال‌های تولید شده از کانال AWGN عبور کرده و وارد ساختار گیرنده می‌شوند. در گیرنده ابتدا توان سیگنال‌های ارسال شده با محاسبه عناصر حاصل از تجزیه مقدار تکین تابع خودهمبستگی تخمین زده می‌شود و پس از آن ویژگی J محاسبه می‌گردد.



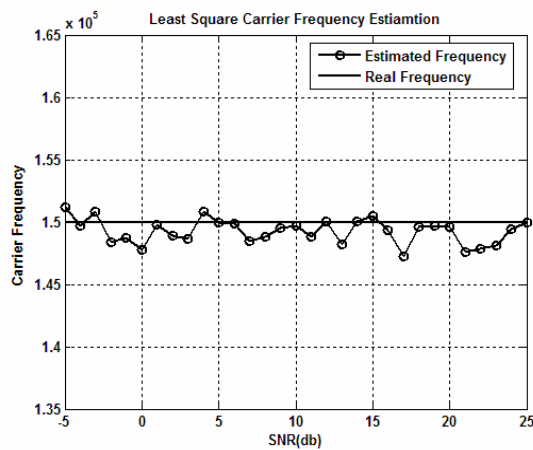
شکل ۲: بلاک دیاگرام نحوه عملکرد عملیات بهینه‌سازی طبقه‌بندی کننده SVM.

درجه چندجمله‌ای در تابع کرنل چندجمله‌ای به صورت عددی صحیح در بازه (۸-۱) و میانگین تابع گوسی در کرنل گوسی به صورت عددی حقیقی در بازه (۴-۰) متغیر می‌باشد. انتخاب بازه‌های فوق بر مبنای مقادیر پیش فرض انتخاب شده در برخی الگوریتم‌های تشخیص الگو بوده است [۸]. لازم به ذکر است که الگوریتم ژنتیک در واقع مقادیر بهینه هر یک از پارامترها را در بازه‌های ذکر شده مشخص می‌کند نه در کل فضای اعداد حقیقی.

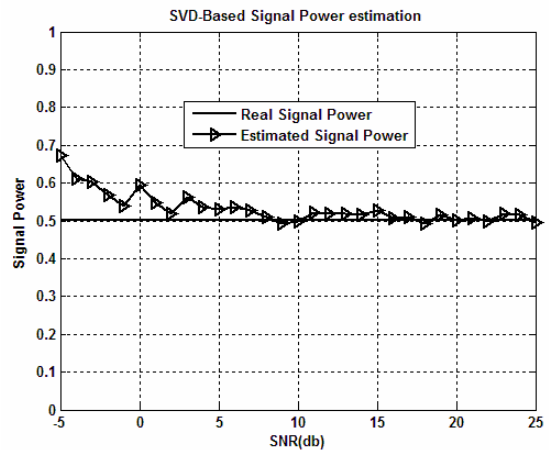
عملیات بهینه‌سازی در دو حالت و با دو تابع هدف متفاوت صورت می‌گیرد. ابتدا مقادیر فاصله اطمینان و کرنل با هدف حداقل کردن حداکثر خطای تشخیص در بازه سیگنال به نویز ۱۵ dB - ۰ dB پیدا می‌شود که آن را با نام استراتژی Min-Max می‌شناسیم. علت انتخاب بازه ۱۵ dB - ۰ dB این است که اگر داده‌های دارای سیگنال به نویز بسیار پایین (کمتر از ۰ dB) در عملیات بهینه‌سازی حضور یابند، به دلیل غلبه نویز بر سیگنال، قطعاً عملکرد ساختار بهینه‌شده مطلوب نخواهد بود. در مرحله دوم ساختار SVM با هدف حداقل کردن میانگین خطای تشخیص در بازه فوق تعیین می‌گردد که آن را با استراتژی Min-Average نام‌گذاری کرده‌ایم. در واقع هدف این است که تا حد ممکن درصد تشخیص صحیح در ساختار بهینه‌شده نسبت به حالت اولیه بهبود یابد. در هر یک از استراتژی‌های ذکر شده، الگوریتم ژنتیک ساختاری را به ما معرفی می‌کند که تابع هدف مربوط به خود را حداقل کرده باشد. همان‌طور که در ادامه خواهید دید، ساختارهای معرفی شده در دو حالت به کلی با یکدیگر متفاوت هستند. این تفاوت بدان معناست که ساختار Min-Max نمی‌تواند میانگین خطا را نیز حداقل کند و بالعکس. شکل ۲ بلاک دیاگرام نحوه عملکرد عملیات بهینه‌سازی را نشان می‌دهد.

همان‌طور که در شکل ۲ دیده می‌شود، ابتدا الگوریتم ژنتیک یک ساختار تصادفی اولیه برای طبقه‌بندی کننده SVM معرفی می‌کند و سپس عملیات تشخیص نوع مدولاسیون سیگنال باند میانی دریافتی با ساختار پیشنهادی انجام می‌شود. پس از محاسبه نتایج عملیات تشخیص مدولاسیون حداقل یا میانگین خطای تشخیص به عنوان تابع هدف به الگوریتم باز می‌گردد. الگوریتم ژنتیک این مسیر را بار دیگر تکرار می‌کند و این عملیات تا رسیدن به ساختار بهینه ادامه می‌یابد.

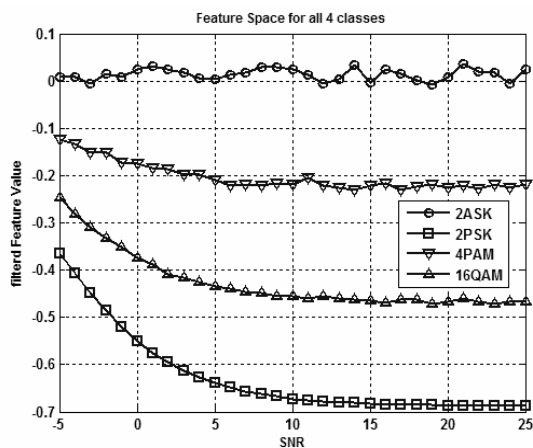
در فاز دوم مقاله که در ادامه شرح آن خواهد آمد، با یک ساختار سلسله مراتبی با ۸ طبقه‌بندی کننده مواجهیم که هر یک از ۸ طبقه‌بندی کننده موجود در ساختار دارای یک بردار ویژگی مخصوص به خود می‌باشند. تعداد ویژگی‌های استخراجی از سیگنال دریافتی ۹ ویژگی است که به صورت کاملاً کور به دست آمده و در دسترس گیرنده می‌باشند. به این ترتیب هر یک از ۸ بردار ویژگی می‌توانند بین ۱ تا حداکثر ۹ ویژگی را شامل شوند. از دید ریاضی با ۸ بردار روبرو هستیم که هر یک از آنها



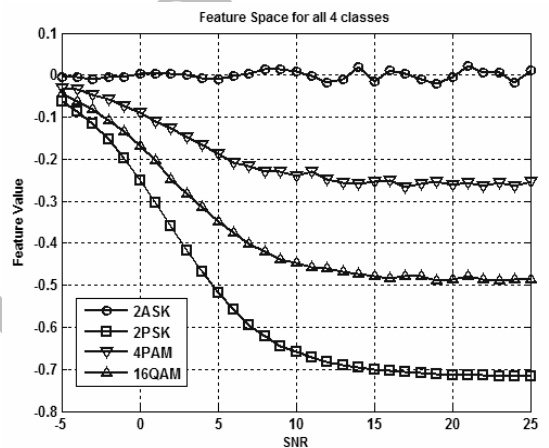
شکل ۶: نمودار مقدار تخمین زده شده فرکانس حامل توسط الگوریتم LSE بر حسب SNR.



شکل ۴: نمودار مقدار تخمین زده شده توان سیگنال ارسالی توسط الگوریتم SVD بر حسب SNR.



شکل ۷: نمودار اندازه ویژگی فیلترشده برای ۴ کلاس مدولاسیون بر حسب SNR.



شکل ۵: نمودار اندازه ویژگی استخراج شده برای ۴ کلاس مدولاسیون بر حسب SNR.

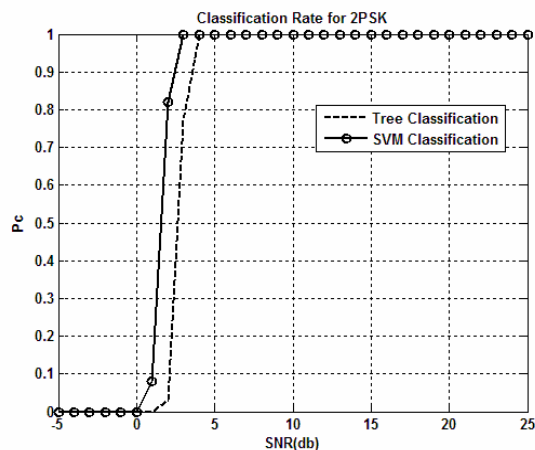
برای آموزش ساختار طبقه‌بندی کننده از مجموعه داده‌های دو سیگنال به نویز ۱۰ dB و ۲۰ dB استفاده شده است. لازم به ذکر است که در بعضی مقالات فرآیند آموزش تنها با داده‌های یک SNR صورت می‌پذیرد که این امر سبب می‌شود در مرحله آزمایش، عملکرد طبقه‌بندی کننده در داده‌های دارای سیگنال به نویز آموزش یافته بسیار خوب بوده و در قبال سایر داده‌ها به شدت افت عملکرد داشته باشد. درست به همین دلیل است که در کاربردهای عملی همواره از ترکیبی از سیگنال به نویزها برای آموزش استفاده می‌شود. برای بررسی عملکرد الگوریتم تشخیص مدولاسیون از مجموعه داده‌های آزمایش استفاده می‌شود. در هر یک از سیگنال به نویزهای بین -۵ dB تا ۲۵ dB که شامل ۳۱ سیگنال به نویز مختلف می‌شود، عملیات تشخیص مدولاسیون صورت گرفته است. در هر یک از مقادیر ذکر شده از هر کلاس ۱۰۰ فریم تولید شده و پس از استخراج ویژگی و عبور از طبقه‌بندی کننده، نوع مدولاسیون آنها تعیین شده است. به این ترتیب هر سیگنال به نویز حاوی ۴۰۰ سیگنال آزمایش می‌باشد که درصد تشخیص هر کلاس بر مبنای نتایج آن محاسبه می‌گردد و درصد تشخیص (P_c) نسبت تعداد تشخیص‌های صحیح به کل تعداد سیگنال‌ها تعریف می‌شود.

به منظور بررسی نتایج [۵]، روش به کار رفته در آن که استفاده از طبقه‌بندی کننده سطح آستانه‌ای دینامیک برای جداسازی مدولاسیون‌ها است، شبیه‌سازی شده است. در طبقه‌بندی کننده سطح آستانه‌ای دینامیک از یک ساختار درختی برای انجام عملیات تشخیص استفاده می‌شود. در این ساختار هر کلاس با اعمال یک سطح آستانه روی ویژگی

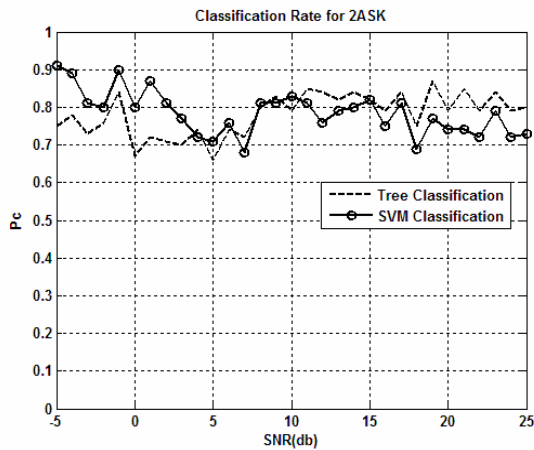
شکل ۴ نمودار توان سیگنال ارسالی شده برای مدولاسیون ۲-ASK، که با الگوریتم SVD تخمین زده شده است را در مقایسه با توان واقعی ارسالی شده بر حسب SNR نمایش می‌دهد. در شبیه‌سازی الگوریتم SVD، مقدار پارامتر m که ابعاد ماتریس خودهمبستگی را مشخص می‌کند، با سعی و خطا ۱۶ انتخاب گردیده است. انتخاب مقادیر بزرگ برای این پارامتر سبب کاهش دقت عملیات میانگین‌گیری و انتخاب مقادیر بسیار کوچک برای آن، سبب کاهش دقت در تشخیص نقطه تغییر و عدد p خواهد شد.

شکل ۵ ویژگی استخراج شده J را برای ۴ کلاس مدولاسیون موجود، نمایش می‌دهد. همان‌طور که در شکل نیز دیده می‌شود، با کاهش SNR قابلیت تفکیک کلاس‌ها کاهش یافته و قطعاً درصد تشخیص صحیح نیز کاهش خواهد یافت.

همان‌طور که پیش از این اشاره شد، به منظور افزایش قابلیت جداسازی ویژگی، عملیات فیلترینگ بر روی سیگنال دریافتی صورت می‌پذیرد. برای فیلترینگ، نیاز به تخمین فرکانس حامل وجود دارد. شکل ۶ تخمین فرکانس حامل را که با استفاده از تخمین LSE محاسبه شده است در مقایسه با فرکانس حامل واقعی نشان می‌دهد. این نمودار برای مدولاسیون ۲ASK رسم شده است اما در مورد سایر مدولاسیون‌ها نیز نتایج عملیات تخمین به صورت مشابهی به دست می‌آید. در شکل ۷ ویژگی استخراجی J که این بار از سیگنال فیلترشده استخراج شده است نمایش داده شده است. مقایسه این نمودار با شکل ۵ که حالت فیلتر نشده ویژگی بود، بهبود کیفیت ویژگی را ثابت می‌کند.



شکل ۹: نمودار درصد تشخیص مدولاسیون ۲PSK بر حسب SNR.



شکل ۸: نمودار درصد تشخیص مدولاسیون ۲ASK بر حسب SNR.

جدول ۴: ماتریس تداخل ۴ نوع مدولاسیون، در طبقه‌بندی‌کننده SVM و در سیگنال به نویز ۳ dB.

	۲ASK	۲PSK	۴PAM	۱۶QAM
۲ASK	۷۰	۰	۳۰	۰
۲PSK	۰	۷۷	۰	۲۳
۴PAM	۲۰	۰	۷۹	۱
۱۶QAM	۰	۰	۱۳	۸۷
	۲ASK	۲PSK	۴PAM	۱۶QAM
۲ASK	۷۳	۰	۲۷	۰
۲PSK	۰	۱۰۰	۰	۰
۴PAM	۶	۰	۹۳	۱
۱۶QAM	۰	۰	۱	۹۹

جدول ۳: ماتریس تداخل ۴ نوع مدولاسیون در طبقه‌بندی‌کننده SVM و در سیگنال به نویز ۱۰ dB.

	۲ASK	۲PSK	۴PAM	۱۶QAM
۲ASK	۷۹	۰	۲۱	۰
۲PSK	۰	۱۰۰	۰	۰
۴PAM	۱۹	۰	۷۸	۳
۱۶QAM	۰	۰	۲	۹۸
	۲ASK	۲PSK	۴PAM	۱۶QAM
۲ASK	۷۷	۰	۲۳	۰
۲PSK	۰	۱۰۰	۰	۰
۴PAM	۷	۰	۸۶	۷
۱۶QAM	۰	۰	۰	۱۰۰

۹۰/۷۵٪ است. در SNR=۳ dB درصد تشخیص صحیح برای مدولاسیون ASK-۲، ۷۳٪، برای مدولاسیون PSK-۲، ۱۰۰٪، برای PAM-۴، ۹۳٪ و برای QAM-۱۶، ۹۹٪ محاسبه شده است. میانگین صحت تشخیص برای کل کلاس‌ها نیز در این سیگنال به نویز در حدود ۹۰٪ است که با توجه به کور بودن گیرنده قابل توجه است.

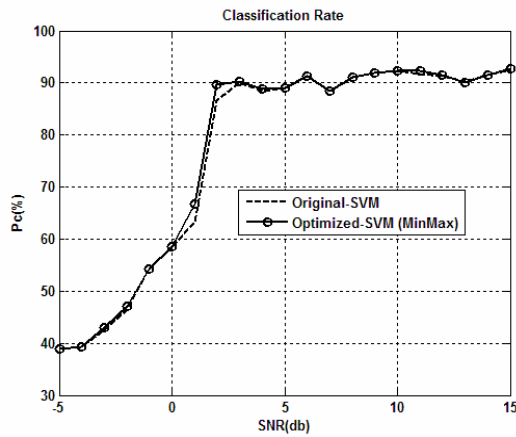
همان‌طور که از مقایسه نتایج SVM با طبقه‌بندی‌کننده مبتنی بر سطح آستانه در جدول ۳ دیده می‌شود، درصد تشخیص مدولاسیون ۴PAM، ۸٪ و درصد تشخیص مدولاسیون ۱۶QAM، ۲٪ نسبت به نتایج [۵] بالاتر است. در مجموع نیز درصد تشخیص کل در این سیگنال به نویز ۲٪ نسبت به درصد تشخیص کل در روش مبتنی بر ساختار درختی مورد استفاده در [۵] بیشتر است. در جدول ۴ نیز همان‌طور که پیداست، طبقه‌بندی‌کننده SVM در سیگنال به نویزهای پایین‌تری محسوس بر روش مورد استفاده در [۵] دارد. در مجموع، درصد تشخیص کل در این سیگنال به نویز ۱۳٪ نسبت به درصد تشخیص [۵] در همین شرایط بالاتر است.

اشکال ۸ تا ۱۲ نمودار درصد تشخیص صحیح مدولاسیون‌ها (P_c) را بر حسب SNR در طبقه‌بندی‌کننده‌های سطح آستانه‌ای و SVM برای هر چهار مدولاسیون مقاله نمایش می‌دهد. در این اشکال، نتایج روش سطح آستانه‌ای [۵] که مبتنی بر یک ساختار درختی می‌باشد، Tree Classification نام‌گذاری شده است. همان‌طور که از نمودارها نیز پیداست، طبقه‌بندی‌کننده SVM دارای برتری محسوس به ویژه در سیگنال به نویزهای کمتر از ۵ dB می‌باشد. این برتری در مدولاسیون‌های ۲ASK و ۴PAM به وضوح قابل مشاهده است.

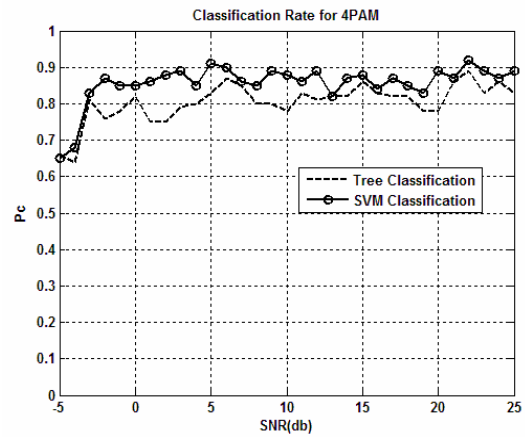
استخراج‌شده از کلاس‌های دیگر جدا می‌شود. تفاوت این روش با سایر ساختارهای سطح آستانه‌ای معمول این است که مقادیر سطح آستانه ثابت نبوده و می‌توانند بر حسب داده‌های آموزشی و در فرآیند آموزش تغییر کنند.

در اولین مرحله از شبیه‌سازی، نتایج ساختار طبقه‌بندی‌کننده SVM مورد بررسی قرار می‌گیرد. همان‌طور که پیش از این نیز ذکر شد، SVM دارای دو پارامتر ساختاری می‌باشد؛ فاصله اطمینان کلاس‌ها و تابع کرنل مورد استفاده برای نگاشت. در ابتدا مقادیر این دو پارامتر ساختاری را به صورت تجربی انتخاب می‌کنیم. با توجه به اینکه تابع کرنل گوسی بیشترین کاربرد را در مقایسه با سایر کرنل‌ها دارد، از این تابع در شبیه‌سازی اولیه استفاده شده است. پارامتر فاصله اطمینان، ۰/۵ و میانگین تابع گوسی نیز ۰/۵ انتخاب شده است که مقادیری متداول برای این دو کمیت می‌باشند [۸]. به منظور بررسی عملکرد، از همان مجموعه داده‌های آموزش و آزمایش پیشین که در طبقه‌بندی‌کننده درختی استفاده شد، بهره گرفتیم.

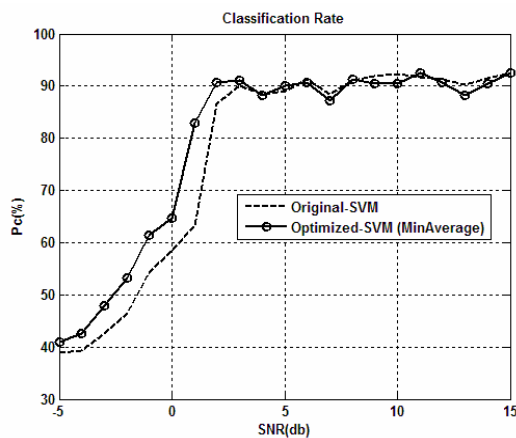
جدول ۳ و ۴ نتایج عملیات تشخیص مدولاسیون با SVM را در SNR = ۱۰ dB و SNR = ۳ dB در مقایسه با روش سطح آستانه‌ای دینامیک نشان می‌دهند. قسمت بالای جداول نتایج طبقه‌بندی‌کننده سطح آستانه‌ای و قسمت پایین نتایج طبقه‌بندی‌کننده SVM می‌باشد. با استفاده از این جداول درصد تشخیص درست در SNR = ۱۰ dB با استفاده از طبقه‌بندی‌کننده SVM برای مدولاسیون ۲-ASK، ۷۷٪، برای مدولاسیون PSK-۲، ۱۰۰٪، برای PAM-۴، ۸۶٪ و برای QAM-۱۶، ۱۰۰٪ محاسبه می‌گردد. میانگین صحت تشخیص برای کل کلاس‌ها نیز




شکل ۱۳: نمودار درصد تشخیص کل برای دو ساختار متفاوت از طبقه‌بندی‌کننده SVM. ساختار اولیه غیر بهینه و ساختار بهینه‌شده توسط الگوریتم ژنتیک با معیار Min-Max.



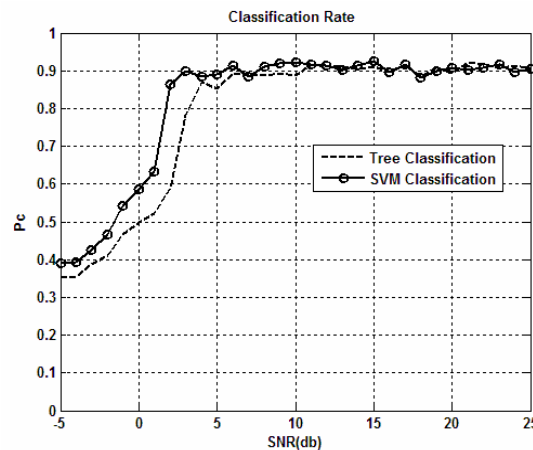
شکل ۱۰: نمودار درصد تشخیص مدولاسیون ۴PAM بر حسب SNR.



شکل ۱۴: نمودار درصد تشخیص کل برای دو ساختار متفاوت از طبقه‌بندی‌کننده SVM. ساختار اولیه غیر بهینه و ساختار بهینه‌شده توسط الگوریتم ژنتیک با معیار Min-Average.



شکل ۱۱: نمودار درصد تشخیص مدولاسیون ۱۶QAM بر حسب SNR.



شکل ۱۲: نمودار درصد تشخیص کل چهار مدولاسیون بر حسب SNR.

جدول ۵: ساختار بهینه تولیدی الگوریتم ژنتیک برای طبقه‌بندی‌کننده SVM با دو معیار متفاوت MIN-AVERAGE و MIN-MAX.

پارامتر کرنل	نوع کرنل	فاصله اطمینان	استراتژی
۰٫۵	گوسی	۰٫۵	ساختار اولیه
۱٫۲۸۳۵	گوسی	۰٫۱۱۸۱	Min-Max
-	خطی	۰٫۳۹۴	Min-Ave

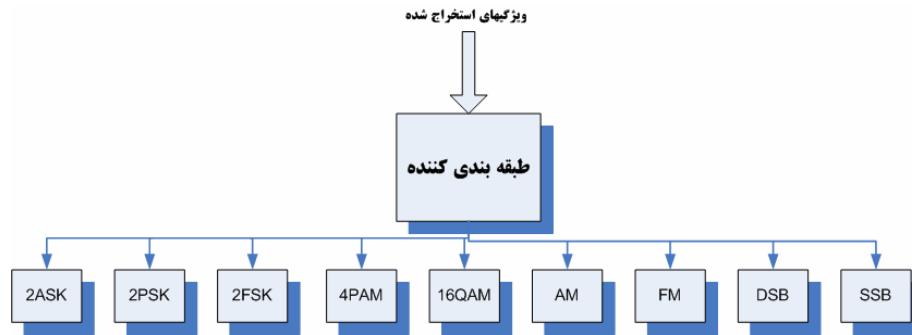
دوم با استراتژی Min-Average رسم شده است. همان‌طور که به وضوح دیده می‌شود، استراتژی دوم در مقایسه با حالت اول عملکرد بسیار قوی‌تری داشته و بهبود بیشتری در نمودار صحت تشخیص ایجاد نموده است. در سیگنال به نویزهای بالاتر از ۵ dB، هر دو استراتژی تقریباً یکسان عمل کرده و تفاوت قابل ملاحظه‌ای با ساختار اولیه از خود نشان نمی‌دهند. اما در سیگنال به نویزهای پایین، استراتژی اول به طور میانگین ۱٫۵٪ و استراتژی دوم ۶٫۱٪ درصد تشخیص را افزایش داده‌اند. در جدول ۵ مشخصات ساختار اولیه و دو ساختار پیشنهادی الگوریتم ژنتیک برای دو معیار مختلف بهینه‌سازی ارائه شده است.

ساختار پیشنهادی حاصل از استراتژی بهینه‌سازی Min-Max دارای یک تابع کرنل گوسی با میانگین ۱٫۲۸۳۵ و مقدار ثابت ۰٫۱۱۸۱ بوده که شبیه به ساختار اولیه می‌باشد. این شباهت می‌تواند تفاوت اندک دقت تشخیص را در این استراتژی نسبت به ساختار اولیه توجیه کند. در سوی

میزان بهبود درصد تشخیص کل که از شکل ۱۲ قابل محاسبه است، در بازه سیگنال به نویزهای بین (-۵ dB، ۲۵ dB) به طور میانگین ۳٫۲٪ می‌باشد که این بهبود در سیگنال به نویزهای کمتر از ۵ dB، ۷٫۹۵٪ محاسبه شده است.

در ادامه فاز اول تلاش شده است تا با بهینه‌سازی ساختار SVM به درصد تشخیص بالاتری دست یابیم. همان‌طور که پیش از این نیز ذکر شد، عملیات بهینه‌سازی با دو معیار متفاوت Min-Max و Min-Average صورت می‌گیرد که در اولی حداکثر خطا و در دومی میانگین خطا به عنوان تابع هدف الگوریتم ژنتیک حداقل می‌شود.

در شکل ۱۳ نمودار درصد تشخیص صحیح برای ساختار بهینه‌شده با استراتژی Min-Max و در شکل ۱۴ همین نمودار برای ساختار بهینه‌شده



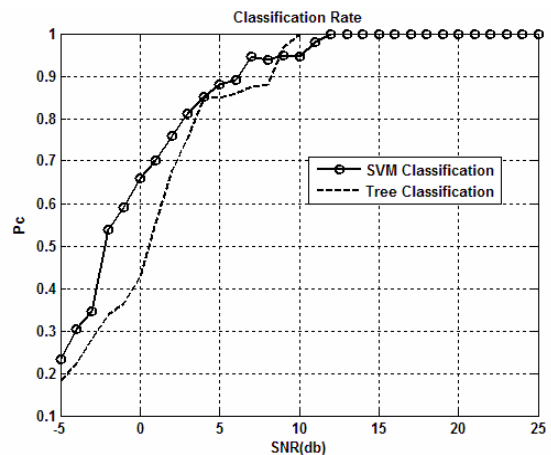
شکل ۱۵: بلاک دیاگرام الگوریتم تشخیص مدولاسیون در مرحله اول از فاز دوم.

میانگین درصد تشخیص صحیح مدولاسیون‌ها در بازه (۲۵ dB، -۵ dB) برابر ۸۵٪ و میانگین درصد تشخیص در سیگنال به نویزهای کمتر از ۵ dB، برابر ۶۰٫۶٪ به دست می‌آید. با وجود بهبود مناسب دقت تشخیص در این طبقه‌بندی‌کننده نسبت به ساختار درختی به ویژه در سیگنال به نویزهای پایین، مشکل پیچیدگی فضای ویژگی و آموزش نامناسب ساختار SVM همچنان وجود دارد که در ادامه بدان خواهیم پرداخت.

یکی از تکنیک‌های موجود برای حل مشکل آموزش نامناسب ساختارهای طبقه‌بندی‌کننده، استفاده از ساختارهای سلسله مراتبی می‌باشد. در یک ساختار سلسله مراتبی از طبقه‌بندی‌کننده‌ها، خروجی‌های هر مرحله به چند سوپرکلاس تقسیم می‌شوند که می‌تواند شامل یک یا چند کلاس مختلف باشد. در جداسازی کلاس‌های مختلف ابتدا دو یا چند سوپرکلاس تشکیل می‌گردد که هر یک وارد طبقه‌بندی‌کننده بعدی می‌شوند. طبقه‌بندی‌کننده بعدی نیز به همین ترتیب آن را به چند بخش تقسیم می‌کند و این کار تا رسیدن به سوپر کلاس‌هایی با یک عضو ادامه می‌یابد. به عبارت دیگر به جای تشخیص همه کلاس‌ها با استفاده از یک طبقه‌بندی‌کننده و در یک مرحله، عملیات جداسازی توسط چند طبقه‌بندی‌کننده و در چندین مرحله صورت می‌پذیرد. استفاده از ساختارهای سلسله مراتبی سبب می‌شود که در مسأله جداسازی کلاس‌های مختلف به جای اینکه عملیات تشخیص توسط یک ساختار طبقه‌بندی‌کننده پیچیده و حجیم که دارای سرعت آموزش کم و خطای آموزش بالاست صورت پذیرد، از چند طبقه‌بندی‌کننده ساده که دارای سرعت آموزش بالا و خطای آموزش اندک می‌باشند، استفاده کنیم. این امر سبب می‌شود که در نهایت درصد تشخیص کلاس‌های مختلف در ساختارهای سلسله مراتبی به صورت قابل توجهی بهبود یابد. علاوه بر این ساختارهای سلسله مراتبی می‌توانند در کاهش بعد فضای ورودی نیز مؤثر باشند.

در یک ساختار سلسله مراتبی، هر طبقه‌بندی‌کننده می‌تواند بردار ورودی مخصوص به خود را داشته باشد و نیازی نیست که همه طبقه‌بندی‌کننده‌ها با همه ویژگی‌های استخراجی آموزش یابند. به عبارت دیگر هر طبقه‌بندی‌کننده با ویژگی‌هایی که برای انجام عملیات جداسازی آن طبقه‌بندی‌کننده مؤثر هستند آموزش می‌یابد، نه همه ویژگی‌های استخراج شده. این امر سبب افزایش سرعت آموزش طبقه‌بندی‌کننده‌ها و به تبع آن کاهش خطای آموزش و آزمایش ساختار طبقه‌بندی‌کننده می‌شود.

در این مرحله برای انجام عملیات تشخیص مدولاسیون از یک ساختار سلسله مراتبی با ۸ طبقه‌بندی‌کننده استفاده کرده‌ایم. همان‌طور که در شکل ۱۷ دیده می‌شود، این ساختار در ۵ مرحله عملیات تشخیص را انجام می‌دهد. استفاده از ۸ طبقه‌بندی‌کننده سبب می‌شود که هر یک از آنها تنها عملیات جداسازی بین دو سوپرکلاس را انجام دهند که این امر در



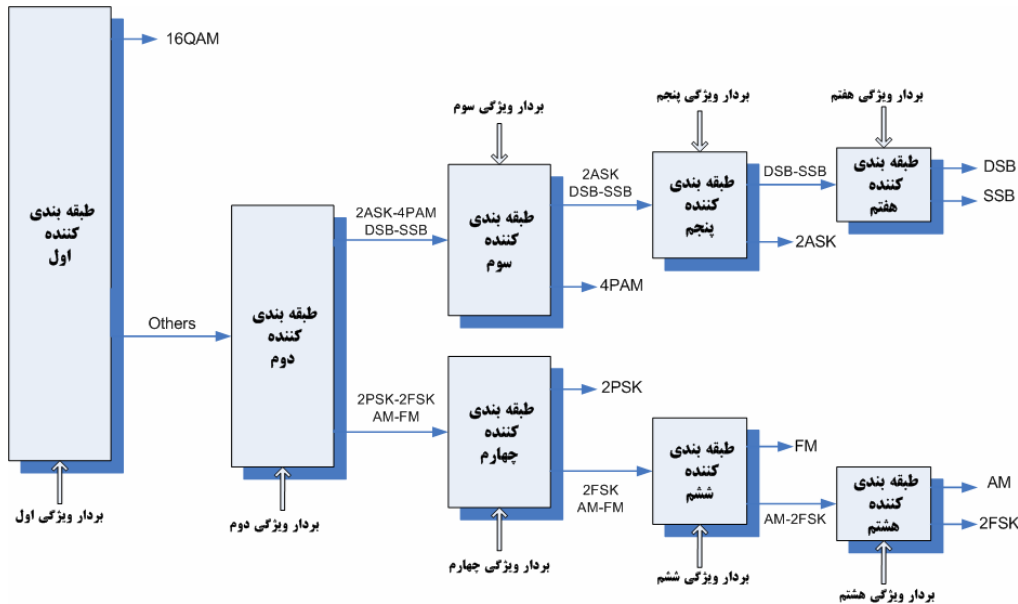
شکل ۱۶: نمودار درصد تشخیص صحیح کل در ساختار طبقه‌بندی‌کننده SVM بر حسب SNR.

مقابل ساختار پیشنهادی الگوریتم ژنتیک با استراتژی بهینه‌سازی Min - Average دارای یک تابع کرنل خطی است که پارامتر دیگری ندارد و مقدار ثابت فاصله اطمینان ۰٫۳۹۴ به دست آمده است. این ساختار از آنجا که به طور کلی با ساختار اولیه متفاوت است، انتظار داریم عملکرد متفاوتی نیز از خود بروز دهد که این امر می‌تواند نتایج مناسب این ساختار را مخصوصاً در سیگنال به نویزهای پایین توجیه نماید.

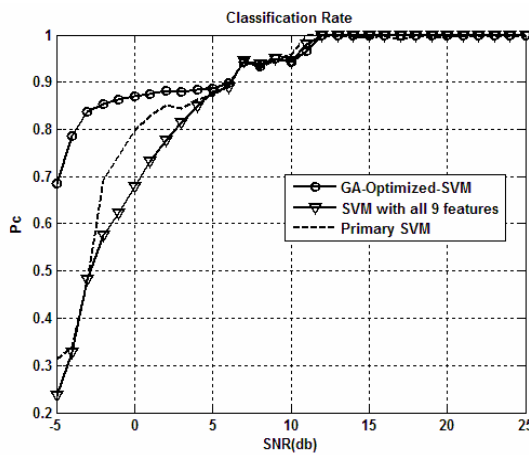
۲-۷ نتایج فاز دوم

همان‌طور که پیش از این ذکر شد، در این فاز از مقاله عملیات جداسازی مدولاسیون‌ها در شرایطی صورت می‌گیرد که ۹ مدولاسیون دیجیتال و آنالوگ در محیط حضور دارند. برای انجام عملیات تشخیص مدولاسیون، ۹ ویژگی از سیگنال باند میانی دریافتی در گیرنده استخراج می‌شود. همه این ویژگی‌ها که جزئیات نحوه استخراج آنها از سیگنال دریافتی در ابتدای مقاله آمده است، به صورت کاملاً کور و بدون نیاز به هیچ‌گونه اطلاعی از فرستنده سیگنال به دست می‌آیند. در ادامه این ویژگی‌ها وارد ساختار طبقه‌بندی‌کننده می‌شوند و از روی آنها نوع مدولاسیون سیگنال به دست می‌آید. در مرحله اول عملیات جداسازی مدولاسیون‌ها با استفاده از یک طبقه‌بندی‌کننده واحد انجام شده است. همان‌طور که در شکل ۱۵ دیده می‌شود، بردار ویژگی استخراج شده از سیگنال دریافتی، شامل ۹ ویژگی، وارد طبقه‌بندی‌کننده می‌شود و ساختار طبقه‌بندی‌کننده که یک SVM است، در یک مرحله نوع مدولاسیون سیگنال را تشخیص می‌دهد. نتایج عملیات جداسازی با طبقه‌بندی‌کننده متداول درختی مقایسه شده است.

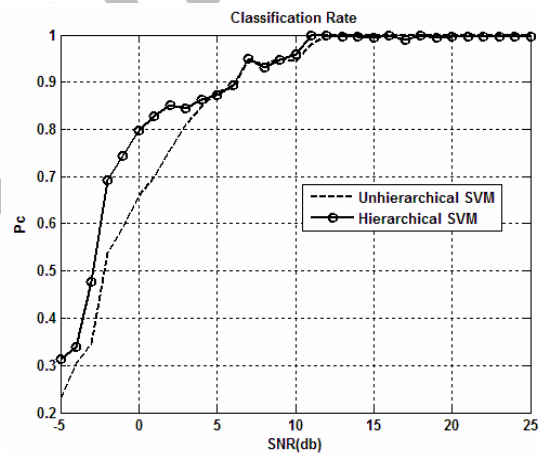
در شکل ۱۶ نمودار دقت تشخیص مدولاسیون‌ها بر حسب SNR در ساختار طبقه‌بندی‌کننده SVM رسم شده است. با استفاده از این نمودار،



شکل ۱۷: بلاک دیاگرام ساختار سلسله مراتبی از طبقه‌بندی کننده‌ها.



شکل ۱۹: نمودار درصد تشخیص صحیح کل در ساختار سلسله مراتبی طبقه‌بندی کننده SVM بهینه‌شده با الگوریتم ژنتیک بر حسب SNR.



شکل ۱۸: نمودار درصد تشخیص صحیح کل در ساختار سلسله مراتبی طبقه‌بندی کننده SVM بر حسب SNR.

اندیس‌های پیشنهادی GA با آنچه از تجربه کاربر پیداست، هم‌پوشانی دارد. البته در مواردی نیز GA، تعداد و نیز اندیس ویژگی‌ها را به کلی تغییر داده است. به هر صورت تنها راه برای آزمایش عملکرد صحیح پیشنهادی GA، انجام عملیات طبقه‌بندی با ویژگی‌های مذکور و مقایسه آن با طبقه‌بندی کننده اولیه مبتنی بر ویژگی‌های تجربی می‌باشد. در شکل ۱۹ نتایج عملیات طبقه‌بندی با استفاده از ویژگی‌های پیشنهادی GA آمده است. برای مقایسه عملکرد، از دو وضعیت دیگر در انتخاب ویژگی‌ها بهره گرفته‌ایم. وضعیت اول حالتی است که در آن ویژگی‌های انتخابی به صورت تجربی و بر مبنای شناخت کاربر از هر یک استفاده شده است (همان مقادیر اولیه موجود در جدول ۶) و وضعیت دوم حالتی است که از همه ۹ ویژگی برای همه طبقه‌بندی کننده‌ها استفاده شده است.

همان‌طور که از نتایج پیداست، عملیات بهینه‌سازی انتخاب ویژگی به صورت فوق‌العاده‌ای عملکرد ساختار سلسله مراتبی را بهبود داده است. با استفاده از این شکل، این نکته به وضوح قابل مشاهده است که ساختاری با حداکثر تعداد ویژگی ممکن (۹ ویژگی در هر ۸ بردار) لزوماً ساختار بهینه از حیث حداقل خطا نیست. میانگین درصد تشخیص صحیح مدولاسیون‌ها در ساختار بهینه‌شده با الگوریتم ژنتیک در بازه (۵ dB, ۲۵ dB) -۵ تا ۵/۵٪

بالا رفتن سرعت آموزش شبکه‌ها و کاهش خطای آنها بسیار مؤثر است. هر یک از ۸ طبقه‌بندی کننده موجود دارای یک بردار ویژگی مخصوص به خود می‌باشند.

در شکل ۱۸ نمودار دقت تشخیص مدولاسیون‌ها بر حسب SNR در ساختار سلسله مراتبی از بردارهای ماشین تکیه‌گاه رسم شده است. با استفاده از این نمودار، میانگین درصد تشخیص صحیح مدولاسیون‌ها در بازه (۵ dB, ۲۵ dB) -۵ تا ۲/۹٪ بهبود نسبت به ساختار غیر سلسله مراتبی، برابر ۸۷/۹٪ و میانگین درصد تشخیص در سیگنال به نویزهای کمتر از ۵ dB با ۸/۸٪ بهبود، برابر ۶۹/۴٪ به دست می‌آید.

همان‌طور که پیش از این نیز ذکر شد، برای بهینه‌سازی عملکرد ساختار سلسله مراتبی در این فاز از الگوریتم ژنتیک برای انتخاب ویژگی‌های بهینه از میان تمام ویژگی‌های موجود در بانک ویژگی که در این بخش ۹ ویژگی متفاوت است، استفاده کرده‌ایم. از آنجا که در ساختار سلسله مراتبی با هشت بردار ویژگی متفاوت (هر طبقه‌بندی کننده یک بردار) روبرو هستیم، الگوریتم ژنتیک نیز ۸ بردار متفاوت به ما معرفی کرده است. جدول ۶ اندیس ویژگی‌های پیشنهادی الگوریتم ژنتیک و نیز اندیس‌های اولیه و تجربی فرض شده را برای ۸ طبقه‌بندی کننده ساختار نشان می‌دهد. همان‌طور که از جدول نیز پیداست، در برخی موارد

جدول ۶: بردارهای ویژگی انتخابی الگوریتم ژنتیک برای طبقه‌بندی کننده سلسله مراتبی SVM.

انديس ویژگی‌های انتخابی اولیه	انديس ویژگی‌های انتخابی توسط GA	بردار ویژگی
۵، ۶	۳	بردار ویژگی طبقه‌بندی کننده اول
۱	۴، ۵، ۸	بردار ویژگی طبقه‌بندی کننده دوم
۵	۱، ۲، ۳، ۴، ۵، ۶، ۷	بردار ویژگی طبقه‌بندی کننده سوم
۳	۲، ۳، ۴، ۸، ۶	بردار ویژگی طبقه‌بندی کننده چهارم
۱	۱، ۵، ۶، ۷	بردار ویژگی طبقه‌بندی کننده پنجم
۳	۲، ۳، ۶، ۸	بردار ویژگی طبقه‌بندی کننده ششم
۳	۱، ۳، ۴	بردار ویژگی طبقه‌بندی کننده هفتم
۳، ۷	۲، ۳، ۴، ۵، ۶، ۸	بردار ویژگی طبقه‌بندی کننده هشتم

- [6] F. Bo, C. Jun, and C. Gnaq, "An algorithm of SNR estimation for non constant envelope signal in the AWGN channel," *Acta Electronica Sinica*, vol. 30, no. 1, pp. 1369-1371, Apr. 2002.
- [7] H. Stark and J. W. Woods, *Probability, Random Processes, and Estimation Theory for Engineers*, 2nd ed., Prentice-Hall, 1994.
- [8] C. J. C. Burges, "A tutorial on support vector machines for pattern recognition," *Data Mining and Knowledge Discovery*, vol. 2, no. 1, pp. 955-974, Apr. 1998.

سعید شعرباف تبریزی در سال ۱۳۸۲ مدرک کارشناسی مهندسی برق خود را از دانشگاه فردوسی و در سال ۱۳۸۵ مدرک کارشناسی ارشد مهندسی برق خود را از همان دانشگاه اخذ نمود. از سال ۱۳۸۵ تا کنون وی در دوره دکتری مخابرات گرایش سیستم در دانشگاه فردوسی در حال تحصیل است. زمینه‌های تحقیقاتی مورد علاقه ایشان عبارتند از: تشخیص الگو، محاسبات نرم و کاربردهای آن، نظریه آشوب و سیستم‌های دینامیکی و مخابرات پهن باند.

مرتضی خادمی مدرک کارشناسی خود را در گرایش الکترونیک از دانشگاه صنعتی اصفهان در سال ۱۳۶۴ اخذ نمود. نامبرده تحصیلات خود را در همان دانشگاه ادامه داده و موفق شد کارشناسی ارشد را در گرایش مخابرات در سال ۱۳۶۶ به پایان برساند. وی بلافاصله پس از فراغت از تحصیل در دانشگاه فردوسی مشهد به عنوان عضو هیأت علمی استخدام گردیده و به مدت چهار سال به امر تدریس اشتغال ورزید. در سال ۱۳۷۰ برای ادامه تحصیل به کشور استرالیا عزیمت نموده و در سال ۱۳۷۴ با اخذ مدرک دکترا مراجعت نمود. هم‌اکنون نامبرده به عنوان دانشیار گروه برق دانشگاه فردوسی مشهد مشغول به کار می‌باشد. زمینه‌های تحقیقاتی مورد علاقه وی، مخابرات تصویری، فشرده سازی تصویر و صوت و پردازش سیگنال‌های پزشکی می‌باشد.

محمد مولوی کاخکی مدرک کارشناسی خود را در فیزیک الکترونیک از دانشگاه تبریز در سال ۱۳۴۹ اخذ نمود. وی تحصیلات خود را در مقاطع کارشناسی ارشد و دکترا در دانشگاه کنت کانتربری انگلستان به ترتیب در سالهای ۱۳۵۵ و ۱۳۵۹ ادامه داد و تا ۱۳۶۲ در همان دانشگاه به عنوان محقق به کار اشتغال داشت. از سال ۱۳۶۳ وی به دانشکده مهندسی دانشگاه فردوسی پیوست و هم‌اکنون به عنوان دانشیار گروه برق دانشگاه فردوسی مشهد مشغول به کار می‌باشد. زمینه‌های تحقیقاتی مورد علاقه وی، مخابرات نوری، مخابرات دیجیتال و مخابره روی خطوط برق می‌باشد.

بهبود نسبت به ساختار سلسله مراتبی اولیه، برابر ۹۳/۴٪ و میانگین درصد تشخیص در سیگنال به نویزهای کمتر از ۵ dB با ۱۵/۳٪ بهبود، برابر ۸۴/۷٪ به دست می‌آید. میانگین دقت تشخیص ۷۰٪ در سیگنال به نویز ۵ dB- و بهبود قابل توجه عملکرد ساختار بهینه‌شده، نشان از اهمیت انجام عملیات بهینه‌سازی و تأثیر شگرف آن بر عملکرد ساختار سلسله مراتبی دارد.

سپاس‌گزاری

در پایان این مقاله با سپاس از خداوند متعال به خاطر نعمات بی‌پایانی که بر ما عرضه داشته است، از اساتید پژوهشکده مخابرات و کامپیوتر دانشکده مهندسی دانشگاه فردوسی که در این تحقیق کمک شایانی نمودند، تشکر می‌کنیم.

مراجع

- [1] Y. Yang and S. S. Soliman, "A suboptimal algorithm for modulation classification," *IEEE Trans. on Aerospace and Electronic Systems*, vol. 33, no. 1, pp. 38-45, Jan. 1997.
- [2] W. Wei and M. Mendel, "A new maximum - likelihood for modulation classification," in *Proc. IEEE Int. Conf. on Communications*, vol. 1, pp. 57-61, Feb. 1996.
- [3] E. Azzouz and A. Nandi, "Algorithms for automatic modulation recognition of communication signals," *IEEE Trans. on Commun.*, vol. 46, no. 4, pp. 431-436, Jan. 1998.
- [4] A. Iversen, *Classification of Digital Modulation Schemes Using Multi-Layered Perceptrons*, Ph.D Thesis, Heriot Watt University, pp. 30-35, Feb. 2004.
- [5] Q. Cai and P. Wei, "A digital modulation recognition method," in *Proc. IEEE Int. Conf. on Communications*, vol. 3, pp. 863-866, Apr. 2004.