

تشخیص خودکار مدولاسیون با استفاده از برنامه‌نویسی ژنتیک و شبکه عصبی چندلایه پرسپترون

کریم حسام‌پور و محمد قاسم‌زاده
دانشکده برق و کامپیوتر، دانشگاه یزد، یزد، ایران

چکیده

تشخیص مدولاسیون سیگنال دریافتی، گام میانی بین تشخیص سیگنال و دمدولاسیون آن محسوب می‌شود؛ به طوری که در بسیاری از سامانه‌های مخابراتی و نظامی تشخیص خودکار مدولاسیون جزئی از سامانه در نظر گرفته می‌شود. برای تشخیص خودکار مدولاسیون، به طور معمول تعدادی ویژگی از سیگنال دریافتی استخراج و به کار گرفته می‌شود، در این رابطه، انتخاب ویژگی مناسب، تأثیر به‌سزایی در افزایش کارایی تشخیص خودکار مدولاسیون دارد. در این مقاله با کمک برنامه‌نویسی ژنتیک از بین ویژگی‌های ورودی، ویژگی مناسب برای جداسازی هر مدولاسیون تولید و انتخاب می‌شود. شبیه‌سازی با سیگنال‌های مدوله شده با مشخصه سیگنال به نوبه پنج و ده دسی‌بل صورت گرفت. مجموعه‌ای از آزمایش‌ها در این پژوهش صورت گرفت که هدف از آنها تعیین میزان کارایی برای سیگنال‌های مدوله شده با مدولاسیون‌های پرکاربرد و متداول مخابراتی بوده است. پس از انتخاب ویژگی مناسب برای جداسازی مدولاسیون‌ها از شبکه عصبی پرسپترون چندلایه برای جداسازی نوع مدولاسیون استفاده می‌شود. نتایج حاصل نشان می‌دهد به کارگیری ویژگی‌هایی که سامانه مورد نظر پیشنهاد می‌دهد، منجر به افزایش قابل توجهی در تشخیص دقیق‌تر و سریع‌تر نوع مدولاسیون می‌شود.

واژگان کلیدی: تشخیص خودکار مدولاسیون، برنامه‌نویسی ژنتیک، آنتروپی، شبکه عصبی چندلایه پرسپترون.

۱- مقدمه

اگر یکی از اهداف اساسی علم مخابرات ایجاد ارتباط مناسب بین دو نقطه دور از هم در نظر گرفته شود، مدولاسیون به‌عنوان بخش جدانشدنی از این روند محسوب می‌شود. مدولاسیون فرایند تغییر یک یا چند مشخصه سیگنال حامل، متناسب با تغییرهای سیگنال پیام است (Carlson, Crilly, et al., 2001).

مشخصه‌های قابل تغییر یک سیگنال عبارت از دامنه، فاز و فرکانس (Carlson, Crilly, et al., 2001) هستند. به این ترتیب سازوکار کدبندی داده‌های دیجیتال به سیگنال آنالوگ با مدولاسیون دیجیتال عبارت‌اند از:

- شیفت گسسته در دامنه^۱
- شیفت گسسته در فرکانس^۲

- شیفت گسسته در فاز^۳
 - مدولاسیون دامنه با حالت تربیعی^۴
- تشخیص خودکار مدولاسیون، قدم مهمی بین آشکارسازی حضور یک سیگنال مخابراتی و دمدولاسیون آن است. در شرایط واقعی، پس از اطلاع از وجود یک سیگنال مخابراتی در باند مورد نظر، می‌توان با الگوریتم‌های تشخیص خودکار مدولاسیون، نوع آن را شناسایی کرد (Dobre, Abdi et al., 2007).

شایان ذکر است که بسیاری از روش‌های رایج در تشخیص خودکار مدولاسیون، توانایی تشخیص انواع محدودی از مدولاسیون‌ها را دارند و به‌طور معمول این مدولاسیون‌ها را از بین مجموعه‌ای مشخص از ورودی‌ها تشخیص می‌دهند. شناسایی خودکار مدولاسیون به‌عزت

³ Phase Shift Keying (PSK)

⁴ Quadrature Amplitude Modulation (QAM)

¹ Amplitude Shift Keying (ASK)

² Frequency Shift Keying (FSK)

مزایای فراوانی که دارد، توجه قابل ملاحظه‌ای را به خود جلب کرده است که در ادامه به چند مورد آن اشاره می‌شود. در بخش نظامی سامانه‌های جنگ الکترونیک از تشخیص خودکار مدولاسیون به‌عنوان یک منبع اطلاعاتی برای شنود سیگنال‌های متخاصم، تشخیص تهدیدها و همچنین اخلاص گر^۱ سامانه‌های متخاصم استفاده می‌شود (Soliman and Hsue, 1992; Lopatka and Pedzisz, 2000; Mobasseri, 2000; Wong and Nandi, 2001). در کاربردهای غیرنظامی می‌توان به مدیریت فرکانس، مانیتورینگ فرستنده‌ها و تشخیص فرستنده‌های غیرمجاز اشاره کرد (Soliman and Hsue, 1992; Lopatka and Pedzisz, 2000; Mobasseri, 2000).

کاربردهای دیگری که در هر دو گروه کاربردهای شهری و نظامی قرار می‌گیرد و اخیراً مورد توجه بسیاری قرار گرفته است، امکان ساخت گیرنده‌های هوشمندی است که بدون داشتن اطلاعات پیشین از سیگنال‌های ارسالی، نوع مدولاسیون را تشخیص و اطلاعات را استخراج می‌کنند. به این ترتیب فرستنده/گیرنده‌های هوشمندی امکان ظهور می‌یابند که با توجه به شرایط محیط و کانال ارتباطی مناسب‌ترین نوع مدولاسیون را جهت ارسال اطلاعات انتخاب می‌کنند و گیرنده نیز به‌صورت بلادرنگ امکان تشخیص تغییرهای نوع مدولاسیون را دارد (Dobre, Abdi et al., 2007).

در طراحی یک تشخیص دهنده خودکار مدولاسیون دو گام اساسی در نظر گرفته می‌شود: پیش‌پردازش اولیه سیگنال ورودی و انتخاب الگوریتم جداکننده (Zhu, Aslam, et al., 2010). هم‌چنین در بخش الگوریتم جداکننده، روش‌های تشخیص خودکار مدولاسیون به دو دسته، رهیافت مبتنی بر بیشینه شباهت^۲ و رهیافت مبتنی بر شناسایی آماری الگو تقسیم می‌شود. در روش‌های بیشینه شباهت به‌طور معمول مسأله تشخیص خودکار مدولاسیون به یک مسئله آزمون فرض با چند فرض ترکیبی^۳ تبدیل می‌شود. چنان‌چه فرض H_i برآورده شود، سیگنال ورودی مربوط به مدولاسیون i ام بوده است که $i = 1, 2, \dots, N_{\text{mod}}$. معمولاً در این روش از آزمون نسبت شباهت^۴ استفاده می‌شود که نیازمند محاسبه تابع شباهت سیگنال $r(t)$ در بازه $[0, KT]$ است (Wu, Saquib et al., 2008).

الگوریتم‌های بیشینه شباهت انواع متعددی دارند که عبارت‌اند از: ALRT^۵، GLRT^۶ و HLRT^۷. این روش‌ها با توجه به پیچیدگی پیاده‌سازی و دقت مورد نیاز و نیز پارامترهای نامعلوم در تشخیص خودکار مدولاسیون مورد استفاده قرار می‌گیرند. لازم به ذکر است روش‌های مبتنی بر بیشینه شباهت پیچیدگی محاسباتی بالایی دارند و نامعلوم بودن پارامترها نیز در هنگام استفاده از این روش‌ها دارای محدودیت است (Dobre, Abdi et al., 2007).

در رهیافت مبتنی بر شناسایی آماری الگو، ابتدا ویژگی‌های خاصی از سیگنال استخراج می‌شود. سپس براساس این ویژگی‌ها، تصمیم‌گیری انجام می‌شود. این روش نسبت به روش بیشینه شباهت، تنوع بیشتری دارد (Dobre, Abdi et al., 2007). باید دقت کرد ویژگی‌های سیگنال، به‌گونه‌ای انتخاب شوند که در برابر ایده‌آل نبودن پارامترهای سیگنال مقاوم باشد. برای افزایش کارایی این روش می‌توان از الگوریتم‌های یادگیری ماشین^۸ استفاده کرد. هم‌چنین رهیافت مبتنی بر شناسایی آماری الگو پیچیدگی محاسباتی کم‌تری نسبت به روش‌های بیشینه شباهت دارند و از این‌رو در سامانه‌های عملی امکان پیاده‌سازی آنها بیشتر است (Dobre, Abdi et al., 2007).

در سال‌های اخیر مطالعه‌های زیادی بر روی تشخیص خودکار مدولاسیون صورت گرفته است. در سال ۱۹۹۸ میلادی Nandi و همکارش یک الگوریتم طبقه‌بندی مدولاسیون بر اساس ویژگی‌های سریع و آنی سیگنال‌های دریافتی ارائه کردند. وی تمام ویژگی‌های مورد استفاده در الگوریتم طبقه‌بندی را از دامنه، فاز و فرکانس لحظه‌ای سیگنال دریافتی استخراج کرد. روش ایشان مجموعه مدولاسیون‌های آنالوگ و دیجیتال را با دقت متوسط ۹۴ درصد در سیگنال به نوبه ۱۵ دسی بل جدا می‌کرد (Nandi, Azzouz, 1998). در سال ۲۰۰۳ میلادی Wong و همکارش از شبکه عصبی مصنوعی و الگوریتم ژنتیک^۹ برای تشخیص خودکار مدولاسیون استفاده کرد. وی از الگوریتم ژنتیک برای انتخاب ویژگی‌های بهتر و از روش پس انتشار خطا ارتجاعی^{۱۰} در شبکه عصبی چندلایه پرسپترون برای جداسازی مدولاسیون‌ها استفاده کرد (Wong and Nandi, 2004).

⁵ Average Likelihood Ratio Test

⁶ Generalized LRT

⁷ Hybrid LRT

⁸ Machine Learning

⁹ Genetic algorithm(GA)

¹⁰ Resilient Back Propagation (RBP)

¹ Jamming

² Maximum Likelihood (ML)

³ Multiple hypothesis-testing problem

⁴ Likelihood Ratio (RL)

۱-۲- مدل سیگنال

در سامانه‌های ارتباطی شکل موج سیگنال باند پایه در گیرنده به صورت رابطه ۱ در نظر گرفته می‌شود (Hsue and Soliman, 1990).

(1)

$$y(n) = a e^{j(2\pi f_0 n T + \theta_n)} \sum_{l=-\infty}^{\infty} x(l) h(nT - lT + \epsilon_T T) + g(n)$$

در این رابطه $x(l)$ دنباله علامت‌ها، a دامنه نامشخص، T فاصله زمانی علامت‌ها، ϵ_T خطای تنظیم زمانی یا خطای مرحله نمونه‌برداری در خروجی فیلتر و f_0 مقدار عدم دقت فرکانسی اسیلاتور گیرنده نسبت به سیگنال حامل است. هم‌چنین $h(\cdot)$ ویژگی کانال باند پایه، θ_n انحراف فاز سیگنال حامل نسبت به اسیلاتور گیرنده و $g(n)$ نوفه گوسی سفید جمع‌شونده^۴ است. در این مطالعه فرض می‌شود شرایط کاری ایده‌آل باشد و تنها نوفه گوسی موجود است. هم‌چنین فرض می‌شود پارامترهای کانال معلوم و جبران‌سازی کانال قبلاً انجام شده و اثرات کانال ناچیز و قابل چشم‌پوشی است.

۲-۲- معرفی ویژگی‌ها

در این تحقیق از رهیافت شناسایی آماری الگو برای تشخیص خودکار مدولاسیون استفاده شده و از این رو مجموعه‌ای از ویژگی‌ها به‌عنوان ورودی الگوریتم تشخیص خودکار مدولاسیون پیشنهادی در نظر گرفته شده است. در ادامه این ویژگی‌ها معرفی می‌شوند.

۱-۲-۲- بیشینه طیف دامنه هنجار سازی شده

این ویژگی با γ_{max} نمایش داده می‌شود و ارائه‌کننده بیشینه مقدار چگالی توان طیف نرمال و متمرکز شده مربوط به دامنه لحظه‌ای سیگنال دریافتی است. طبق قضیه پارسوال چگالی طیف توان یک سیگنال معادل با مربع قدر مطلق دنباله‌های DFT^۵ آن سیگنال است و بنابراین γ_{max} را می‌توان به صورت رابطه ۲ بیان کرد.

$$\gamma_{max} = \frac{\max |DFT(a_{cn}(i))|^2}{N_s} \quad (2)$$

در این رابطه a_{cn} با استفاده از رابطه‌های ۳، ۴ و ۵ قابل محاسبه است.

در سال ۲۰۰۸ میلادی Neshatian و همکارش از GP (Genetic programming) برای کاهش تعداد ویژگی‌های داده‌های استاندارد مربوط به حوزه یادگیری ماشین^۱ استفاده کرد (Neshatian and Zhang, 2008). در سال ۲۰۱۰ میلادی Zhu و همکارانش از ترکیب برنامه‌نویسی ژنتیک^۲ و K نزدیک‌ترین همسایه^۳ برای تشخیص خودکار مدولاسیون استفاده کرد. وی از GP برای جداسازی مدولاسیون‌ها و از KNN برای محاسبه تابع برازندگی GP استفاده کرد (Zhu, Aslam et al.; 2010).

پیدا کردن ویژگی‌های مناسب، قدم مهمی برای تشخیص خودکار مدولاسیون است. (Shrme, 2011). در روش‌های تشخیص خودکار مدولاسیون ارائه‌شده، از ترکیب چند ویژگی به‌عنوان ویژگی مناسب برای جداسازی هر مدولاسیون استفاده نشده است. هم‌چنین انتخاب ویژگی مناسب برای جداسازی مدولاسیون‌ها به صورت تجربی انجام می‌شود. در این مقاله سعی می‌شود از GP برای انتخاب هوشمند ویژگی‌های ورودی تشخیص خودکار مدولاسیون استفاده شود. تعداد ویژگی‌های به دست آمده از GP برابر انواع مدولاسیون‌های خروجی است. ویژگی‌ها در جستجوی GP به‌گونه‌ای انتخاب می‌شوند که کارایی جداکننده افزایش یابد؛ لذا این پژوهش در افزایش کارایی جداکننده شبکه عصبی پرسپترون در امر شناسایی خودکار مدولاسیون کاربرد دارد. هم‌چنین اگر تعداد ویژگی‌های مسئله تشخیص خودکار مدولاسیون از تعداد مدولاسیون‌های خروجی بیشتر باشد، با بهره‌گیری از روش پیشنهادی در این پژوهش می‌توان تعداد ویژگی‌های مسئله را کاهش داد.

ساختار مقاله به صورت زیر است. در بخش دوم مدل سیگنال، خصوصیات آماری سیگنال و ویژگی‌های اصلی استفاده شده شرح داده می‌شود. ساختار الگوریتم تولید ویژگی‌های اولیه برای GP و هم‌چنین ساختار GP در بخش سوم توضیح داده می‌شود. ارزیابی کارایی و تحلیل حاصل از نتایج به دست آمده در بخش بعد شرح داده و نتیجه‌گیری در بخش پایانی ارائه می‌شود.

۲- مدل سیگنال و ویژگی‌ها

در این بخش مدل سیگنال و ویژگی‌های استفاده‌شده در این مقاله شرح داده می‌شود.

¹ Machine Learning

² Genetic Programming (GP)

³ K-Nearest Neighborhood (KNN)

⁴ Additive White Gaussian Noise (AWGN)

⁵ Discrete Fourier transform (DFT)



۲-۲-۳- انحراف معیار مرحله لحظه‌ای غیر خطی

این ویژگی با σ_{dp} نمایش داده می‌شود. این ویژگی شباهت زیادی به ویژگی قبل دارد با این تفاوت که در محاسبه σ_{dp} در قسمت دوم رابطه قدر مطلق وجود ندارد و مقدار واقعی جزء غیرخطی مرحله لحظه‌ای در محاسبه‌ها شرکت می‌کند. این ویژگی برابر با انحراف استاندارد مقدار واقعی جز غیرخطی متمرکز شده فاز لحظه‌ای است. σ_{dp} به صورت رابطه ۷ محاسبه می‌شود:

$$\sigma_{dp} = \sqrt{\frac{1}{C} \left(\sum_{a_n(i) > a_t} \phi_{NL}^2 \right) - \left(\frac{1}{C} \sum_{a_n(i) > a_t} \phi_{NL} \right)^2} \quad (7)$$

که در این رابطه ϕ_{NL} جزء غیرخطی متمرکز شده مرحله لحظه‌ای مربوط به لحظه t است. این ویژگی، سیگنال‌های دارای اطلاعات مرحله مستقیم 2PSK را از 2ASK و 4ASK جدا می‌کند (Nandi and Azzouz, 1998). متغیرهای استفاده شده در این رابطه مشابه رابطه ۲-۲-۲ می‌باشند.

۲-۲-۴- انحراف معیار قدر مطلق دامنه لحظه‌ای

این ویژگی با σ_{aa} نمایش داده می‌شود و برابر با انحراف معیار قدر مطلق دامنه لحظه‌ای هنجار، هنگامی که سیگنال از سطح آستانه خاص بیش‌تر باشد، تعریف می‌شود. σ_{aa} به صورت رابطه ۸ محاسبه می‌شود. این معیار سیگنال‌های دارای اطلاعات قدر مطلق دامنه 4ASK را از 2ASK جدا می‌کند (Nandi and Azzouz, 1998). متغیرهای استفاده شده در این رابطه، مشابه متغیرهای استفاده شده در رابطه ۲-۲-۲ هستند.

$$\sigma_{aa} = \sqrt{\frac{1}{N_s} \left(\sum_{i=1}^{N_s} a_{cn}^2 \right) - \left(\frac{1}{N_s} \sum_{i=1}^{N_s} |a_{cn}| \right)^2} \quad (8)$$

۲-۲-۵- انحراف معیار قدر مطلق فرکانس لحظه‌ای

این ویژگی با σ_{af} نمایش داده می‌شود و برابر با انحراف معیار قدر مطلق فرکانس لحظه‌ای هنجار، هنگامی که سیگنال از سطح آستانه خاص بیش‌تر باشد، تعریف می‌شود. σ_{af} به صورت رابطه ۹ محاسبه می‌شود. این معیار سیگنال‌های دارای اطلاعات قدر مطلق دامنه 4FSK را از 2FSK جدا می‌کند (Nandi and Azzouz, 1998).

$$a_{cn}(i) = a_n(i) - 1 \quad (3)$$

$$a_n(i) = \frac{a(i)}{m_a} \quad (4)$$

$$m_a = \frac{1}{N_s} \sum_{i=1}^{N_s} a(i) \quad (5)$$

N_s تعداد نمونه‌های گرفته شده در هر بخش از سیگنال، $a_n(i)$ دامنه لحظه‌ای نرمال شده^۱، $a_{cn}(i)$ مقدار دامنه لحظه‌ای نرمال شده و جابه‌جاشده به مرکز^۲ مربوط به زمان $t = \frac{i}{f_s}$ است، به نحوی که: $i = 1, 2, \dots$ و f_s فرکانس نمونه‌برداری هر بخش از سیگنال و m_a مقدار متوسط نمونه‌های دامنه لحظه‌ای هر بخش از سیگنال دریافتی است. این معیار سیگنال‌هایی را که اطلاعات دامنه مانند 2ASK، 4ASK، 2PSK و 4PSK دارند، از سیگنال‌های 2FSK و 4FSK جدا می‌کند.

۲-۲-۲- انحراف معیار قدر مطلق مرحله لحظه‌ای غیر خطی

این ویژگی با σ_{ap} نمایش داده می‌شود و به انحراف استاندارد قدر مطلق جزء غیرخطی و متمرکز شده مرحله لحظه‌ای سیگنال، هنگامی که سیگنال از سطح آستانه خاص بیش‌تر باشد، تعریف می‌شود. بنابراین σ_{ap} را می‌توان به صورت رابطه ۶ بیان کرد.

که در این رابطه ϕ_{NL} جزء غیرخطی متمرکز شده مرحله لحظه‌ای مربوط به لحظه t است؛ به نحوی که $t = \frac{i}{f_s}$ و $i = 1, 2, \dots, N_s$ است. همچنین C برابر با جمع تعداد نمونه‌های مربوط به مرحله لحظه‌ای $\phi_{NL(i)}$ است که دامنه لحظه‌ای متناظر با نمونه آنها از یک سطح آستانه خاص بیش‌تر باشد. به عبارت دیگر اگر $a_n(i)$ دامنه لحظه‌ای نرمال شده متناظر با مرحله $\phi_{NL(i)}$ و a_t سطح آستانه مورد بحث باشد، C تعداد نمونه‌های سیگنال بالاتر از سطح آستانه است. این ویژگی، سیگنال‌های دارای اطلاعات قدر مطلق مرحله 4PSK را از 2ASK، 4ASK و 2PSK جدا می‌سازد (Nandi and Azzouz, 1998).

(۶)

$$\sigma_{ap} = \sqrt{\frac{1}{C} \left(\sum_{a_n(i) > a_t} \phi_{NL}^2 \right) - \left(\frac{1}{C} \sum_{a_n(i) > a_t} |\phi_{NL}| \right)^2}$$

¹ Normalized
² Centered

اساس فرضیه بقای بهترین‌ها (داروین) و انجام عمل ژنتیکی بهبود و توسعه می‌یابند. به‌طور خلاصه برنامه‌نویسی ژنتیک، برنامه‌های رایانه‌ای را در سه مرحله زیر بهبود می‌بخشد تا به پاسخ مطلوب دست یابد:

۱- یک جمعیت اولیه از ترکیبات تصادفی توابع و پایانه‌ها (آرگومان‌ها) ایجاد می‌کند (مدل‌های تصادفی اولیه)

۲- مراحل زیر را تکرار می‌کند تا شرط پایان برنامه‌نویسی ژنتیک برقرار گردد.

◀ هر برنامه از جمعیت اجرا شده و بسته به چگونگی حل مسأله یک مقدار شایستگی به آن اختصاص داده می‌شود.

◀ با استفاده از دو عملگر ابتدایی، جمعیت جدیدی از برنامه‌های رایانه‌ای ایجاد می‌شود.

- برنامه‌های رایانه‌ای نسل قبل متناسب با شایستگی مربوطه انتخاب می‌شوند. (Reproduction)

- برنامه‌های رایانه‌ای انتخابی، دو به دو باهم ترکیب می‌شوند و در جمعیت جدید قرار می‌گیرند. (Crossover)

۳- بهترین برنامه رایانه‌ای که در طول برنامه‌نویسی ژنتیک به دست آمده است، به‌عنوان جواب نهایی انتخاب می‌شود.

منظور از توابع در بند ۱ کلیه توابعی است که به نظر می‌رسد برای حل مسئله لازم باشند و یا به احتمال به حل بهتر و سریع‌تر مسئله کمک می‌کنند. اما پایانه‌ها عبارت‌اند از متغیرها و یا مقادیر ثابت که در حل مسئله به‌کاربرده می‌شوند.

در شکل (۱) روندنمای کلی روش نشان داده شده است. در مرحله پیش‌پردازش یک تبدیل خطی متعامد مبتنی بر نوع مدولاسیون^۱ به مجموعه ویژگی‌های اصلی اعمال می‌شود. مراحل عملیات این تبدیل به این شرح است:

اگر مجموعه داده‌های ورودی X توسط تبدیل D به نوع مدولاسیون آن‌ها نگاشت داده شود $(D: X \rightarrow C)$ ، آن گاه هدف یافتن فضای جدیدی از ویژگی‌های ورودی مانند Y است که بتوان توسط تبدیل D' ویژگی‌ها را به‌صورت ساده‌تر به نوع مدولاسیون آنها نگاشت داد $(D': Y \rightarrow C)$. در این روابط، C مجموعه انواع مدولاسیون‌ها و m تعداد انواع

^۱ Modulation-wise orthogonal linear transformation

$$\sigma_{af} = \sqrt{\frac{1}{C} \left(\sum_{a_n(i) > a_t} f_N^2(i) \right) - \left(\frac{1}{C} \sum_{a_n(i) > a_t} |f_N(i)| \right)^2} \quad (9)$$

در این رابطه $f_N(i)$ با استفاده از رابطه‌های ۱۰ و ۱۱ قابل محاسبه است.

$$f_N(i) = \frac{f(i) - m_f}{r_s} \quad (10)$$

$$m_f = \frac{1}{N_s} \sum_{i=1}^{N_s} f(i) \quad (11)$$

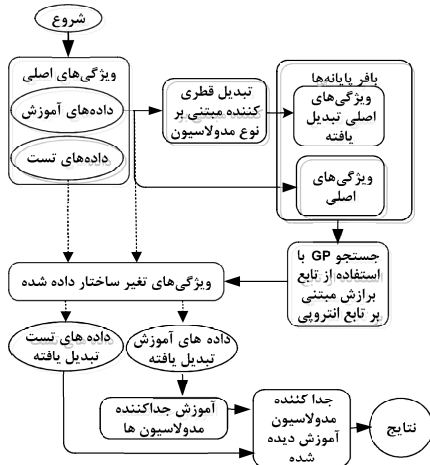
در این رابطه m_f مقدار متوسط نمونه‌های فرکانس لحظه‌ای هر بخش از سیگنال دریافتی، r_s نرخ علائم سیگنال ورودی و سایر متغیرهای استفاده‌شده مشابه رابطه ۲-۲-۲ است.

۳- روش پیشنهادی

در این روش با استفاده از برنامه‌نویسی ژنتیک روشی برای انتخاب ویژگی‌ها در مسأله تشخیص خودکار مدولاسیون ارائه می‌شود تا کارایی طبقه‌بندی بهبود یابد. در برنامه‌نویسی ژنتیکی هدف این است که بدون برنامه‌نویسی صریح، به حل مسأله مورد نظر پرداخته شود. به عبارت دیگر، مطلوب آن است که توسط برنامه‌نویسی ژنتیک یک برنامه رایانه‌ای به دست آید که بتواند مسأله مورد نظر را حل کند و یا حتی‌المقدور پاسخ نهایی را تخمین بزند. باید توجه داشت که اندازه، شکل و پیچیدگی ساختاری برنامه باید قسمتی از پاسخ باشد. از آن جا که فضای برنامه‌های رایانه‌ای بسیار گسترده است، لذا با جستجوی کور و تصادفی نمی‌توان به پاسخ دست یافت و به همین دلیل باید یک راه هوشمندانه و تطبیقی دنبال شود و برای این منظور برنامه‌نویسی ژنتیک استفاده می‌شود. برنامه‌نویسی ژنتیک می‌تواند به منظور پیدا کردن برنامه‌ای که قابلیت حل مسأله مورد نظر را داشته باشد و یا حتی‌المقدور بهتر از بقیه به حل مسئله‌ای بپردازد، فضای برنامه را جستجو کند. برنامه‌های که توسط برنامه‌نویسی ژنتیک به دست می‌آید در رقابتی بر اساس شایستگی حاصل می‌شود. برای این منظور صدها و یا هزاران برنامه رایانه‌ای با اندازه و شکل‌های مختلف که به‌صورت تصادفی خلق شده‌اند، با هم به رقابت پرداخته و این برنامه‌ها بر



پس از انجام پیش‌پردازش لازم، چون m مدولاسیون مجزا در مسئله وجود دارد، $(m \times n)$ ویژگی ساخته می‌شود که با ویژگی‌های اصلی مسئله جمع خواهند شد و مجموعه متغیرهای تولیدشده در جستجوی GP شرکت خواهند داشت. تعداد متغیرها در بافر پایانه‌ها^۱ برابر $n \times (m + 1)$ است. باید دقت کرد که در این مرحله ابعاد مسئله افزایش خواهد یافت. اما به GP این فرصت داده می‌شود که ویژگی‌های سطح بالاتر مناسب را جهت تشخیص خودکار مدولاسیون استخراج کند.



(شکل - ۱): روندنمای پیشنهادی

عمل جستجو در GP بر اساس تابع برازندگی مبتنی بر آنتروپی انجام می‌گیرد. این تابع برازندگی قادر به جداکردن ویژگی‌های حاوی اطلاعات^۲ از ویژگی‌های بدون اطلاعات^۳ است. این تابع برای رتبه‌بندی همهٔ جواب‌ها در جمعیت استفاده می‌شود. به‌طور کلی می‌توان گفت که اندازه‌گیری آنتروپی روی یک بازه‌ای که سیگنال‌های متعلق به یک مدولاسیون قرار دارند یک ابزار مناسب برای کمینه‌کردن احتمال رخداد نمونه‌های مدولاسیون‌های دیگر در آن بازه است. این سیستم اندازه‌گیری دارای دو قسمت است. محدوده مربوط به هر مدولاسیون و دیگری یک متریک برای اندازه‌گیری سطح عدم قطعیت. از آنتروپی داده‌ای که در یک بازه قرار دارد به‌عنوان یک معیار اندازه‌گیری از سطح عدم قطعیت استفاده می‌شود. در این جا از آنتروپی شانون استفاده می‌شود که به‌صورت رابطه ۱۵ تعریف می‌شود.

مدولاسیون‌ها یا کلاس‌ها است. برای به‌کارگیری تبدیل خطی متعامد مبتنی بر نوع مدولاسیون، مجموعه داده‌های آموزش باید به m دسته بر حسب نوع مدولاسیون‌ها تقسیم شوند.

اگر هر دسته یک ابر کره در نظر گرفته شود، محورهای این ابر کره به‌گونه‌ای باید قرار گیرند که در مرز بین سیگنال‌های متعلق به هر مدولاسیون مجزا قرار داشته باشد.

$$X_i = \{x | (x, c) \in D\}, \quad (12)$$

$$\text{where } \bigcup_{i=1}^m X_i = X$$

برای پیدا کردن یک تبدیل با خصوصیات ذکرشده، باید کوواریانس داده‌ها در هر قسمت قطری شود. کوواریانس قسمت i به‌صورت رابطه ۱۳ محاسبه می‌شود.

$$\Sigma_i = E\{X_i X_i^T\} - E\{X_i\}E\{X_i^T\} \quad (13)$$

که در این رابطه $E\{X_i\}$ امید ریاضی داده‌های مجموعه $\{X_i\}$ و Σ_i یک ماتریس مربعی $n \times n$ شامل کوواریانس ویژگی‌ها براساس نمونه داده‌های مشاهده شده در قسمت i است. این ماتریس کوواریانس مربوط به قسمت i می‌تواند با تبدیل داده‌های هر قسمت با استفاده از رابطه ۱۴ قطری شود.

$$Y_i = \Phi_i X_i, \text{ where } \Phi_i = \text{eigen}(\Sigma_i) \quad (14)$$

این رابطه مجموعه داده‌های اصلی را طوری نگاشت می‌دهد که محاسبه‌های کوواریانس و بردار ویژه براساس سیگنال‌های متعلق به هر قسمت باشند.

اگر n اندازه فضای ورودی داده‌های اصلی باشد، هر تبدیل n ویژگی میانی تولید می‌کند. این پردازش برای هر قسمت و هر مدولاسیون تکرار خواهد شد و در پایان $m \times n$ بعد جدید ایجاد می‌شود. آن‌گاه فضای داده D فضای تبدیل یافته Y را به‌صورت $Y = \{Y_1, Y_2, \dots, Y_m\}$ استفاده می‌کند.

در این مرحله تعداد ویژگی‌های تشخیص مدولاسیون افزایش می‌یابد و بنابراین ابعاد مسئله افزایش خواهد یافت. با استفاده از یک مکانیزم مناسب می‌توان ابعاد این ویژگی‌ها را کاهش داد. جستجوی GP این اجزا را برای ساختن ویژگی‌های سطح بالاتر ترکیب می‌کند و یک تابع رتبه‌بندی را برای انتخاب ویژگی‌هایی که حاوی اطلاعات بیش‌تر هستند استفاده می‌کند.

¹ Terminal Pool

² Informative

³ Non Informative

GP باید انجام شود. در هر اجرا تابع برازندگی روی یک مدولاسیون مشخص متمرکز می‌شود. در انتهای اجرا، بهترین برنامه ارزیابی شده، به‌عنوان ویژگی برای آن مدولاسیون استفاده می‌شود. بنابراین برای مسئله تشخیص خودکار مدولاسیون، تعداد ویژگی‌ها برابر با تعداد مدولاسیون‌هاست. به‌عبارت دیگر جستجوی GP بعد از m اجرا از میان $n(m+1)$ ویژگی میانی تعداد m ویژگی تولید می‌کند. خطوط بین داده‌های آموزش و تست اصلی با داده‌های آموزش و آزمون تغییر یافته در شکل (۱) به‌صورت خط‌چین مشخص شده است که نشان‌گر تبدیل مجموعه داده‌های آموزش و آزمون اصلی با استفاده از ویژگی‌های جدید استخراج شده با الگوریتم GP به مجموعه داده‌های آموزش و تست با قالب جدید است. از شبکه عصبی پرسپترون با دو لایه مخفی برای آموزش و جداسازی مدولاسیون‌ها از یکدیگر استفاده شده است. شبکه عصبی مورد نظر با استفاده از داده‌های آموزش و آزمون ایجاد شده از ویژگی‌های جدید، آموزش و ارزیابی می‌شود.

۴- ارزیابی کارایی و تحلیل نتایج شبیه‌سازی

همان‌طور که در بخش ۱ توضیح داده شد، تشخیص خودکار مدولاسیون از دو قسمت پیش‌پردازش و جداسازی مدولاسیون‌ها تشکیل شده است. از آنجا که اکثر موارد کاربرد تشخیص خودکار مدولاسیون در سیستم‌هایی استفاده می‌شود که به‌صورت برخط^۱ هستند یعنی به‌محض دریافت سیگنال ورودی باید عملیات تشخیص نوع مدولاسیون انجام شود تا نتیجه این تشخیص برای تصمیم‌گیری در این سیستم‌ها مورد استفاده قرار گیرد. پس از انتخاب ویژگی مناسب فرایند محاسبه این ویژگی‌ها در کارت‌های پردازش با سرعت بالا انجام می‌شود. این کارت‌ها به‌طور عمومی کارت‌های^۲ FPGA می‌باشند تا فرایند پردازش در این کارت‌ها به‌صورت موازی و هم‌زمان انجام شود. لذا در قسمت پیش‌پردازش، نخست ویژگی‌های اصلی استخراج می‌شود. برای شبیه‌سازی استخراج ویژگی‌ها در این مطالعه از ابزار GPLAB (Silva, 2007) در محیط مطلب استفاده شد. جهت بررسی عملکرد روش پیشنهادی، این روش را با

$$H_2 = \log_2 \sum_{c \in C} \frac{1}{p_1^2(c)} \quad (15)$$

در این رابطه، I بازه‌ای است که حاوی داده‌های مربوط به مسئله ساختن ویژگی‌های جدید به‌عنوان یک مسئله بهینه‌سازی با هدف کمینه‌کردن رابطه ۱۵ بیان می‌شود. در واقع این بازه‌ای است که باید تخمین زده شود و حاوی داده‌های مربوط به نوع مدولاسیون c است، C مجموعه همه کلاس‌ها یا نوع مدولاسیون‌های خروجی است و $P_1(c)$ احتمال کلاس c در بازه I در نظر گرفته شده است و به وسیله فرکانس رخداد کلاس c در بازه I محاسبه می‌شود.

برای کمینه‌کردن $H_2(I)$ عبارت $\sum_{c \in C} p_1^2(c)$ باید بیشینه شود. تنها راه برای بیشینه‌کردن این عبارت، افزایش احتمال رخداد سیگنال‌های مربوط به مدولاسیون مورد نظر و کاهش احتمال رخداد دیگر مدولاسیون‌هاست. به‌عبارت دیگر ویژگی مطلوب است که تمام نمونه‌های مربوط به یک مدولاسیون را در یک بازه عددی جمع کند و در آن بازه نمونه‌های مربوط به سایر مدولاسیون‌ها نباشد. مراحل برای ارزیابی یک عضو جمعیت i (برنامه تولید شده توسط GP) برای یک مدولاسیون هدف t (یک ویژگی برای جدا کردن سیگنال‌های با مدولاسیون t) روی یک مجموعه داده‌های آموزش S به‌صورت زیر است:

(۱) از برنامه i برای تبدیل هر نمونه در مجموعه داده‌های آموزش S به یک مجموعه تبدیل شده S' استفاده شود. برنامه مقادیر ویژگی‌های اصلی را از بافر متغیرهای GP می‌گیرد و یک مقدار اعشاری ممیز شناور برای هر نمونه تولید می‌کند. بنابراین S' یک بعدی خواهد بود.

(۲) یک بازه S' که شامل ۹۹ درصد از نمونه‌های مدولاسیون t باشد به‌عنوان بازه مطلوب در نظر گرفته می‌شود.

(۳) همه نمونه‌هایی از S' که در بازه I_t قرار دارند، جمع‌آوری می‌شود. عبارت $\sum_{c \in C} \frac{1}{p_1^2(c)}$ روی داده‌های درون بازه مورد نظر محاسبه می‌شود. اگر بیش‌تر نمونه‌هایی که درون یک بازه قرار گرفته‌اند و این نمونه‌ها متعلق به یک مدولاسیون باشند، مقدار تابع برازندگی برای آنها به‌طور کامل پایین خواهد بود. براساس این طراحی، مقدار تابع برازندگی کم‌تر، برنامه را بهتر می‌کند و در نتیجه ویژگی‌های بهتری تولید می‌کند. برای هر مدولاسیون در مسئله فقط یک اجرای

¹ Online

² field-programmable gate array



(جدول - ۱): تنظیمات شبکه عصبی پرسپترون

مقدار	پارامتر	
پرسپترون چندلایه	نوع شبکه عصبی	۱
۱۵۰۰۰۰	Maximum epoch	۲
۰/۰۰۰۰۱	Required error goal	۳
۰/۰۰۰۰۱	نرخ آموزش اولیه ^۱	۴
۱/۰۴	مقدار افزایش نرخ آموزش ^۲	۵
۰/۷	مقدار کاهش نرخ آموزش ^۳	۶
۲	تعداد لایه‌های پنهان	۷
۱۰	تعداد نودها در لایه پنهان اول	۸
۱۰	تعداد نودها در لایه پنهان دوم	۹
۵	تعداد نرون‌ها در لایه ورودی	۱۰
Log-sigmoid	توابع تحریک گره‌ها در لایه پنهان اول	۱۱
Linear	توابع تحریک گره‌ها در لایه پنهان دوم	۱۲
Log-sigmoid	توابع تحریک گره‌ها در لایه خروجی	۱۳
مجموع مربعات خطا	ارزیابی کارایی	۱۴
۰/۹	مقدار ثابت momentum (m_c)	۱۵

نحوه آزمون جداکننده مدولاسیون‌ها به صورت 10-fold cross validation است. نتایج در جدول‌های زیر به صورت Confusion Matrix نشان داده شده است. در هر سطر از جدول‌های زیر مدولاسیون شبیه‌سازی شده در ستون اول هر جدول مشخص شده است. نتایج حاصل از جداسازی مدولاسیون‌ها در ستون‌های دیگر جدول به صورت نسبت از صد نشان داده شده است. مقدار غیر صفر ستون‌های متفاوت از مدولاسیون مورد نظر نسبت جداسازی اشتباه برای آن مدولاسیون است.

(جدول - ۲): جداسازی مدولاسیون‌ها با استفاده از ویژگی‌های

اصلی (SNR=5db) دقت ۸۳٪ جداسازی ۸۳/۸۲ درصد

نوع مدولاسیون استنتاج شده از الگوریتم						نوع مدولاسیون
4PS K	2PS K	4FSK	2FS K	4ASK	2AS K	
0	0	0	0	0	100	2ASK
0	0	0	0	100	0	4ASK
0	0	35	65	0	0	2FSK
7	0	54	39	0	0	4FSK
0	100	0	0	0	0	2PSK
84	1	10	5	0	0	4PSK

¹ Learning rate(lr)

² Learning rate increment(lr_{inc})

³ Learning rate increment(lr_{dec})

سیگنال‌های مدوله‌شده با مقدار سیگنال به نوفه‌های 5db و 10db و مدولاسیون‌های 4FSK, 2FSK, 4ASK, 2ASK و 2PSK و 4PSK مورد بررسی قرار گرفت.

برای تهیه داده‌های آموزش، ۶۰۰ سیگنال مختلف که به صورت تصادفی با یکی از مدولاسیون‌های ذکر شده مدوله شده‌اند، تولید شد. از هر سیگنال ۴۰۰۰ نمونه متوالی، با فرکانس نمونه‌برداری ۸۰ کیلوهرتز، نمونه‌برداری شد. از GP برای جستجو و ساختن ویژگی‌های جدید استفاده شد. تعداد این ویژگی‌ها برابر تعداد انواع مدولاسیون‌های خروجی است. از ساختار درخت برای نمایش خروجی GP استفاده شده است. هر درخت یک مقدار اعشاری به عنوان خروجی تولید می‌کند. مجموعه پایانه‌های استفاده‌شده شامل تابع rand نرم‌افزار مطلب و اعداد ۰، ۱، ۲، ۳، ۴، ۵، ۶، ۷، ۸، ۹ و مجموعه توابع GP از چهار عمل‌گر اصلی جمع، تفاضل، ضرب و تقسیم تشکیل شده‌اند. دلیل استفاده از این عمل‌گرها و پایانه‌ها این است که نتایج به دست آمده از اعمال این عمل‌گرها بر روی این پایانه‌ها و ویژگی‌ها، ویژگی‌های شایسته‌تری در مرحله میانی تولید می‌کند. برای تولید برنامه‌های اولیه از روش ramped half-and-half و از سیاست elitism برای انتقال بهترین والد به نسل بعد استفاده شده است. اندازه جمعیت ۱۰۲۴ و بیش‌ترین عمق درخت‌ها در هنگام مقداردهی شش در نظر گرفته شده است. این مقدار در حین اجرا تا عمق ۱۲ می‌تواند افزایش یابد. نرخ تولید مثل و جهش مقدار ۰/۰۵ تنظیم شد و فرآیند تکامل برای هر مدولاسیون بعد از ۲۵ نسل متوقف می‌شود. مقدار این پارامترها بر این اساس صورت گرفته است که در طی فرآیند تکامل، تعداد مناسبی از نامزدهای جواب در بافر جواب‌ها وجود داشته باشد؛ و مقدار این پارامترها به صورت آزمون و خطا و در طی آزمایش‌ها به دست آمده است.

در جدول‌های ۲ و ۳، مدولاسیون‌ها با SNR=5db و در جدول‌های ۴ و ۵، مدولاسیون‌ها با SNR=10db با هم مقایسه شده‌اند. برای هر گروه از سیگنال‌ها با ویژگی‌های اصلی و ویژگی‌های به دست آمده با جستجوی GP، نتایج جداسازی با شبکه عصبی دولایه پرسپترون با هم مقایسه شده‌اند. تنظیمات شبکه عصبی استفاده‌شده برای اجرای شبکه عصبی مورد نظر مطابق جدول (۱) است.

شبکه عصبی پرسپترون با دو لایه مخفی برای جداسازی مدولاسیون‌ها استفاده شده است.

همان‌طور که مشاهده می‌شود کارایی الگوریتم شبکه عصبی چندلایه پرسپترون برای جداسازی مدولاسیون‌ها در سیگنال به نوفه‌های 5db و 10db با استفاده از ویژگی‌های ایجاد شده توسط روش پیشنهادی بهبود یافته است. البته در سیگنال به نوفه پایین‌تر این افزایش قابل ملاحظه‌تر است. به عبارت دیگر در داده‌های نوفه‌ای با تغییر فضای ویژگی‌ها و اعمال یک تبدیل خطی متعامد مبتنی بر نوع مدولاسیون^۱ به مجموعه ویژگی‌های اصلی در مرحله پیش‌پردازش، فضای ویژگی‌ها به فضای تفکیک پذیرتری تبدیل می‌شود. در مرحله تغییر فضای ویژگی‌ها تعداد ویژگی‌ها افزایش یافته است. لذا در طی فرایند تکاملی جستجوی GP با استفاده از تابع برازندگی مبتنی بر "آنتروپی" ویژگی‌هایی که قدرت جداکنندگی بیش‌تری دارند، به عنوان ویژگی مناسب برای تفکیک هر مدولاسیون پیدا می‌کند. به همین دلیل کارایی شبکه عصبی پرسپترون با دو لایه مخفی افزایش یافته است.

۵- نتیجه گیری

هدف از این تحقیق استفاده از برنامه نویسی ژنتیک برای انتخاب هوشمند ویژگی‌ها در جهت افزایش کارایی شبکه عصبی چندلایه پرسپترون به عنوان جداکننده، برای جداسازی مدولاسیون‌ها بود. این فرآیند از چهار گام مهم تشکیل شده است: اولین گام استخراج ویژگی‌های معمول و تشکیل مجموعه داده‌های آموزش است. در گام دوم با استفاده از تبدیل مبتنی بر مدولاسیون، فضای ویژگی‌های اصلی به یک فضای جداپذیرتر تبدیل می‌شود. در گام سوم فضای ویژگی‌های جدید به عنوان ورودی بافر پایانه جستجوی GP استفاده می‌شود تا ویژگی‌های سطح بالاتری بسازد. از مفهوم آنتروپی برای ارزیابی کیفیت ویژگی ایجاد شده، استفاده شد. در گام چهارم با استفاده از شبکه عصبی چندلایه پرسپترون اقدام به جداسازی مدولاسیون‌ها شد.

در سیگنال به نوفه 5db و 10db ویژگی‌های ایجاد شده با این روش با ویژگی‌های اصلی بررسی و مقایسه شد. نتایج پیشنهاد می‌دهند که سیستم GP ارائه شده قادر به افزایش کارایی شبکه عصبی مبتنی بر پرسپترون چندلایه است. البته کارایی شبکه عصبی مورد نظر در سیگنال به نوفه‌های پایین‌تر نسبت به سیگنال به نوفه‌های بالاتر بیش‌تر افزایش پیدا می‌کند.

^۱ Modulation-wise orthogonal linear transformation

(جدول-۳): جداسازی مدولاسیون‌ها با استفاده از ویژگی‌های به دست آمده از GP (SNR=5db) دقت جداسازی ۹۴/۸۳ درصد

نوع مدولاسیون استنتاج شده از الگوریتم						
نوع مدولاسیون	2AS K	4A SK	2FS K	4FSK	2PS K	4PS K
2ASK	100	0	0	0	0	0
4ASK	0	100	0	0	0	0
2FSK	0	0	89	11	0	0
4FSK	0	0	15	85	0	7
2PSK	0	0	0	0	100	0
4PSK	0	0	0	5	0	95

(جدول-۴): جداسازی مدولاسیون‌ها با استفاده از ویژگی‌های اصلی (SNR=10db) دقت جداسازی ۹۷/۱۶ درصد

نوع مدولاسیون استنتاج شده از الگوریتم						
نوع مدولاسیون	2AS K	4A SK	2FS K	4FSK	2PS K	4PS K
2ASK	100	0	0	0	0	0
4ASK	0	100	0	0	0	0
2FSK	0	0	91	9	0	0
4FSK	0	0	6	96	0	7
2PSK	0	0	0	0	100	0
4PSK	0	0	0	1	2	96

(جدول-۵): جداسازی مدولاسیون‌ها با استفاده از ویژگی‌های به دست آمده از GP (SNR=10db) دقت جداسازی ۹۸/۵ درصد

نوع مدولاسیون استنتاج شده از الگوریتم						
نوع مدولاسیون	2AS K	4A SK	2FS K	4FSK	2PS K	4PS K
2ASK	100	0	0	0	0	0
4ASK	0	100	0	0	0	0
2FSK	0	0	95	5	0	0
4FSK	0	0	3	97	0	7
2PSK	0	0	0	0	100	0
4PSK	0	0	0	0	1	99

با استفاده از جدول‌های ۲ تا ۵ می‌توان به صورت میانگین نتایج جدول (۶) را به دست آورد. در این جدول دقت جداسازی مدولاسیون‌ها با استفاده از ویژگی‌های اصلی مسأله و ویژگی‌هایی که با استفاده از روش پیشنهادی در مسأله ایجاد شده‌اند مقایسه شده‌اند. در هر دو این روش‌ها از

Soliman, S.S. and S.Z. Hsue, Signal classification using statistical moments. Communications, IEEE Transactions on, 1992. 40(5): p. 908-916.

Wong, M. and Nandi., A., Automatic digital modulation recognition using spectral and statistical features with multi-layer perceptrons. in Signal Processing and its Applications, Sixth International, Symposium on. 2001. IEEE.

Wong, M. and Nandi., A., Automatic digital modulation recognition using artificial neural network and genetic algorithm. Signal Processing, 2004. 84(2): p. 351-365.

Wu, H.C., M. Saquib, and Z. Yun, Novel automatic modulation classification using cumulant features for communications via multipath channels. Wireless Communications, IEEE Transactions on, 2008. 7(8): p. 3098-3105.

Zhu, Z., M.W. Aslam, and A.K. Nandi. Augmented genetic programming for automatic digital modulation classification. in Machine Learning for Signal Processing, IEEE International Workshop on. 2010.



کریم حسام‌پور مدرک کارشناسی خود را در رشته مهندسی نرم‌افزار کامپیوتر از دانشگاه شهید باهنر کرمان و مدرک کارشناسی ارشد خود را سال ۱۳۹۱ در رشته مهندسی کامپیوتر، گرایش هوش ماشین و رباتیک از دانشگاه یزد دریافت کردند. زمینه‌های پژوهشی ایشان پردازش سیگنال، سیستم‌های هوشمند و محاسبات نرم است. نشانی رایانامه ایشان عبارت است از:

k.hessampour@stu.yazd.ac.ir



محمد قاسم‌زاده مدرک کارشناسی خود را در رشته مهندسی کامپیوتر از دانشگاه شیراز و مدرک کارشناسی ارشد را در رشته مهندسی کامپیوتر، گرایش هوش ماشین و رباتیک از دانشگاه صنعتی امیرکبیر دریافت

کردند. ایشان زمستان ۱۳۸۴ دوره دکترای خود در رشته علوم کامپیوتر، الگوریتم و محاسبه‌پذیری را در دانشگاه پتسدام آلمان به اتمام رساندند. زمینه‌های پژوهشی ایشان شامل محاسبه‌پذیری، سیستم‌های هوشمند و محاسبات نرم است.

نشانی رایانامه ایشان عبارت است از:

m.ghasemzadeh@yazd.ac.ir

(جدول-۶): مقایسه کارایی روش استخراج ویژگی‌ها توسط

روش جدید در سیگنال به نوفه‌های مختلف

SNR(db)		میانگین دقت جداسازی مدولاسیون‌ها
۱۰	۵	
۹۷/۱۶	۸۳/۸۳	دقت به دست آمده با ویژگی‌های اصلی مقاله
۹۸/۵	۹۴/۸۳	دقت جداسازی با ویژگی‌های ایجادشده توسط GP

سیاس‌گذاری

این پژوهش با حمایت «وزارت ارتباطات و فناوری اطلاعات- مؤسسه تحقیقات ارتباطات و فناوری اطلاعات» انجام شده است.

مراجع

Carlson, A.B., Crilly., P.B., and Rutledge., J.C., Comm-unication system fourth ed. 2001: McGraw Hill.

Dobre, O.A., et al., Survey of automatic modulation classification techniques: classical approaches and new trends. Communications, IET, 2007. 1(2)p. 137-156.

Hsue, S.Z. and S.S. Soliman. Automatic modulation classification using zero crossing. in Radar and signal processing, IEE Proceedings F. 1990

Lopatka, J. and M. Pedzisz. Automatic modulation classification using statistical moments and a fuzzy classifier. in Signal Processing Proceedings, 5th International Conference on. 2000. IEEE.

Mobasserri, B.G., Digital modulation classification using constellation shape. Signal processing, 2000. 80(2): p. 251-277.

Nandi, A.K. and E.E. Azzouz, Algorithms for automatic modulation recognition of communication signals. Communications, IEEE Transactions on, 1998. 46(4): p. 431-436.

Neshatian, K. and M.Zhang. Genetic programming for performance improvement and dimensionality reduction of classification problems. in Evolutionary Computation, 2008. IEEE World Congress on Computational Intelligence. IEEE Congress on. 2008.

Shrme ,A.E. Hybrid intelligent technique for automatic communication signals recognition using Bees Algorithm and MLP neural networks based on the efficient features, Expert Systems with Applications, 2011. 38(5): p. 6000-6006
Silva, S., GPLAB-a genetic programming toolbox for MATLAB, version 3.0. University of Coimbra, 2007

دو فصلی

