

# یک روش کارآمد برای تشخیص مدولاسیون سیگنال‌های MPSK در کانال‌های محوشونده

سعید حکیمی

زیاد پیچیده و تغییرپذیر با زمان از جمله محوشدگی چندمیسریگی، گسترش داپلر، شیفت فرکانسی و غیره، کاهش و یا حتی بالکل از بین می‌رود [۶] تا [۸]. در [۹] نویسندگان یک طبقه‌بند مدولاسیون بر مبنای مشخصات عبور از صفر برای سیگنال معرفی کردند. انواع سیگنال‌های در نظر گرفته شده شامل BPSK، QPSK، APSK، BFSK، FSK و FSK<sub>۴</sub> بودند. تصمیم‌گیری در مورد نوع مدولاسیون بر مبنای واریانس دنباله‌های بازه عبور از صفر، هیستوگرام‌های تفاضل فاز و فرکانس بود. مرجع [۱۰] تکنیکی را بر اساس شکل مدولاسیون ارائه کرد. این تکنیک از روش خوشه‌بندی متوسط C-فازی برای طبقه‌بندی FSK<sub>۴</sub>، APSK و ۱۶QAM استفاده کرده است. نرخ صحت شناسایی برای SNR > ۵dB متجاوز از ۹۰٪ بود. نویسندگان [۱۱] تکنیکی برای شناسایی سیگنال‌های ASK<sub>۴</sub>، ASK<sub>۲</sub>، PSK<sub>۴</sub>، PSK<sub>۲</sub>، FSK<sub>۲</sub> و FSK<sub>۴</sub> ارائه کردند. طبقه‌بندی کننده بر مبنای جریان تصمیم بود. این نوع سیگنال‌ها با موفقیت حدود ۹۰٪ در SNR = ۱۰dB شناسایی شدند. در [۱۲] نویسندگان طبقه‌بندی برای تمیزدادن میان سیگنال‌های دیجیتال ASK، FSK و ۱۶QAM، DPSK پیشنهاد دادند. ویژگی‌های انتخابی شامل درجه اوج سیگنال‌ها، تعداد قله‌ها در فاز تابع چگالی احتمال (PDF) و متوسط قدر مطلق فرکانس سیگنال بود. یک طبقه‌بند فازی در این تکنیک استفاده شد. برای SNR > ۵dB شناساگر عملکرد خوبی دارد و برای SNRهای پایین‌تر از ۵ dB عملکرد افت می‌نماید. در [۱۳] نویسندگان روشی با استفاده از شبکه عصبی پرسپترون چندلایه (MLP) با الگوریتم یادگیری انتشار برگشتی (BP) برای شناسایی خودکار نوع سیگنال ارائه کردند. آنها نشان دادند طبقه‌بند شبکه عصبی دارای عملکرد بهتری از سایر طبقه‌بندها مانند K نزدیک‌ترین همسایگی (KNN) می‌باشد. در [۱۴] معیارهای چگالی طیفی توان (PSD) به همراه شبکه‌های عصبی جهت شناسایی نوع سیگنال به کار گرفته شدند. این رویکرد روی انواع سیگنال مانند PSK به خوبی عمل نمود. در [۶] نویسندگان دو طبقه‌بند را معرفی کردند: طبقه‌بند شبکه عصبی و طبقه‌بند آستانه ثابت، جهت شناسایی مدولاسیون آنالوگ و دیجیتال. آنها نشان دادند که طبقه‌بند شبکه عصبی کارایی بالاتری از طبقه‌بند آستانه دارد. در [۱۵] نویسندگان از میانگین و سه ممان بعدی مشخصات لحظه‌ای به عنوان ویژگی برای طبقه‌بندی نوع سیگنال بهره گرفتند. آنها از طبقه‌بندهای مختلفی استفاده کردند و نشان دادند که شبکه عصبی مصنوعی (ANN) دارای عملکرد بهتری از طبقه‌بند KNN و درخت‌های تصمیم باینری معروف می‌باشد. آنها نرخ موفقیت ۹۰٪ را برای محدوده SNR، ۲۵-۱۵ dB گزارش کردند. در [۱۶] نویسندگان شناساگر مبتنی بر ویژگی‌های طیفی دوره‌ای را برای شناسایی AM، USB، LSB، FM، ASK، FSK، BPSK، QPSK و SQPK پیشنهاد کردند. ادعا شد که طیف دوره‌ای مزایای بیشتری از طیف توان در شناسایی انواع سیگنال دارد. نرخ موفقیت این شناساگر حدود ۹۰٪ برای محدوده ۲۵-۵dB

چکیده: شناسایی خودکار نوع مدولاسیون سیگنال‌های دیجیتال برای سامانه‌های مخابرات هوشمند یک ضرورت است. اغلب روش‌های طبقه‌بندی خودکار نوع سیگنال‌های دیجیتال مسئله را در کانال‌های نویز سفید جمع‌شونده بررسی می‌کنند. با این وجود محیط‌های مخابره واقعی از جمله کانال‌های مخابرات بی‌سیم، با اثرات محوشوندگی روبه‌رو هستند. تعداد بسیار کمی از روش‌ها برای کانال‌های محوشدگی ارائه شده است. این مقاله یک روش بسیار کارآمد برای شناسایی نوع سیگنال‌های دیجیتال کلیدزنی جابه‌جایی فاز M-تایی پیشنهاد می‌دهد. روش ارائه‌شده ترکیبی ابتکاری است متشکل از شبکه عصبی پرسپترون چندلایه به عنوان طبقه‌بند و الگوریتم زنبور به عنوان بهینه‌ساز و همچنین یک همسان‌ساز برای کاهش اثرات کانال استفاده شده است. یک ترکیب مناسب از آمارگان مرتبه بالا تا مرتبه هشت، به عنوان مشخصه‌های سیگنال‌ها در نظر گرفته شده است. نتایج شبیه‌سازی کارآمدی بالای تکنیک ارائه‌شده را برای تشخیص نوع سیگنال‌های دیجیتال، حتی در نسبت‌های سیگنال به نویز پایین، تأیید می‌کند.


کلیدواژه: الگوریتم زنبور، تشخیص نوع مدولاسیون، شبکه عصبی.

## ۱- مقدمه

تشخیص نوع مدولاسیون خودکار (AMR) نقش مهمی را در کاربردهای گوناگون ایفا می‌کند. برای مثال، AMR می‌تواند برای مدیریت طیف، مراقبت الکترونیکی، نظارت، مدیریت ترافیک شبکه، تخصیص نرخ داده متفاوت، تأیید سیگنال، شناسایی تداخل، رادیو نرم‌افزار، مودم‌های هوشمند و غیره به کار گرفته شود [۱] تا [۳]. به علت افزایش استفاده از سیگنال‌های دیجیتال در تکنولوژی‌های جدید، این مقاله بر روی طبقه‌بندی نوع سیگنال‌های دیجیتال تمرکز می‌کند. به طور کلی، روش‌های طبقه‌بندی خودکار مدولاسیون به دو گروه تقسیم می‌شوند: تئوری تصمیم (DT) و تشخیص الگو (PR). رهیافت‌های DT برای فرموله کردن مسئله طبقه‌بندی از آرگومان‌های احتمالاتی و آزمون فرضیات استفاده می‌کنند [۱]، [۴] و [۵]. اشکال اساسی این روش‌ها پیچیدگی محاسباتی زیاد و فقدان قابلیت تعمیم‌پذیری در عدم مطابقت مدل است. در حالی که رهیافت‌های PR بی‌نیاز از چنین عملیات دقیقی هستند و به راحتی قابل اجرا هستند. روش‌های PR شامل دو زیرسامانه استخراج ویژگی و طبقه‌بند هستند که اولی ویژگی‌های سیگنال‌ها را استخراج و دومی عضویت آنها را تعیین می‌کند. در حال حاضر اغلب طبقه‌بندهای مدولاسیون در کانال‌های نویز سفید جمع‌شونده AWGN کار می‌کنند. عملکرد این طبقه‌بندها در سناریوهای واقعی با وجود فاکتورهای بسیار

این مقاله در تاریخ ۱۰ تیر ماه ۱۳۹۲ دریافت و در تاریخ ۳ فروردین ماه ۱۳۹۳ بازنگری شد.

سعید حکیمی، دانشکده مهندسی، دانشگاه فردوسی مشهد، مشهد، (email: hakimi.saeed@mail.um.ac.ir)



شکل ۲: مدل مورد استفاده برای کانال.

بنابراین همسان‌سازی باید به صورت کور، تنها با استفاده از خصوصیات ساختاری و آماری رشته داده ارسال‌شده، صورت پذیرد. ماژول استخراج ویژگی ممان‌های مرتبه بالاتر و کومولان‌های مرتبه بالاتر تا هشت را استخراج می‌نماید. ماژول طبقه‌بند از شبکه عصبی MLP تشکیل می‌شود. ماژول BA تعداد ویژگی‌هایی که به طبقه‌بند تزریق می‌شوند را کاهش می‌دهد و پارامترهای همسان‌ساز را بهینه می‌سازد.

این مقاله به صورت زیر سازمان‌دهی شده است: در بخش ۲ همسان‌سازی کانال توضیح داده خواهد شد. ماژول استخراج ویژگی در بخش ۳ توصیف خواهد شد. شبکه عصبی MLP در بخش ۴ توضیح داده می‌شود. در بخش ۵، BA به عنوان بهینه‌ساز شرح داده خواهد شد و نهایتاً در بخش ۷ مقاله نتیجه‌گیری می‌شود.

## ۲- همسان‌سازی کور کانال

در سناریوهای دنیای واقعی، کانال انتقال به عنوان عاملی مهم ممکن است اعوجاج غیر قابل‌بازایی را روی سیگنال، مخصوصاً برای سیگنال‌های دیجیتال مرتبه بالاتر، باعث شود. جهت کاهش اثرات پراکندگی کانال‌ها، یک مرحله همسان‌سازی معمولاً در گیرنده مورد استفاده قرار می‌گیرد. در کاربردی مانند طبقه‌بندی نوع سیگنال، دنباله آموزشی مورد نیاز برای تنظیم ضرایب همسان‌ساز در دسترس نمی‌باشد و بنابراین همسان‌سازی باید به صورت کورد انجام شود. مدل سیستم، مورد استفاده در همسان‌سازی و شناسایی در شکل ۲ نشان داده شده که در آنجا  $h(t, \tau)$  پاسخ ضربه کانال متغیر با زمان،  $x(t)$  سیگنال دریافت‌شده،  $s(t)$  دنباله ورودی و  $v(t)$  AWGN است. سیگنال ورودی را جمع آثار  $N_p$  مسیر فرض می‌نماییم. پاسخ ضربه کانال منتج می‌تواند با استفاده از توزیع گوسی مدل پراکندگی ناهمبسته ایستا به مفهوم عام (WSSUS) [۲۲] توصیف شود

$$h(t, \tau) = \frac{1}{\sqrt{N_p}} \sum_{p=1}^{N_p} e^{j(\pi f_{d,p} t + \theta_p)} h_{RF}(\tau - \tau_p) \quad (1)$$

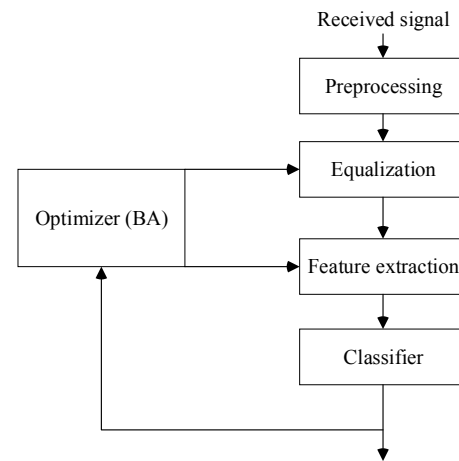
که در آن  $f_{d,p}$  پراکندگی داپلر مسیر  $p$  به علت حرکت گیرنده است. بیشینه پراکندگی داپلر می‌تواند توسط  $f_{d,max} = v_{MS} / \lambda$  بیان شود که در آن  $v_{MS}$  سرعت ایستگاه موبایل و  $\lambda$  طول موج سیگنال می‌باشد.  $\theta_p$  پراکندگی زاویه‌ای مسیر  $p$  است که متغیری تصادفی با توزیع یکنواخت در بازه  $[-\pi, \pi]$  می‌باشد.  $\tau_p$  پراکندگی تأخیر مسیر است که متغیری تصادفی با PDF متناسب با طیف تأخیر توان میانگین محیط انتشار می‌باشد و  $h_{RF}(t)$  پاسخ ضربه فیلتر گیرنده است.

سیگنال دریافت‌شده زمان پیوسته به صورت زیر است

$$x(t) = \sum_{k=-\infty}^{\infty} s(k)h(t-kT) + v(t) \quad (2)$$

که در آن  $T$  تناوب سمبل داده است. سیگنال دریافت‌شده زمان گسسته معادل به صورت زیر است

$$x(n) = \sum_{k=-L}^{L-1} s(k)h(n-k) + v(n) \quad (3)$$



شکل ۱: طرح کلی AMR پیشنهادشده.

گزارش شد. در [۱۷] نویسندگان از ویژگی‌های پیشنهادشده در [۱۱] و شبکه عصبی MLP به عنوان طبقه‌بند بهره گرفتند. این شناساگر نرخ موفقیت حدود ۹۳٪ را در  $SNR = 8\text{dB}$  برای شناسایی سیگنال‌های دیجیتال ۲ASK، ۴ASK، ۲PSK، ۴PSK، ۲FSK، ۴FSK و ۱۶QAM نشان داد. در [۱۸] نویسندگان چهار ویژگی جهت طبقه‌بندی ۲ASK، ۴ASK، ۲PSK، ۴PSK، ۲FSK و ۴FSK پیشنهاد کردند. این ویژگی‌ها بر اساس دو گام پردازش اصلی استخراج شدند. اولین گام ضرب دو مقدار متوالی سیگنال می‌باشد. در گام دوم، میانگین و درجه اوج بخش‌های حقیقی و موهومی مقادیر به دست آمده در گام اول به عنوان ویژگی‌های ورودی طبقه‌بندی مورد استفاده قرار گرفتند. در [۱۹] نویسندگان مطالعه‌ای مقایسه‌ای درباره پیاده‌سازی الگوریتم‌های طبقه‌بندی و استخراج ویژگی مبتنی بر تجزیه موجک گسسته و سیستم استنتاج فازی مبتنی بر شبکه وفقی (ANFIS) برای شناسایی ۸ASK، ۸FSK، ۸PSK و ۸QASK انجام داده‌اند. در [۲۰] نویسندگان روشی عددی برای شناسایی ۲PSK، ۴PSK و ۸PSK در محیط‌های محوشدگی پیشنهاد کردند. مرجع [۲۱] استفاده از برنامه‌ریزی ژنتیکی (GP) را در ترکیب با KNN برای طبقه‌بندی خودکار مدولاسیون بررسی نمودند. چهار نوع مدولاسیون در نظر گرفته شدند: BPSK، QPSK، ۱۶QAM و ۶۴QAM کومولان‌ها به عنوان ویژگی‌های ورودی برای GP مورد استفاده قرار گرفته‌اند. در [۳] آشکارساز مدولاسیون سلسله‌مراتبی کور خودکار جهت تمیز میان BPSK، QPSK و ۱۶QAM در کانال‌های محوشدگی و AWGN اعمال شد. ویژگی‌های ایستای دوره‌ای مرتبه دوم با استفاده از تابع هم‌دوس طیفی با جزئیات ابتدا جهت تمیز میان مدولاسیون BPSK و مدولاسیون‌های غیر BPSK (مثلاً مدولاسیون‌های ۱۶QAM و QPSK) در اولین سطح آشکارساز مدولاسیون سلسله‌مراتبی اعمال می‌شود. سپس ویژگی کومولان مرتبه چهارم روی سیگنال‌های RF غیر BPSK جهت تمیز میان QPSK و ۱۶QAM به کار گرفته شد.

در این مقاله، یک روش AMR بسیار کارآمد برای محیط‌های محوشدگی ارائه شده است. شکل ۱ طرح کلی AMR پیشنهادشده را نمایش می‌دهد که شامل ۵ ماژول اصلی است. در ماژول پیش‌پردازش، اجزای نویز کانال که خارج از پهنای باند سیگنال می‌باشند، حذف می‌شوند، فرکانس حامل تخمین زده می‌شود و پوش مختلط بازایی می‌گردد. جهت کاهش اثر چندمسیری، ماژول همسان‌سازی در گیرنده به کار می‌رود. در بسیاری از کاربردها مانند نظارت و مدیریت طیف، هیچ دنباله آموزش معمولی برای تنظیم ضرایب همسان‌ساز در دسترس نیست.

### ۳- استخراج ویژگی

ویژگی‌ها نقش حیاتی در طبقه‌بندی مدولاسیون ایفا می‌نمایند. یافتن ویژگی‌های مناسب جهت تعیین انواع مختلف سیگنال مسأله‌ای بحرانی است زیرا انواع مختلف سیگنال‌های مخابراتی مشخصات متفاوتی دارند [۲۷]. همان طور که در بخش ۲ اشاره شد، انتظار می‌رود CMA برای MPSK دارای عملکرد بهتری از سایر انواع مدولاسیون باشد و بنابراین این مقاله قصد دارد میان سیگنال‌های رادیویی زیر تمیز دهد: ۲PSK، ۴PSK، ۸PSK، ۱۶PSK، ۳۲PSK و ۶۴PSK جهت سادگی، سیگنال‌های یادشده به ترتیب با  $P_1, P_2, P_3, P_4, P_5, P_6$  و  $P_7$  جایگزین می‌شوند.

ترکیبی از ممان‌های مرتبه بالاتر و کومولان‌های مرتبه بالاتر، تا هشت، عملکرد بهتر طبقه‌بندها را موجب می‌شود. آمارگان مرتبه بالاتر ابزاری در زمینه پردازش سیگنال آماری می‌باشد که از اطلاعات اضافی به جای معیارهای پردازش سیگنال متداول مانند طیف توان و تابع خودهمبستگی بهره می‌گیرند. مزایای آمارگان مرتبه بالاتر شامل توانایی شناسایی فرایندهای غیر گوسی و سیستم‌های غیر مینیمم فاز و آشکارسازی و توصیف خصوصیات غیر خطی سیگنال می‌باشد. این ویژگی‌ها می‌تواند جهت توصیف PDF سیگنال (توضیحات بیشتر در پیوست) اعمال گردد. رفتارهای ممان‌ها و کومولان‌های مرتبه بالاتر در مقابل تبدیلات مختلف عواملی مهم هستند که تعیین می‌نمایند این مقادیر چقدر ممکن است برای توصیف سیگنال‌ها در سیستم‌ها مفید باشند. تنها اثر انتقال روی سیگنال دریافت‌شده تغییر متوسط آن است. واریانس و تمامی ممان‌ها یا کومولان‌های مرتبه بالاتر بدون تغییر باقی می‌مانند. چرخش منظومه سیگنال دریافت‌شده که توسط چندمسیری یا سایر اعوجاج‌ها ایجاد شده، واریانس‌ها و ممان‌ها یا کومولان‌های مرتبه بالاتر را تحت تأثیر قرار می‌دهند. با این وجود، پارامترهای مشخص دیگری مانند مقادیر ویژه و ماتریس کوواریانس در مقابل چرخش تغییرناپذیر می‌باشند. زیربخش بعدی این ویژگی‌ها را به طور خلاصه توصیف می‌نماید.

#### ممان‌های مرتبه بالاتر و کومولان‌های مرتبه بالاتر

ممان‌های توزیع احتمال تعمیمی از مفهوم امید ریاضی می‌باشند. یادآوری می‌شود که عبارت کلی برای ممان  $i$ ام متغیری تصادفی توسط معادله زیر به دست می‌آید [۲۷]

$$\mu_i = \int_{-\infty}^{\infty} (s-m)^i f(s) ds \quad (10)$$

که در آن  $m$  میانگین متغیر تصادفی و  $f(\cdot)$  PDF متغیر تصادفی  $s$  می‌باشد. تعریف ممان  $i$ ام برای سیگنال گسسته با طول محدود، توسط معادله زیر به دست می‌آید

$$\mu_i = \sum_{k=1}^N (s_k - m)^i f(s_k) \quad (11)$$

که در آن  $N$  طول داده است. در این مقاله، سیگنال‌ها دارای میانگین صفر فرض می‌شوند و بنابراین

$$\mu_i = \sum_{k=1}^N s_k^i f(s_k) \quad (12)$$

سپس، خود ممان متغیر تصادفی می‌تواند به صورت زیر تعریف شود

$$M_{pq} = E[s^{p-q} (s^*)^q] \quad (13)$$

که در آن  $h(n)$  ضرایب محوشدگی برای کانال چندمسیره با طول  $L$ ،  $s(k)$  دنباله سمبل‌های اطلاعات و  $v(n)$  AWGN است. پاسخ  $h(t)$  دارای طول محدود فرض می‌شود.

همسان‌ساز مبتنی بر الگوریتم قدر مطلق ثابت (CMA) [۲] و [۲۳] تا [۲۵] تاکنون متداول‌ترین طرح همسان‌سازی کور با پیچیدگی کم است زیرا به سهولت محدودیت محاسباتی زمان واقعی را برآورده می‌سازد. CMA الگوریتم گرادبان تصادفی است که وزن همسان‌ساز را الزام می‌نماید تا پوشه ثابتی را حفظ کند. در نتیجه انتظار می‌رود CMA برای PSK عملکرد بهتری از سایر تکنیک‌های مدولاسیون دیجیتال داشته باشد. مرجع [۲۶] مروری بسیار خوب بر مطالعات مربوط به رفتار همگرایی CMA انجام داده است. تابع هزینه CMA به صورت زیر است

$$J(k) = E\{|y(k)|^2 - \gamma\} \quad (4)$$

که در آن  $y(k)$  خروجی برابر است.  $\gamma$  ثابت پراکندگی توسط معادله زیر تعریف می‌شود

$$\gamma = \frac{M_{\gamma_+}}{M_{\gamma_-}} \quad (5)$$

که در آن  $M_{\gamma_+}$  و  $M_{\gamma_-}$  به ترتیب ممان‌های مرتبه چهارم و دوم سیگنال دریافت‌شده  $x(t)$  می‌باشند. در این مقاله، مدولاسیون MPSK در نظر گرفته شده و بنابراین ثابت پراکندگی برای تمامی سیگنال‌ها یکتا می‌باشد. تابع هزینه  $J(k)$  به طور تکراری با استفاده از الگوریتمی مبتنی بر گرادبان کمینه شده است.

در سیستم همسان‌سازی CMA استاندارد، فرکانس نمونه‌برداری ترازگر، برابر نرخ ارسال سیگنال دریافتی است. با این وجود گاهی استفاده از همسان‌سازی با شیرهای با فواصل کسری از تناوب سمبل  $T$  مطلوب می‌باشد. این پیکره‌بندی درجات آزادی بیشتری جهت انجام فیلترینگ اضافی به دست می‌دهد. این طرح همسان‌سازی فواصل کسری (FSE) نامیده می‌شود. خروجی کانال با فواصل کسری منتج از بیش‌نمونه‌برداری با مرتبه  $p$  نسبت به نرخ سمبل می‌تواند به صورت زیر نوشته شود

$$x(k \frac{T}{p}) = \sum_{l=-\infty}^{\infty} s(l)h(k \frac{T}{p} - lT) + v(k \frac{T}{p}) \quad (6)$$

نمایشی مشابه می‌تواند با استفاده از مدل بانک فیلتر موازی  $P$  کاناله شکل گیرد. در نتیجه خروجی زیر کانال  $i$ ام،  $h_i(k)$  به صورت زیر به دست می‌آید

$$x_i(k) = \sum_{l=-\infty}^{\infty} s(l)h_i(k-l) + v_i(k), \quad i = 0, \dots, p-1 \quad (7)$$

اکنون همسان‌ساز  $w_i(k)$  به صورت سری با هر کانال  $h_i(k)$  به کار می‌رود و شیرهای همسان‌ساز با استفاده از الگوریتم FSE\_CMA تنظیم می‌شوند

$$w(k+1) = w(k) + \zeta x^*(k)y(k)(|y(k)|^2 - \gamma)^2 \quad (8)$$

که در آن  $\zeta$  پارامتر اندازه گام و  $y(k)$  خروجی همسان‌ساز است

$$y(k) = w^T(k)x(k) \quad (9)$$

از آنجایی که سرعت همگرایی به  $\zeta$  وابسته است و انتخاب نامناسب ممکن است منجر به واگرایی معادله برگشتی (۸) شود، یک بهینه‌ساز جهت تعیین مقدار مناسب اندازه گام به کار می‌رود.

ج) نهایتاً با فرض  $n = 3$  مجموعه در دسترس اندیس‌ها  $(1, 2, 3)$  می‌باشد. بنابراین چهار نوع مختلف بخش‌بندی‌ها به دست می‌آیند یعنی  $v = (v_1, v_2, v_3, v_4)$  این بخش‌ها عبارتند از:

- (۱)، (۲، ۳) منجر به  $q = 1$ ،
- (۲)، (۱، ۳) منجر به  $q = 2$ ،
- (۳)، (۱، ۲) منجر به  $q = 2$ ،
- (۱)، (۲)، (۳) منجر به  $q = 3$ .

بنابراین (۱۷) تبدیل به معادله زیر می‌شود

$$\begin{aligned} Cum[s_1, s_2, s_3] &= (-1)^{-1}(1-1)!E[s_1 s_2 s_3] + \\ &(-1)^{-1}(2-1)!E[s_1]E[s_2 s_3] + \\ &(-1)^{-1}(2-1)!E[s_2]E[s_1 s_3] + \\ &(-1)^{-1}(2-1)!E[s_3]E[s_1 s_2] + \\ &(-1)^{-1}(3-1)!E[s_1]E[s_2]E[s_3] \Rightarrow \\ Cum[s_1, s_2, s_3] &= E[s_1 s_2 s_3] - \\ &E[s_1]E[s_2 s_3] - E[s_2]E[s_1 s_3] - \\ &E[s_3]E[s_1 s_2] + 2E[s_1]E[s_2]E[s_3] \end{aligned} \quad (20)$$

مرتبه دو، چهار، شش و هشت ممان‌ها و کومولان‌ها به عنوان ویژگی‌ها در نظر گرفته شدند. این ویژگی‌ها عبارتند از  $M_{v_1}, M_{v_2}, M_{v_3}, M_{v_4}, M_{v_5}, M_{v_6}, M_{v_7}, M_{v_8}, M_{v_9}, M_{v_{10}}, M_{v_{11}}, M_{v_{12}}, M_{v_{13}}, M_{v_{14}}, M_{v_{15}}, M_{v_{16}}, M_{v_{17}}, M_{v_{18}}, M_{v_{19}}, M_{v_{20}}, C_{v_1}, C_{v_2}, C_{v_3}, C_{v_4}, C_{v_5}, C_{v_6}, C_{v_7}, C_{v_8}, C_{v_9}, C_{v_{10}}, C_{v_{11}}, C_{v_{12}}, C_{v_{13}}, C_{v_{14}}, C_{v_{15}}, C_{v_{16}}, C_{v_{17}}, C_{v_{18}}, C_{v_{19}}, C_{v_{20}}$ . شایان ذکر است که در نظر گرفتن مرتبه‌های بالاتر از هشت عملکرد سیستم را به طور محسوس تحت تأثیر قرار نداد اما سیستم را پیچیده کرد و زمان محاسباتی را افزایش داد. ممان‌های فرد مرتبه بالاتر صفر است و بنابراین تعداد کل ویژگی‌های آماری ۲۶ است، زیرا  $M_{v_1}$  به ترتیب برابر  $C_{v_1}$  و  $C_{v_2}$  می‌باشند. تمامی این ویژگی‌ها برای سیگنال‌های دیجیتال در نظر گرفته شده محاسبه شده‌اند. مقادیر تئوری ویژگی‌های انتخاب‌شده برای تعدادی از انواع سیگنال‌های دیجیتال مورد بررسی تحت قید واریانس واحد، بدون نویز و نرمالیزه‌شده با توان تئوری سیگنال محاسبه و در جدول ۱ ارائه شده‌اند. در واقع، این مقادیر محاسبه‌شده با فرض این که سیگنال تمیز و دارای طول محدود است به دست آمده‌اند. با این حال در عمل، سیگنال‌ها معمولاً در معرض برخی انواع اعوجاج در داخل فرستنده یا طی ارسال می‌باشند. شکل‌های ۳ و ۴ برخی ویژگی‌های مرتبه بالاتر را برای تعدادی از انواع سیگنال‌های دیجیتال در نظر گرفته شده نشان می‌دهد.

### ۴- طبقه‌بند

در این مقاله، شبکه عصبی MLP به عنوان طبقه‌بند عمل می‌نماید. شبکه عصبی MLP نوعی از یک لایه ورودی (از گره‌های منبع)، یک یا چند لایه پنهان (از گره‌های محاسباتی) و یک لایه خروجی [۲۸] تشکیل می‌شود. تعداد لایه‌های پنهان و تعداد گره‌ها در هر لایه پنهان روی قابلیت تعمیم شبکه عصبی اثر می‌گذارد. فرایند طبقه‌بندی با استفاده از شبکه عصبی MLP اساساً از دو فاز تشکیل می‌شود: فاز آموزش و فاز آزمایش. در فاز آموزش، اوزان مطابق الگوریتم یادگیری انتخاب‌شده محاسبه می‌گردند. الگوریتم یادگیری و سرعت آن عملکرد شبکه عصبی MLP را به شدت تحت تأثیر قرار می‌دهد. یکی از متداول‌ترین الگوریتم‌های یادگیری الگوریتم BP [۲۹] می‌باشد. با این حال، تحت شرایط معینی، طبقه‌بند شبکه BP می‌تواند نتایج طبقه‌بندی ضعیفی را تولید نماید و به راحتی به مینیمم محلی همگرا شود و به علاوه دارای فاز

جدول ۱: برخی مقادیر ویژگی‌ها.

APSK	۴PSK	۲PSK	$M_{v_i}$
۰	۰	۱	$M_{v_1}$
۱	-۳۴	-۲۴۴	$C_{v_2}$
-۱	-۱	-۱	$M_{v_2}$
۴	۴	۱۶	$C_{v_3}$

که در آن  $p$  مرتبه ممان نامیده می‌شود و  $p-q$  و  $q$  به ترتیب تعداد عبارات مزدوج و غیر مزدوج را نشان می‌دهند.  $s^*$  نشانگر مزدوج مختلط  $s$  می‌باشد و با در نظر گرفتن دنباله سیگنال به شکل  $s_k = a_k + jb_k$  استفاده از تعریف خود ممان‌ها، عبارات برای مرتبه‌های مختلف به راحتی به دست می‌آیند.

متغیر تصادفی اسکالر  $s$  با میانگین صفر و تابع مشخصه  $\hat{f}(t)$  را در نظر بگیرید. بسط لگاریتم تابع مشخصه به صورت سری تیلور معادله زیر را به دست می‌دهد

$$\log \hat{f}(t) = k_1(jt) + \dots + \frac{k_r(jt)^r}{r!} + \dots \quad (14)$$

ثابت‌های  $k_r$  در (۱۴) کومولان‌های (توزیع)  $s$  نامیده می‌شوند. نماد کومولان مرتبه  $p$  ام مشابه مرتبه  $p$  ام ممان می‌باشد. به طور مشخص

$$C_{pq} = Cum[\underbrace{s, \dots, s}_{(p-q) \text{ terms}}, \underbrace{s^*, \dots, s^*}_{(q) \text{ terms}}] \quad (15)$$

برای مثال  $C_{v_1} = Cum(s, s, s, s, s, s, s, s, s^*)$  ممان‌ها می‌توانند بر حسب کومولان‌ها به صورت زیر بیان شوند

$$M[s_1, \dots, s_n] = \sum_{v \in V} Cum[\{s_j\}_{j \in v_1}] \dots Cum[\{s_j\}_{j \in v_q}] \quad (16)$$

که در آن اندیس جمع روی تمامی بخش‌های  $v = (v_1, \dots, v_q)$  برای مجموعه اندیس‌های  $(1, 2, \dots, n)$  و  $q$  تعداد عناصر در بخش داده‌شده می‌باشد.  $M[.]$  به معنی ممان‌ها می‌باشد. کومولان مرتبه  $n$  ام تابعی از ممان‌ها تا مرتبه (و شامل)  $n$  می‌باشد

$$Cum[s_1, \dots, s_n] = \sum_{v \in V} (-1)^{q-1} (q-1)! E[\prod_{j \in v_1} s_j] \dots E[\prod_{j \in v_q} s_j] \quad (17)$$

که  $Cum[.]$  به معنی کومولان‌ها است و جمع روی تمامی بخش‌های  $v = (v_1, \dots, v_q)$  برای مجموعه اندیس‌های  $(1, 2, \dots, n)$  عمل می‌کند. برای درک بیشتر فرمول‌های فوق، چند مثال ذکر می‌شود. الف) با فرض  $n = 1$ ، تنها یک بخش  $v_1$  می‌تواند تعریف شود.

بنابراین  $q = 1$  و (۱۷) منجر به عبارت زیر می‌شود

$$Cum[s_1] = (-1)^{1-1} (1-1)! E[s_1] \Rightarrow Cum[s_1] = E[s_1] \quad (18)$$

ب) اکنون با فرض  $n = 2$  مجموعه موجود اندیس‌ها ۱ و ۲ است. بنابراین دو نوع مختلف بخش‌بندی به دست می‌آیند یعنی  $v = (v_1, v_2)$ . بخش‌ها عبارتند از:

- (۱، ۲) با  $q = 1$ ،
- (۲)، (۱) با  $q = 2$ ،

بنابراین (۱۷) به عبارت زیر تبدیل می‌شود

$$\begin{aligned} Cum[s_1, s_2] &= \\ &(-1)^{-1}(1-1)!E[s_1 s_2] + (-1)^{-1}(2-1)!E[s_1]E[s_2] \Rightarrow \\ Cum[s_1, s_2] &= E[s_1 s_2] - E[s_1]E[s_2] \end{aligned} \quad (19)$$

۱. جمعیت اولیه با راه حل های تصادفی تولید شود.
۲. برازش جمعیت ارزیابی شود.
۳. تا زمانی که شرط توقف برآورده نشده است جمعیت جدید تولید شود.
۴. زنبورهای برگزیده برای جستجوی همسایگی انتخاب شوند. سایر زنبورها برای جستجوی همسایگی انتخاب شوند.
۵. زنبورها به نواحی منتخب اعزام و برازش ارزیابی شود.
۶. برازنده ترین زنبور از هر ناحیه انتخاب شود.
۷. زنبورهای باقیمانده جهت جستجوی تصادفی و ارزیابی برازش آنها تخصیص یابند.
۸. تا شرط توقف ادامه یابد.

شکل ۵: شبه کد BA پایه.

این امر همگرایی را در نواحی کم عمق سرعت می بخشد. جهت جلوگیری از سرعت بیش از حد، هنگامی که مشتق صفر می گردد مقدار به روز رسانی بدون تغییر باقی می ماند ( $\eta$ ). توجه شود که مقادیر  $\Delta_{ij}$  در هر دوره غیر منفی باقی می ماند. بعد از طی شدن این پروسه، عمل به روز رسانی اصلی صورت می گیرد که توسط (۲۲) و (۲۳) هدایت می گردد

$$\Delta w_{ij}(t) = \begin{cases} -\Delta_{ij}(t) & \text{if } \frac{\delta E}{\delta w_{ij}}(t) > 0 \\ +\Delta_{ij}(t) & \text{if } \frac{\delta E}{\delta w_{ij}}(t) < 0 \\ 0 & \text{otherwise} \end{cases} \quad (22)$$


$$w_{ij}(t+1) = w_{ij}(t) + \Delta w_{ij}(t) \quad (23)$$

### ۵- الگوریتم زنبور عسل


#### ۵-۱ الگوریتم زنبور عسل

BA الگوریتم بهینه سازی ای است که از رفتار جستجوی غذای زنبورهای عسل الهام گرفته است [۳۱]. شکل ۵ شبه کد BA را به صورتی بسیار ساده بیان می نماید. BA مستلزم تنظیم تعدادی پارامتر است که عبارتند از تعداد زنبورهای کاوش گر ( $n$ )، تعداد نواحی انتخاب شده از  $n$  نقطه بازدید شده ( $m$ )، تعداد نواحی برگزیده از  $m$  ناحیه منتخب ( $e$ )، تعداد زنبورهای اعزام شده به  $e$  بهترین ناحیه ( $nep$ )، تعداد زنبورهای اعزام شده به سایر ( $m-e$ ) ناحیه منتخب ( $nsp$ )، اندازه نواحی ( $ngh$ ) و شرط توقف. الگوریتم با قراردادن تصادفی  $n$  زنبور کاوش گر در ناحیه جستجو شروع می شود. برازش نقاط بازدید شده توسط زنبورهای کاوش گر در گام دو ارزیابی می گردد.

در گام ۴، زنبورهایی که بالاترین برازش را دارند به عنوان زنبورهای منتخب و نواحی بازدید شده توسط آنها برای جستجوی همسایگی در نظر گرفته می شوند. سپس در گام های ۵ و ۶ الگوریتم جستجوهای همسایگی زنبورهای منتخب با تخصیص زنبورهای بیشتر در اطراف  $e$  بهترین زنبور اجرا می نماید. زنبورها می توانند به طور مستقیم مطابق برازش مرتبط با نقاطی که بازدید می نمایند انتخاب شوند. به طور جایگزین، مقادیر برازش جهت تعیین احتمال انتخاب زنبورها به کار می روند. جستجوها در همسایگی  $e$  بهترین زنبور که نماینده راه حل های نویدبخش تر می باشند، توسط اعزام زنبورهای بیشتر جهت دنبال کردن آنها و نه سایر زنبورهای دیگر منتخب با جزئیات بیشتر ادامه می یابد. این نحوه



شکل ۳: مقدار  $M_{\alpha}$  برای برخی از انواع سیگنال های دیجیتال در نظر گرفته شده.




شکل ۴: مقدار  $C_{\text{FF}}$  برای برخی از انواع سیگنال های دیجیتال در نظر گرفته شده.


آموزش زمان بری است. در سال های اخیر الگوریتم های یادگیری جدیدتری برای آموزش شبکه عصبی ارائه شده اند. در این مقاله، الگوریتم انتشار برگشتی انعطاف پذیر (RPROP) به عنوان الگوریتم یادگیری شبکه عصبی به کار گرفته شده است [۳۰]. RPROP از علامت مشتقات برای تعیین جهت به روز رسانی وزن ها استفاده می کند و به این ترتیب اندازه نسبی مشتق گام وزن را تحت تأثیر قرار نمی دهد. معادله (۲۱) نحوه تغییر مقادیر به روز شده  $\Delta_{ij}$  (تغییرات اوزان) را برای این الگوریتم شرح می دهد. در ابتدا تمام  $\Delta_{ij}$  به مقادیر مثبت کوچکی تنظیم می شوند

$$\Delta_{ij} = \begin{cases} \eta^+ \Delta_{ij}(t-1) & \text{if } \frac{\delta E}{\delta w_{ij}}(t-1) \frac{\delta E}{\delta w_{ij}}(t) > 0 \\ \eta^- \Delta_{ij}(t-1) & \text{if } \frac{\delta E}{\delta w_{ij}}(t-1) \frac{\delta E}{\delta w_{ij}}(t) < 0 \\ \eta^0 \Delta_{ij}(t-1) & \text{otherwise} \end{cases} \quad (21)$$

که در آن  $\eta^+ = 1, 0 < \eta^- < 1, \eta^0 = 0$  به عنوان فاکتورهای به روز رسانی شناخته می شوند،  $w_{ij}$  بیانگر مقدار وزن از نورون  $j$  به نورون  $i$  و  $E$  بیانگر تابع خطا می باشد. هر جا تغییری در علامت مشتق وزن مربوطه وجود داشته باشد، نشان می دهد مقدار به روز شده قبلی بسیار بزرگ بوده و از مینیمی عبور کرده است. بنابراین همان طور که در (۱۸) نشان داده شده است، مقدار به روز شده کاهش می یابد ( $\eta^-$ ). با این وجود اگر مشتق علامت خود را حفظ کند، مقدار به روز شده افزایش می یابد ( $\eta^+$ ).



شکل ۷: حساسیت زمان اجرا به تعداد زنبورهای کاوش گر.



شکل ۸: حساسیت دقت به تعداد زنبورهای کاوش گر.

جدول ۲: پارامترها.

مقدار	سمبل	پارامترهای BA
۲۵	$n$	تعداد زنبورهای کاوش گر
۱۰	$m$	تعداد نواحی منتخب
۴	$e$	تعداد زنبورهای برگزیده
۰٫۱	$nghl$	اندازه اولیه ناحیه ۱
۱۵	$nep$	تعداد زنبورها اطراف نقاط برگزیده
۱۰	$nsp$	تعداد زنبورها اطراف نقاط منتخب

یک الگو در مجموعه داده جدید دارای  $N_s$  ویژگی منتخب از مجموعه اولیه  $N_{tot}$  ویژگی می‌باشد. یک زنبور عسل نماینده زیرمجموعه‌ای از  $N_s$  ویژگی و پارامتر همسان‌ساز می‌باشد. زنبور عسل می‌تواند به طور یکتا توسط رشته باینری-حقیقی (مثل ۰۱۱۰۱۱۱۱ -  $2 \times 10^{-7}$ ) شناسایی شود که در آن بخش اول اندازه گام و بخش دوم ویژگی‌ها را نشان می‌دهد. بخش حقیقی تنها یک عدد است. تعداد کلی بیت‌ها در بخش باینری  $N_{tot}$  و تعداد کل بیت‌های غیر صفر  $N_s$  است. موقعیت یک بیت در طول رشته باینری ویژگی به خصوصی را نشان می‌دهد. اگر ویژگی‌ای جهت تشکیل مجموعه داده انتخاب شود، بیت متناظر ۱ در غیر این صورت صفر است.

در فاز اولیه، BA با تولید تصادفی جمعیتی از رشته‌های باینری-حقیقی شروع می‌شود. عدد حقیقی در بازه مناسبی تولید می‌شود. مجموعه داده به دو مجموعه تقسیم می‌شود. یک مجموعه داده (داده آموزش) جهت آموزش MLP به کار می‌رود. مجموعه داده دیگر (داده آزمایش) جهت ارزیابی دقت طبقه‌بند MLP آموزش دیده به کار می‌رود.

همان طور که اشاره شد، BA مستلزم جستجوی همسایگی است. در این مقاله، این به معنی تولید و ارزیابی همسایگی‌های زنبورهای برازنده ترافیک می‌باشد. اپراتورهای مختلفی می‌توانند جهت ایجاد همسایگی‌های زنبور داده‌شده، شامل اپراتورهای یکنواخت مانند جهش، وارونگی، معاوضه و الحاق (تکی یا چندگانه) به کار روند. شکل‌های ۶ و ۷ حساسیت دقت و زمان اجرا به تعداد زنبورهای کاوش گر را نشان می‌دهند. می‌توان ملاحظه کرد که  $n = 25$  انتخاب بهینه است. برای انتخاب سایر پارامترهای BA، سناریویی مشابه تحقق یافته است. جدول ۲ مقادیر پارامترهای در نظر گرفته شده برای BA را نشان می‌دهد.

## ۶- نتایج شبیه‌سازی

این بخش نتایج شبیه‌سازی طبقه‌بند را برای سیگنال‌های در نظر گرفته شده نشان می‌دهد. فرض می‌شود فرکانس‌های حامل به طور صحیح تخمین زده شدند و سیگنال هتروداین شده است. بنابراین تنها سیگنال‌های باند پایه مختلط در نظر گرفته شدند. برای مقاصد طبقه‌بندی مدولاسیون، نمونه‌برداری کسری انجام شده و در نتیجه، نرخ سمبل باید پیش از انتخاب نرخ نمونه‌برداری معلوم باشد. در این مقاله، فرکانس سمبل ۱۰ کیلوهرتز در نظر گرفته شده است اگرچه در عمل، باید تخمین زده شود. هر سیگنال توسط ادیتور متلب تولید شد. پیام دیجیتال به طور تصادفی برای هر آزمایش تولید شد تا تضمین نماید نتایج به دست آمده

اعزام زنبورها به همراه کاوش‌گری عملیات کلیدی الگوریتم زنبورهای عسل می‌باشد. در گام ۶ برای هر ناحیه تنها زنبور با بالاترین برآزش جهت تشکیل جمعیت زنبور عسل بعدی انتخاب خواهد شد. در طبیعت، چنین محدودیتی وجود ندارد و این محدودیت در اینجا برای کاهش تعداد نقاطی که باید جستجو شوند معرفی شده است. در گام ۷، زنبورهای باقیمانده در جمعیت به طور تصادفی در اطراف فضای جستجو جهت کاوش راه حل‌های احتمالی جدید اختصاص داده می‌شوند. این گام‌ها تا برآورده شدن شرط توقف تکرار می‌شوند. در آخر هر تکرار، کلونی دو بخش در جمعیت جدید خود دارد، نمایندگان از هر ناحیه منتخب و سایر زنبورهای کاوش گر تخصیص یافته جهت انجام جستجوهای تصادفی.

## ۵-۲ الگوریتم‌های زنبور عسل برای بهینه‌سازی همسان‌ساز و انتخاب ویژگی

همان طور که قبلاً اشاره شد در این مقاله الگوریتم CMA به عنوان همسان‌ساز کور و BA جهت بهینه‌سازی اندازه گام به کار گرفته شده است. همان طور که می‌دانیم تعداد زیاد ویژگی‌ها منجر به پیچیدگی محاسباتی طبقه‌بند می‌شود [۳۲]. از سوی دیگر، برخی از این ویژگی‌ها ممکن است در حالتی که جدا در نظر گرفته شوند، حامل اطلاعات طبقه‌بندی خوبی باشند. به علت اشتراک محتوای اطلاعات مشابه، ترکیب ویژگی‌ها مزیت اندکی دارد. آسان‌ترین روش جهت کاهش تعداد ویژگی‌ها انتخاب ویژگی است. الگوریتم‌های انتخاب زیرمجموعه ویژگی‌ها می‌توانند به دو گروه تقسیم شوند بر اساس این که آیا انتخاب ویژگی مستقل از الگوریتم یادگیری مورد استفاده برای ساختن طبقه‌بند انجام شده یا خیر. اگر انتخاب ویژگی مستقل از الگوریتم یادگیری انجام شود، این روش باید از رویکرد فیلتر پیروی نماید و در غیر این صورت باید از رویکرد پوشه‌ای پیروی کند [۳۳]. در این مقاله، رویکرد نوع پوشه‌ای به کار رفته است.

جدول ۳: اثر لایه‌های پنهان و تعداد گره‌ها بر دقت.

تعداد لایه‌ها	تعداد گره‌ها در هر لایه	زمان اجرا (ثانیه)	دقت (%)
۱	(۲۰)	۴۶۲	۹۳٫۵۰
۱	(۱۵)	۲۲۴	۹۰٫۸۴
۲	(۲۵×۱۵)	۲۸۹	۹۳٫۸۴
۲	(۲۰×۱۵)	۳۱۱	۹۴٫۱۳
۳	(۲۰×۲۰×۱۵)	۳۷۷	۹۴٫۱۱

جدول ۴: مقایسه میان الگوریتم‌های یادگیری مختلف (کانال محوشونده تخت در SNR = ۰).

rprop	bp	scg	lm	زمان (ثانیه)	دقت (%)
۲۴۶	۲۶۳	۲۵۷	۲۵۳	۹۳٫۵۰	۹۱٫۳۸
		۹۱٫۷۲	۹۲٫۹۸		

جدول ۵: ماتریس اغتشاش برای کانال FIR در SNR = -۲ dB.

	P1	P2	P3	P4	P5	P6
P1	۱۰۰					
P2		۱۰۰				
P3			۱۰۰			
P4				۹۲	۸	
P5				۸	۹۲	
P6						۱۰۰

جدول ۶: ماتریس اغتشاش برای کانال FIR در SNR = ۰ dB.

	P1	P2	P3	P4	P5	P6
P1	۱۰۰					
P2		۱۰۰				
P3			۱۰۰			
P4				۱۰۰		
P5				۱۳	۸۷	
P6						۱۰۰

جدول ۷: ماتریس اغتشاش برای کانال FIR در SNR = ۲ dB.

	P1	P2	P3	P4	P5	P6
P1	۱۰۰					
P2		۱۰۰				
P3			۱۰۰			
P4				۹۳	۷	
P5				۱	۹۹	
P6						۱۰۰

جدول ۸: ماتریس اغتشاش برای کانال FIR در SNR = ۴ dB.


	P1	P2	P3	P4	P5	P6
P1	۱۰۰					
P2		۱۰۰				
P3			۱۰۰			
P4				۹۴	۶	
P5				۱	۹۹	
P6						۱۰۰

جدول ۹: ماتریس اغتشاش برای کانال FIR در SNR = ۶ dB.


	P1	P2	P3	P4	P5	P6
P1	۱۰۰					
P2		۱۰۰				
P3			۱۰۰			
P4				۹۵	۵	
P5					۱۰۰	
P6						۱۰۰

اطمینانی برای تعیین تعداد نوروها در لایه‌ها وجود ندارد، چندین معماری شبکه با یک و دو لایه پنهان مورد بررسی قرار گرفتند و به طور تجربی معماری با نتایج نسبتاً برتر انتخاب شد. نتایج به دست آمده در کانال‌های محوشونده تخت در SNR = ۰ dB در جدول ۳ نشان داده شده‌اند. معلوم شد که MLP دارای یک لایه پنهان با ۲۰ گره عملکرد بالایی علاوه بر حداقل پیچیدگی در مقایسه با سایرین دارد. به علاوه، جدول ۴ مقایسه‌های میان RPROP و سایر الگوریتم‌های یادگیری متداول مانند LM<sup>۱</sup>، گرادبان مزدوج مقیاس‌یافته (SCG) و BP را نشان می‌دهد. برای شروع بهینه‌سازی، تعداد ویژگی‌ها که از ۱ تا ۲۶ تغییر می‌کند باید مشخص شود. به طور واضح، محدود کردن تعداد ویژگی‌ها پیچیدگی طبقه‌بند را کاهش می‌دهد و همچنین به حافظه کمتری نیاز دارد. در این مقاله، کاهش فضای ویژگی توسط BA انجام شد. به طور کلی، انتخاب کمترین تعداد ویژگی دقت طبقه‌بند را در SNR پایین کاهش می‌دهد. با این وجود در این مقاله الگوریتم نوینی مبتنی بر کاهش تعداد ویژگی‌ها و بهینه‌سازی همزمان طبقه‌بند، یعنی بهترین راه حل برای مسأله طبقه‌بندی مدولاسیون ارائه شده است. بنابراین دقت شناساگر ارائه‌شده بهبود و همچنین پیچیدگی آن کاهش یافت. جداول ۵ تا ۹ ماتریس اغتشاش طبقه‌بند ارائه‌شده برای کانال FIR را در پنج سطح SNR نشان می‌دهد. می‌توان مشاهده کرد که با افزایش سطح SNR طبقه‌بندی اشتباه کاهش می‌یابد. شکل ۸ مقایسه‌ای میان عملکردهای طبقه‌بند غیر بهینه و طبقه‌بند بهینه را نمایش می‌دهد. همان طور که ملاحظه می‌شود

مستقل از پیام ارسال شده خواهد بود. تخمین مقادیر ممان و کومولان برای تمام انواع سیگنال‌ها بر اساس فرمول‌های بخش ۳ بود. برای هر نوع سیگنال دیجیتال، طرح مدولاسیون با ۱۰۰۰۰ نمونه ایجاد و ذخیره شد. کانالی نوعی در شبیه‌سازی مورد آزمایش قرار گرفت که پاسخ ضربه محدود (FIR) با سه شیر  $h = [0.5 \ 0.7 \ 0.5]^T$  بود. ابتدا دنباله ۶۰۰۰ نمونه از ۱۰۰۰۰ نمونه استخراج و برای هر نوع سیگنال دیجیتال تولید شدند. سپس هر دنباله از کانال انتشار عبور کرد و دنباله سیگنال منتج با AWGN با سطوح SNR بین -۲ تا ۶ دسی‌بل تخریب شد. برای الگوریتم FSE-CMA، همسان‌ساز دارای ۹ شیر انتخاب و اندازه گام توسط BA تنظیم شد. در نهایت ۲۰۰ آزمایش در هر سطح SNR تولید گشت. آزمایش‌های چندگانه در هر سطح SNR اعمال شدند تا درکی از عملکرد طبقه‌بند به دست آید. سپس ویژگی‌ها از هر سیگنال نویزی استخراج شدند. پس از انتخاب بهترین ویژگی‌ها توسط BA، به شبکه عصبی MLP برای آموزش تزریق شدند. پس از آموزش، طبقه‌بند آزمایش شد. برای فاز آزمایش پنج سطح SNR، -۲، ۰، ۲، ۴ و ۶ دسی‌بل انتخاب شدند. در هر آزمایش یک پیام جدید تصادفی جهت تضمین استقلال تمامی نتایج ایجاد شد. پیچیدگی MLP معمولاً به تعداد لایه‌های پنهان و گره‌ها مرتبط می‌باشد. از آنجایی که هیچ روش قابل



شکل ۱۰: عملکرد طبقه‌بند ارائه شده در محیط‌های مختلف.



شکل ۸: مقایسه میان طبقه‌بند غیر بهینه و طبقه‌بند بهینه.

جدول ۱۰: مقایسه میان عملکرد BA-MLP-CMA و سایر تکنیک‌های شناسایی.


تکنیک‌های شناسایی	دقت شناسایی (%)
ABC-MLP-CMA	۹۰٫۹۶
GA-MLP-CMA	۹۲٫۶۴
PSO-MLP-CMA	۸۹٫۸۱
BA-MLP-CMA	۹۳٫۵۰

دقت برای مجموعه آزمایش توسط BA-MLP-CMA ۹۳٫۵۰٪ می‌باشد. می‌توان ملاحظه نمود که نرخ‌های موفقیت BA بالاتر از سایر الگوریتم‌های الهام‌گرفته از طبیعت می‌باشند.

همان‌طور که در [۱۰] اشاره شد مقایسه مستقیم میان دو مطالعه در زمینه طبقه‌بندی انواع سیگنال مشکل است. این مسأله عمدتاً به خاطر این واقعیت است که هیچ مجموعه داده متحدی در دسترس نیست. مقایسه با سایر طبقه‌بندها که در بخش ۱ به آنها اشاره شد نشان می‌دهد که طبقه‌بند ارائه شده در این مقاله دارای مزایای بسیاری می‌باشد. این طبقه‌بند انواع متنوعی از سیگنال‌های دیجیتال را در بر می‌گیرد و قابلیت تعمیم‌پذیری قابل توجهی برای طبقه‌بندی انواع سیگنال‌های دیجیتال مد نظر از خود نشان می‌دهد. طبقه‌بند ارائه شده دارای نرخ موفقیت حدود ۹۴٪ در کانال محوشونده تخت در  $SNR = 0\text{ dB}$  می‌باشد. عملکرد این طبقه‌بند بالاتر از ۹۸٪ برای  $SNR > 6\text{ dB}$  است. این عملکردها با نمونه‌های اندکی به دست آمدند. نتایج نشان می‌دهند که ویژگی‌های انتخاب شده دارای خصوصیات مؤثری در نمایش سیگنال می‌باشند.

### ۷- نتیجه‌گیری

این مقاله شناسایی خودکار نوع سیگنال دیجیتال که ضرورت سیستم‌های ارتباطی نوین است را هدف قرار داد. یک سیستم یادگیری ماشین ترکیبی ارائه شد و جهت تشخیص سیگنال‌های MPSK در محیط‌های محوشونده چندمسیره مورد بررسی قرار گرفت. در روش ارائه شده اعوجاج با استفاده از همسان‌ساز FSE-CMA کاهش یافت. شبکه عصبی MLP ساده جهت تعیین عضویت سیگنال دریافت شده ارائه شد. ترکیبی منتخب از ممان‌های مرتبه بالاتر و کومولان‌های مرتبه بالاتر جهت نمایش سیگنال‌های دیجیتال پیشنهاد شدند. BA به عنوان بهینه‌ساز جهت انتخاب بهترین پارامتر همسان‌ساز ارائه شد. به علاوه، BA جهت انتخاب کارآمدترین ویژگی‌ها برای کاهش پیچیدگی و افزایش دقت به کار گرفته شد. نتایج شبیه‌سازی نشان دادند که روش پیشنهاد شده به طور کارآمد در  $SNR$  پایین عمل نمود و عملکردی تقریباً مقاوم در محیط‌های مختلف از خود نشان داد. مسایل طبقه‌بندی جدید در نتیجه تکنولوژی‌های



شکل ۹: مقایسه میان طبقه‌بند غیر همسان و طبقه‌بند همسان شده.

بهینه‌سازی در حالت کلی عملکرد طبقه‌بند را برای تمام سطوح SNR به خصوص سطوح پایین SNR بهبود می‌بخشد. همان‌طور که نشان داده شده است، طبقه‌بند بهینه دارای دقت شناسایی بالاتر از ۹۷٪ برای تمامی سیگنال‌های رادیویی در  $SNR > 2\text{ dB}$  می‌باشد. در بخش ۲ نتایج FSE-CMA توضیح داده شد. جهت ارزیابی مزیت همسان‌ساز، نتایج طبقه‌بندی سیگنال‌های همسان شده و غیر همسان شده در شکل ۹ با یکدیگر مقایسه می‌شوند. همان‌طور که مشاهده می‌شود، عملکرد طبقه‌بند با همسان‌ساز از عملکرد طبقه‌بند بدون همسان‌ساز بهتر است.

جهت مشخص کردن مقاوم بودن شناساگر ارائه شده، عملکرد طبقه‌بند در محیط‌های گوناگون مورد آزمایش قرار گرفت. فرض شد دو کانال چندمسیره محوشونده رایلی باشند. یک کانال محوشونده مسطح با طیف داپلر جکس با بیشترین شیفیت داپلر ۸۰ هرتز بود. کانال دیگر کانال محوشونده فرکانس گزین، کانال سه‌مسیره رایلی دارای طیف داپلر جکس با بیشترین شیفیت داپلر ۴ هرتز برای تمامی مسیرها بود. کانال‌های چندمسیره محوشونده با استفاده از مدل کانال WSSUS تولید شدند [۲۲]. شکل ۱۰ نتایج طبقه‌بند سیستم ارائه شده در این محیط‌ها را نشان می‌دهد. مشخص شد که شناساگر حتی در کانال‌های محوشونده فرکانس گزین به خوبی عمل می‌نماید. با وجود این که عملکرد سیستم در کانال FIR بهتر از سایر کانال‌ها می‌باشد می‌توان ادعا کرد این سیستم عملکرد تقریباً مقاومی در محیط‌های مختلف دارد.

به منظور مقایسه عملکرد BA با سایر الگوریتم‌های تکاملی، چندین الگوریتم مانند بهینه‌سازی کلونی زنبور مصنوعی (ABC) [۳۴]، الگوریتم ژنتیک (GA) [۳۵] و بهینه‌سازی اجتماع ذرات (PSO) [۳۶] برای ارزیابی روش ارائه شده به کار گرفته شدند. این نتایج در کانال‌های محوشونده مسطح در  $SNR = 0\text{ dB}$  به دست آمده‌اند. مطابق نتایج جدول ۱۰، بهترین



- [7] L. Hong and K. C. Ho, "BPSK and QPSK modulation classification with unknown signal level," in *IEEE Military Communications Conf., MILCOM'00*, vol. 2, pp. 976-980, Oct. 2000.
- [8] A. E. El-Mahdy and N. M. Namazi, "Classification of multiple M-ary frequency-shift keying signals over a Rayleigh fading channel," *IEEE Trans. on Communication*, vol. 50, no. 6, pp. 967-974, Jun. 2002.
- [9] S. Z. Hsue and S. S. Soliman, "Automatic modulation classification using zero-crossing," *IEE Proceedings F - Radar and Signal Processing*, vol. 137, no. 6, pp. 459-464, Dec. 1990.
- [10] B. G. Mobasser, "Digital modulation classification using constellation shape," *Signal Processing*, vol. 80, no. 2, pp. 251-277, Feb. 2000.
- [11] E. E. Azzouz and A. K. Nandi, "Automatic identification of digital modulation types," *Signal Processing*, vol. 47, no. 1, pp. 55-69, Nov. 1995.
- [12] J. Lopatka and P. Macrej, "Automatic modulation classification using statistical moments and a fuzzy classifier," in *Proc. 5th Int. Conf. on Signal Processing, ICSP'00*, vol. 3, pp. 1500-1506, Beijing, China, Aug. 2000.
- [13] N. Chani and R. Lamontagne, "Neural networks applied to the classification of spectral features for automatic modulation recognition," in *Proc. IEEE Military Communications Conf., MILCOM'93, Boston, MA, USA*, vol. 1, pp. 111-115, Oct. 1993.
- [14] G. Hagedorn, B. James, and C. Miller, "Neural network recognition of signal modulation types," *Intelligent Engineering Systems Through Artificial Neural Networks*, vol. 7, pp. 170-175, St. Louis, Missouri, USA, Nov. 1997.
- [15] C. Louis and P. Sehier, "Automatic modulation recognition with neural network," in *Proc. IEEE Military Communications Conf., MILCOM'94*, vol. 13, pp. 713-717, Fort Monmouth, NJ, USA, Oct. 1994.
- [16] L. Mingquan, X. Xianci, and L. Leming, "Cyclic spectral features based modulation recognition," in *International Conf. on Communications Technology, ICCT'96*, vol. 2, pp. 792-795, Beijing, China, May 1996.
- [17] Y. Zhao, G. Ren, X. Wang, Z. Wu, and X. Gu, "Automatic digital modulation recognition using artificial neural networks," in *IEEE Int. Conf. Neural Networks & Signal Processing, ICNNSP'03*, vol. 1, pp. 257-260, Nanjing, China, Dec. 2003.
- [18] H. Mustafa and M. Dorolovacki, "Digital modulation recognition using SVM classifier," in *Proc. 38th Asilomar Conf. on Signals, Systems and Computers*, vol. 2, pp. 2238-2242, Pacific Grove, CA, USA, Nov. 2004.
- [19] E. Avci, D. Hanbay, and A. Varol, "An expert discrete-wavelet adaptive network based fuzzy inference system for digital modulation recognition," *Expert Systems with Applications*, vol. 33, no. 3, pp. 582-589, Oct. 2007.
- [20] A. E. Zadeh and M. Aredebilipour, "Numerical methods for signal identification," *J. of Numerical Methods in Engineering*, vol. 5, no. 2, pp. 34-42, Jul. 2008.
- [21] M. W. Aslam, Z. Zhu, and A. K. Nandi, "Automatic modulation classification using combination of genetic programming and KNN," *IEEE Trans. on Wireless Communications*, vol. 11, no. 8, pp. 2742-2750, Aug. 2012.
- [22] P. Hoeher, "A statistical discrete-time model for the WSSUS multipath channel," *IEEE Trans. on Vehicular Technology*, vol. 41, no. 4, pp. 461-468, Nov. 1992.
- [23] D. Godard, "Self-recovering equalization and carrier tracking in two-dimensional data communication systems," *IEEE Trans. on Communications*, vol. 28, no. 11, pp. 1867-1875, Nov. 1980.
- [24] J. R. Treichler and B. G. Agee, "A new approach to multipath correction of constant modulus signals," *IEEE Trans. on Acoustics, Speech Signal Processing*, vol. 31, no. 2, pp. 459-472, Apr. 1983.
- [25] N. K. Jablon, "Joint blind equalization, carrier recovery and timing recovery for high-order QAM signal constellations," *IEEE Trans. Signal Process.*, vol. 40, no. 6, pp. 1383-1398, Jun. 1992.
- [26] R. Johnson, P. Schniter, T. J. Endres, J. D. Behm, D. R. Brown, and R. A. Casas, "Blind equalization using the constant modulus criterion: a review," *Proceedings of the IEEE*, vol. 86, no. 10, pp. 1927-1950, Oct. 1998.
- [27] J. G. Proakis, *Digital Communications*, New York: McGraw-Hill, 2001.
- [28] S. Haykin, *Neural Networks: A Comprehensive Foundation*, 2nd ed., New Jersey, USA: Prentice-Hall, 1999.
- [29] C. L. P. Sehier, "Automatic modulation recognition with a hierarchical neural network," in *Proc. Military Communications Conf., MILCOM'93*, vol. 12, pp. 111-115, New York, USA, Oct. 1993.

تازه متولد شده مانند مدولاسیون ترکیبی، مدولاسیون چندحاملی و غیره به وجود آمده‌اند. تمامی اینها بیان می‌کنند که طبقه‌بندی سیگنال دیجیتال در کانال‌های محوشونده دنیای واقعی، زمینه چالش‌برانگیز پویایی باقی می‌ماند.

## پیوست

سومین تابع متعارف از PDF تابع مشخصه است که به صورت زیر تعریف می‌شود

$$\hat{f}(t) = \int_{-\infty}^{\infty} f(s)e^{jst} ds \quad (پ-۱)$$

که به بیان دیگر تبدیل فوریه PDF است. بنابراین PDF می‌تواند به عنوان تبدیل فوریه معکوس تابع مشخصه آن نوشته شود

$$f(s) = F^{-1}[\hat{f}(t)] = \frac{1}{2\pi} \int_{-\infty}^{\infty} \hat{f}(t)e^{-jst} dt \quad (پ-۲)$$

تابع مشخصه در بسط مک‌لورن صدق می‌کند

$$\hat{f}(t) = \sum_{n=0}^{\infty} m_n \frac{(jt)^n}{n!} \quad (پ-۳)$$

با در نظر گرفتن

$$\delta^{(n)}(s) = \frac{1}{\pi} \int_{-\infty}^{\infty} (-jt)^n e^{-jts} dt \quad (پ-۴)$$

که در آن  $\delta^{(n)}(s)$  مشتق  $n$ ام تابع دلتا است و معکوس فوریه (پ-۱) منجر به بسط PDF رسمی زیر می‌شود که به روش متفاوتی در [۳۷] به دست آمد

$$f(s) = \sum_{n=0}^{\infty} (-1)^n \frac{m_n}{n!} \delta^{(n)}(s) \quad (پ-۵)$$

همچنین مطابق رابطه میان ممان‌ها و کومولان‌ها می‌توان ثابت کرد که [۳۷]

$$f(s) = \frac{1}{\pi} \times \quad (پ-۶)$$

$$\int \exp(-c_{\tau} \frac{t^{\tau}}{\tau!} + c_{\tau} \frac{t^{\tau}}{\tau!} - \dots) \cos(st - c_{\tau} t + c_{\tau} \frac{t^{\tau}}{\tau!} - \dots) dt$$

## مراجع

- [1] Y. Yang, J. N. Chang, J. C. Liu, and C. H. Liu, "Maximum log-likelihood function-based QAM signal classification over fading channels," *Wireless Personal Communications*, vol. 28, no. 1, pp. 77-94, Jan. 2004.
- [2] J. R. Treichler, "Application of blind equalization techniques to voiceband and RF modems," *IFAC Proceedings Volumes*, vol. 25, no. 14, 443-451, Jul. 1992.
- [3] Q. Yang, O. Dayton, L. Xue, Z. Ruolin, V. Chakravarthy, and W. Zhiqiang, "Software-defined radio based automatic blind hierarchical modulation detector via second-order cyclostationary analysis and fourth-order cumulant," in *Proc. Military Communications Conf. (MILCOM)*, vol. 25, pp. 441-446, San Diego, CA, USA, Nov. 2013.
- [4] W. Sue, L. X. Jefferson, and Z. Mengchou, "Real-time modulation classification based on maximum likelihood," *IEEE Comm Letters*, vol. 12, no. 11, pp. 801-803, Nov. 2008.
- [5] Y. Yang and S. S. Soliman, "A suboptimal algorithm for modulation classification," *IEEE Trans. Aerosp. Electron. Syst.*, vol. 33, no. 1, pp. 38-45, Jan. 1997.
- [6] A. K. Nandi and E. E. Azzouz, "Algorithms for automatic modulation recognition of communication signals," *IEEE Trans. on Communication*, vol. 46, no. 4, pp. 431-436, Apr. 1998.

- [35] K. S. Tang, K. F. Man, S. Kwong, and Q. He, "Genetic algorithms and their applications," *IEEE Signal Processing Magazine*, vol. 13, no. 6, pp. 22-37, Nov. 1996.
- [36] R. Eberhart and J. Kennedy, "A new optimizer using particle swarm theory," in *Proc. of Int. Sym. on Micro Machine and Human Science*, vol. 6, pp. 39-43, Oct. 1995.
- [37] D. T. Gillespie, "Moment expansion representation of probability density functions," *American J. of Physics*, vol. 49, no. 6, pp. 552-555, Jun. 1981.
- [30] M. Riedmiller and H. Braun, "A direct adaptive method for faster backpropagation learning: the RPROP algorithm," in *Proc. IEEE Int. Conf. on Neural Networks*, vol. 1, pp. 586-591, Apr. 1993.
- [31] D. T. Pham, A. Ghanbarzadeh, E. Koc, S. Otri, S. Rahim, and S. Zaidi, "The bees algorithm, a novel tool for complex optimization problems," in *Proc. 2nd Int Virtual Conf. on Intelligent Production Machines and Systems, IPROMS'06*, vol. 2, pp. 454-459, Jul. 2006.
- [32] Y. Wang, L. Li, J. Ni, and S. Huang, "Feature selection using tabu search with long-term memories and probabilistic neural networks," *J. of Pattern Recognition Letter*, vol. 30, no. 7, pp. 661-670, May 2009.
- [33] A. A. Minai and R. D. Williams, "Back-propagation heuristics: a study of the extended delta-bar-delta algorithm," in *Proc. Int. Joint Conf. on Neural Networks*, vol. 2, pp. 595-600, San Diego, California, US, Jun. 1990.
- [34] D. Karabog and B. Basturk, "On the performance of artificial bee colony (ABC) algorithm," *Applied Soft Computing*, vol. 8, no. 1, pp. 687-697, Jan. 2008.

**سعید حکیمی** تحصیلات خود را در مقاطع کارشناسی و کارشناسی ارشد مهندسی برق مخابرات به ترتیب در سال‌های ۱۳۸۷ و ۱۳۹۰ از دانشگاه‌های آزاد اسلامی تهران و صنعتی بابل به پایان رسانده است و هم‌اکنون دانشجوی مقطع دکتری در دانشگاه فردوسی مشهد می‌باشد. زمینه‌های تحقیقاتی مورد علاقه نام‌برده عبارتند از: آشکارسازی و تخمین توزیع‌یافته، محاسبات نرم و کاربردهای آن، پردازش سیگنال آماری و تخصیص منابع.