

طبقه‌بندی کننده چندمنظوره گروه ذرات

سید حمید ظهیری

ناشناس می‌باشد. همین رهیافت با به کارگیری نوع جدیدتری از روش هوش جمعی در [۳] تجربه شد و نرخ بازشناسی بالاتری نیز به دست آمد. همه این تحقیقات گام‌های متوالی برای بهبود طبقه‌بندی کننده‌های نوظهور گروه ذرات به شمار می‌روند. اما نکاتی چند نیز در ضمن این تحقیقات جلب نظر می‌کند که توجه به آنها خط مشی صحیح را برای ادامه مسیر تا نیل به طراحی یک طبقه‌بندی کننده گروه ذرات که همه جهات موجود در یک طبقه‌بندی کننده بهینه را داراست، ترسیم می‌کند. در ادامه طلب پاره‌ای از این نکات به این شرح می‌شوند.

در همه تحقیقات فوق‌الذکر تنها ملاکی که مبنای ارزیابی عملکرد طبقه‌بندی کننده‌های گروه ذرات قرار گرفته است نرخ تشخیص صحیح^۵ است. این در حالی است که شاخص‌های مهم دیگری نیز وجود دارند که می‌توانند در ارزیابی عملکرد یک طبقه‌بندی کننده به همان اندازه و حتی بیش از آن حائز اهمیت باشند. قابلیت اطمینان^۶ که میزان اعتبار تصمیم یک طبقه‌بندی کننده را تعیین می‌کند، مثال بارزی از این شاخص‌ها است. باید دانست که در بسیاری از موارد ممکن است نرخ تشخیص صحیح الگوهای یک کلاس در یک طبقه‌بندی کننده مقدار در خور توجهی باشد، اما قابلیت اطمینان آن طبقه‌بندی کننده در خصوص همان کلاس چندان زیاد نباشد. این حالت بیشتر در مواقعی رخ می‌دهد که نمونه‌هایی از کلاس‌های دیگر در ناحیه متعلق به کلاس مذکور حاضر می‌شوند. عکس این موضوع نیز صادق است، یعنی مواردی پیش می‌آیند که در آن نرخ تشخیص کم است اما اعتبار یا قابلیت اطمینان تصمیم اتخاذ شده زیاد است.

تعداد ابرصفحه‌های^۷ لازم برای تقسیم‌بندی فضای ویژگی در همه تحقیقات یاد شده به عنوان یک پیش‌فرض و با سعی و خطا به دست آمده است. بی‌تردید با بکارگیری تعداد زیادی از ابرصفحه‌ها، الگوهای آموزشی با دقت بیشتری طبقه‌بندی می‌شوند اما در غالب اوقات چنین دقتی در مواجهه با داده‌های آزمایشی به دست نمی‌آید. این پدیده فوق-برازش^۸ یا فوق-آموزش^۹ خوانده می‌شود و به عنوان یک پارامتر نامطلوب در طبقه‌بندی کننده‌ها به شمار می‌رود. چنانچه با ارائه راه‌حلی بتوان تعداد ابرصفحه‌های مورد نیاز طبقه‌بندی کننده را در حین مرحله آموزش به عنوان یک متغیر در نظر گرفت، می‌توان انتظار داشت که روش بهینه‌سازی به کار گرفته شده در طبقه‌بندی کننده گروه ذرات مقدار یا مقادیر بهینه آن را نیز تخمین بزند.

کاستی‌های فوق‌الذکر از یکسو و توانایی روش بهینه‌سازی گروه ذرات در بهینه‌سازی همزمان چندین تابع برزندگی از سوی دیگر، انگیزه‌های قوی برای طراحی و معرفی نوع جدیدی از طبقه‌بندی کننده‌های هوش جمعی به شمار می‌روند. در این تحقیق با به کارگیری یک روش

چکیده: در این تحقیق با استفاده از روش بهینه‌سازی چندمنظوره گروه ذرات طبقه‌بندی کننده‌ای ارائه شده است که همزمان قادر به بهینه‌سازی شاخص‌های متفاوت و مهمی در تشخیص الگو نظیر قابلیت اطمینان، نرخ تشخیص صحیح و تعداد ابرصفحه‌های لازم برای مرزبندی مؤثر کلاس‌های متفاوت در فضای ویژگی می‌باشد. در طراحی طبقه‌بندی کننده پیشنهاد شده مسایل مهم فوق-برازش و فوق-آموزش نیز برطرف شده است. توانایی دستیابی همزمان به شاخص‌های مذکور در سایر طبقه‌بندی کننده‌های مبتنی بر روش‌های هوش جمعی وجود ندارد. نتایج عملی به دست آمده بر روی داده‌های آزمایشی نشان می‌دهند که طبقه‌بندی کننده چندمنظوره پیشنهادی با تخمین جبهه پرتو بهترین مجموعه انتخابی از ابرصفحه‌های جداکننده کلاس‌های مختلف را برای برپایی شرایط دلخواه کاربر در خصوص انتخاب شاخص‌های فوق‌الذکر، فراهم می‌آورد.

کلید واژه: بهینه‌سازی چندمنظوره گروه ذرات، تشخیص الگو، طبقه‌بندی کننده، هوش جمعی.

۱- مقدمه

در طراحی یک سیستم تشخیص الگو پس از انجام مراحل مربوط به اخذ داده، عملیات پیش‌پردازش و استخراج ویژگی نوبت به استفاده از یک طبقه‌بندی کننده می‌رسد که با استفاده از بردارهای ویژگی توابع تصمیم را یافته و فضای ویژگی را به نواحی مختلفی که هر یک از آنها متعلق به یک کلاس خاص است تقسیم کند. طبقه‌بندی کننده‌های متنوعی جهت استفاده در سیستم‌های بازشناسی الگو مطرح شده است که از میان آنها می‌توان به طبقه‌بندی کننده‌های بیز، k -نزدیکترین همسایه^۱، شبکه عصبی و فازی^۲ اشاره کرد. در کنار این طبقه‌بندی کننده‌ها، انواع دیگری نیز بر اساس روش‌های هوش جمعی پیشنهاد شده‌اند [۱] تا [۳].

پیشینه طراحی طبقه‌بندی کننده‌های مبتنی بر روش‌های جمعی چندان طولانی نیست و منحصر به مقالات محدودی است که اخیراً در مجلات به چاپ رسیده‌اند. در این پژوهش‌ها، نخست یک طبقه‌بندی کننده گروه ذرات^۴ طراحی و با اعمال آن بر روی داده‌های آزمایشی، نشان داده شد که طبقه‌بندی کننده مذکور دارای نرخ تشخیص قابل مقایسه (و گاه بهتر) از طبقه‌بندی کننده شبکه عصبی و k -نزدیکترین همسایه می‌باشد [۱]. در گام بعد با افزودن یک کنترل کننده فازی به طبقه‌بندی کننده مذکور نوع کارآمدتر آن به نام طبقه‌بندی کننده هوشمند گروه ذرات معرفی شد [۲]. نتایج عملی نشان داد که این طبقه‌بندی کننده با تعداد تکرار کمتر حلقه اصلی جستجو، قادر به تشخیص صحیح تعداد بیشتری از الگوهای

این مقاله در تاریخ ۹ دی ماه ۱۳۸۴ دریافت شد و در تاریخ ۱۶ اردیبهشت ۱۳۸۵ بازنگری شد.

سیدحمید ظهیری، استادیار دانشکده مهندسی، دانشگاه بیرجند، میدان شهدا، بیرجند، صندوق پستی: ۳۷۶-۹۷۱۷۵، بیرجند، ایران.

5. Score of Recognition
6. Reliability
7. Hyperplanes
8. Over Fitting
9. Over Learning

1. Decision Functions
2. K-nearest Neighbor
3. Fuzzy Classifiers
4. Particle Swarm Classifier

بلکه ممکن است از دید تک تک آنها جواب‌های نزدیک بهینه تلقی شوند. یک مفهوم مهم در روشهای بهینه‌سازی چندمنظوره تسلط^۶ است. پاسخ x_i را مسلط بر x_j می‌خوانند اگر شرایط زیر محقق شود: پاسخ x_i از دید هیچ یک از توابع هدف از x_j بدتر نباشد. پاسخ x_i حداقل در یکی از توابع هدف از x_j بهتر باشد. تعاریف فوق به نوبه خود منجر به تعریف بهینگی پرتو^۷ می‌شود. $x_i \in U$ (مجموعه مرجع همه پاسخ‌هاست) را بهینه پرتو گویند اگر و تنها اگر هیچ $x_j \in U$ وجود نداشته باشد که مسلط بر x_i باشد. مجموعه همه پاسخ‌های x_i را مجموعه بهینه پرتو یا جبهه پرتو می‌خوانند.

روشهای بهینه‌سازی مختلفی مانند روشهای تکاملی^۸ و روش بهینه‌سازی گروه مورچگان^۹ برای بهینه‌سازی چندمنظوره به کار گرفته شده‌اند. روش بهینه‌سازی گروه ذرات نیز از این قاعده مستثنی نبوده و به عنوان یک راهکار برای حل اینگونه مسایل پیشنهاد شده است ([۴]) تا [۶]. از آنجا که طبقه‌بندی کننده مورد بحث در این تحقیق مبتنی بر روش بهینه‌سازی گروه ذرات است، بنابراین توجه اصلی بر روش بهینه‌سازی چندمنظوره گروه ذرات معطوف شده است.

۲-۲ روش بهینه‌سازی چندمنظوره گروه ذرات

در این قسمت با توجه به مفاهیم کلی بیان شده در قسمت قبل و پس از آشنایی مقدماتی با روش بهینه‌سازی گروه ذرات به کاربرد این روش برای بهینه‌سازی چندمنظوره می‌پردازیم. الف) روش بهینه‌سازی گروه ذرات

روش بهینه‌سازی گروه ذرات برای نخستین بار در سال ۱۹۹۵ مطرح شد [۷]. این روش با ایجاد یک گروه شامل اجزای کاملاً تصادفی آغاز می‌شود و جستجو در حلقه اصلی و با تکرارهای مداوم صورت می‌گیرد. در این روش نحوه جستجو در فضای پاسخ، از حرکات منظم جمعی پرندگان و ماهی‌ها اقتباس شده است. برای مدل‌سازی نظم موجود در حرکت جمعی این جانداران دو دیدگاه در نظر گرفته شده است. یک بعد، تعاملات اجتماعی موجود بین اعضای گروه است و بعد دیگر امتیازات فردی است که ممکن است هر یک از اعضای گروه واجد آنها باشد. در بعد اول همه اعضای گروه موظف‌اند همواره موقعیت خود را با تبعیت از بهترین فرد گروه تغییر دهند و از بعد دوم لازم است تک تک اعضا بهترین موقعیتی را که تاکنون شخصاً تجربه کرده‌اند در حافظه خود نگهداری کرده و تمایلی نیز به سمت چنین موقعیتی نداشته باشند، زیرا ممکن است هر یک از اعضا خود رهبر گروه شوند به طوریکه بقیه وظیفه تبعیت از آنها را داشته باشند. یکی از گونه‌های مشهور این روش به نام روش بهینه‌سازی گروه ذرات با وزن/اینرسی^{۱۰} بوده و به وسیله دو رابطه ریاضی زیر بیان می‌شود

$$V_i^{q+1} = \omega V_i^q + c_1 \phi_1 (P_i^q - Y_i^q) + c_2 \phi_2 (P_g - Y_i^q) \quad (2)$$

$$Y_i^{q+1} = Y_i^q + V_i^{q+1} \quad (3)$$

رابطه (۲) تعیین کننده سرعت جدید برای هر یک از گروه ذرات می‌باشد و رابطه (۳) نحوه تغییر موقعیت مکانی اجزاء را با استفاده از سرعت محاسبه شده نشان می‌دهد. در این روابط $i = 1, 2, \dots, Pop$ اندیس مشخص کننده

بهینه‌سازی گروه ذرات چندمنظوره طبقه‌بندی کننده بهبود یافته‌ای به نام طبقه‌بندی کننده چندمنظوره گروه ذرات پیشنهاد شده است که به طور همزمان به بهینه‌سازی سه پارامتر زیر می‌پردازد:

تعداد نقاط آموزشی که توسط ابرصفحه‌های معرفی شده بوسیله هر جزء از گروه به اشتباه طبقه‌بندی می‌شود.

تعداد ابرصفحه‌های لازم برای تقسیم‌بندی مناسب فضای ویژگی و تخصیص هر منطقه به یک کلاس خاص.

قابلیت اطمینان تصمیمات اتخاذ شده در خصوص تعلق یک الگو به یک کلاس.

دو مسئله معروف طبقه‌بندی داده‌های گل‌های زنبق^۱ و داده‌های شراب^۲ در کنار مسئله کاربردی و پیچیده طبقه‌بندی اهداف رادار^۳ سه موضوع انتخاب شده برای بررسی عملکرد طبقه‌بندی کننده پیشنهادی و مقایسه آن با سایر روش‌های مشابه هستند. علت انتخاب داده‌های مذکور تنوع در ابعاد، تعداد کلاس‌های مرجع و تداخل قابل قبول آنهاست.

سازماندهی این مقاله بدین گونه است که: بخش ۲ مروری کوتاه بر موضوع روش بهینه‌سازی گروه ذرات چندمنظوره^۴ خواهد داشت. سپس طبقه‌بندی کننده پیشنهادی با نام طبقه‌بندی کننده چندمنظوره گروه ذرات در بخش ۳ معرفی خواهد شد. بخش ۴ نتایج عملی و مقایسه‌ای حاصل از حل سه مسئله انتخابی فوق‌الذکر را در بر دارد. نهایتاً بخش ۵ با جمع‌بندی و بحث در خصوص نتایج به دست آمده مقاله را به پایان خواهد رساند.

۲- معرفی روش بهینه‌سازی چندمنظوره گروه ذرات

۱-۲ مفهوم بهینه‌سازی چندمنظوره

نیاز به بهینه‌سازی همزمان چندین تابع هدف در بسیاری از مسایل واقعی به چشم می‌خورد. حل اینگونه مسایل غالباً به یافتن یک پاسخ یا (احتمالاً) مجموعه‌ای از پاسخ‌ها منجر خواهد شد که مقادیر قابل قبولی از توابع هدف را در بر دارد. یک مسئله بهینه‌سازی با M هدف خاص را در حالت کلی می‌توان به صورت زیر تعریف کرد

$$\text{Minimize } f(x) = [f_i(x), i = 1, \dots, M] \quad (1)$$

در حالیکه شرایط زیر نیز باید رعایت شوند

$$g_j(x) \leq 0 \quad j = 1, 2, \dots, J$$

$$h_k(x) = 0 \quad k = 1, 2, \dots, K$$

$f_i(x)$ ، i امین تابع هدف، $g_j(x)$ ، z امین محدودیت اعمال شده از میان J محدودیت به صورت نامساوی و $h_k(x)$ ، k امین محدودیت لحاظ شده از میان K محدودیت معادله‌ای می‌باشد. در این صورت مسئله بهینه‌سازی چندمنظوره عبارت است از یافتن پاسخی برای x که $f(x)$ را بهینه کند.

اغلب اوقات توابع هدف با یکدیگر در مغایرت^۵ دارند به گونه‌ای که پاسخ بهینه برای یکی (در صورت وجود) از دید یک یا چند تابع هدف دیگر غیر بهینه است. این واقعیت لزوم یک مصالحه معقولانه بین جواب‌های به دست آمده را آشکار می‌کند. با انجام این مصالحه منطقی نهایتاً پاسخ‌هایی به دست خواهند آمد که بهینه‌ساز همه توابع هدف نبوده

6. Domination
7. Pareto Optimality
8. Evolutionary Algorithms
9. Ant Colony Optimization
10. PSO with Inertia Weight

1. Iris Data
2. Wine Data
3. Automatic Target Recognition
4. Multi Objective Particle Swarm Optimization (MOPSO)
5. Conflict

مخزن (REP)

۵) تولید ابرمکعب‌هایی^۷ در مناطق مرور شده در فضای پاسخ و قرار دادن اجزا درون این ابرمکعب‌ها نحوه قرارگیری اجزا درون این ابرمکعب‌ها به گونه‌ای است که مختصات هر جزء بر حسب مقادیر برازندگی به دست آمده از توابع هدف برای هر جزء، تعیین می‌شود.

۶) مقداردهی اولیه به حافظه هر جزء

این حافظه به عنوان راهنمایی در مرور فضای پاسخ به کار رفته، مقادیر آن نیز در مخزن ذخیره‌سازی می‌شود

For $i = 1$ to MAX

$PBEST[i] = POP[i];$

End For;

۷) ایجاد حلقه اصلی جستجو

حلقه اصلی جستجو در این بخش پایه‌ریزی می‌شود. این حلقه به تعدادی که به صورت پیش فرض تعیین می‌شود ادامه می‌یابد. در این حلقه در گام اول سرعت هر جزء با استفاده از رابطه زیر محاسبه می‌شود

$$VEL[i] = W * VEL[i] + R1 * (PBEST[i] - POP[i]) + R2 * (REP[h] - POP[i]);$$

در رابطه فوق W همان وزن اینرسی بوده دارای مقدار 0.4 می‌باشد [۴]. $R1$ و $R2$ اعداد تصادفی در بازه $[0,1]$ هستند. $PBEST[i]$ بهترین مکانی است که جزء i تاکنون داشته است. $POP[i]$ جزء i نام است. $REP[h]$ مقداری است که از مخزن استخراج می‌شود. h اندیسی است که به این شرح مقدار می‌گیرد: ابتدا به هر ابرمکعبی مقدار برازندگی نسبت داده می‌شود که عبارتست از حاصل تقسیم تعداد اجزای موجود در آن مکعب بر یک عدد خاص. سپس به شیوه‌ای مطابق با روش چرخ رولت^۸ عمل انتخاب ابرمکعب انجام می‌گیرد. پس از انتخاب ابرمکعب مزبور یک جزء از میان آن به صورت تصادفی انتخاب می‌شود.

پس از محاسبه سرعت هر جزء موقعیت جدید آن به وسیله رابطه زیر به دست می‌آید

$$POP[i] = POP[i] + VEL[i];$$

اکنون برازندگی هر جزء با توجه به توابع هدف تعریف شده مجدداً محاسبه شده محتویات مخزن REP به وسیله اجرای مسلط جدید تغییر می‌یابد. ضمناً چنانچه جزء i نام از موقعیت بهتری برخوردار شود حافظه آن نیز تغییر می‌کند

$$PBEST[i] = POP[i];$$

نهایتاً یک واحد به شمارنده حلقه اضافه شده در صورت عدم تحقق شرط اتمام، پردازش‌های گفته شده در این حلقه مجدداً تکرار می‌شود.

۳- طبقه‌بندی کننده چندمنظوره گروه ذرات

در این بخش با استفاده از ابزار جستجوی چندمنظوره‌ای که در بخش قبل معرفی شد، به طراحی طبقه‌بندی کننده‌ای مبادرت می‌شود که ضمن تخمین ضرایب ابرصفحه‌های جدا کننده کلاس‌های مختلف قادر به

هر یک از اجزا و Pop اندازه گروه است. $V_i = (v_{i1}, v_{i2}, \dots, v_{in})$ بردار سرعت i امین جزء گروه، $P_i = (p_{i1}, p_{i2}, \dots, p_{in})$ بهترین موقعیت دیده شده تاکنون توسط i امین جزء، $Y_i = (y_{i1}, y_{i2}, \dots, y_{in})$ موقعیت فعلی وی بوده، $P_g = (p_{g1}, p_{g2}, \dots, p_{gn})$ می‌تواند موقعیت بهترین جزء در میان کل گروه باشد که به این حالت بهترین-کلی^۱ گفته می‌شود. در صورتیکه P_g موقعیت بهترین جزء در یک همسایگی تعیین شده باشد، روش بهینه‌سازی گروه ذرات را بهترین-محلی^۲ می‌نامند. واضح است در این حالت چنانچه اندازه همسایگی برابر با اندازه گروه باشد، بهترین-محلی به بهترین-کلی تبدیل می‌شود. n ابعاد فضا را مشخص می‌کند. q شمارنده تعداد تکرار حلقه اصلی روش بهینه‌سازی گروه ذرات است. ϕ و ϕ_p دو عدد تصادفی با توزیع یکنواخت در بازه $[0,1]$ هستند. c_1 و c_2 دو عدد ثابت مثبت بوده و به ترتیب پارامتر فردی^۳ و پارامتر اجتماعی^۴ نام دارند. در کاربردهای معمولی هر دو این ضرایب برابر با 2 انتخاب می‌شوند. ω وزن اینرسی نام داشته به جهت ایجاد توازن لازم بین یافتن پاسخ کلی و محلی در رابطه (۲) وارد شده است. معمولاً مقادیر زیاد ω به معنای تأکید بر جستجو برای پاسخ کلی است و مقادیر کم آن معنای جستجو برای یافتن پاسخ‌های محلی را در بر دارد [۸] و [۹].

ب) روش بهینه‌سازی چندمنظوره گروه ذرات

راهکارهای مختلفی در خصوص به کارگیری روش بهینه‌سازی گروه ذرات در حل مسایلی که شامل چند تابع هدف هستند پیشنهاد شده است [۴] تا [۶]. با توجه به کارایی و هزینه محاسباتی کمتری که روش پیشنهادی در [۴] به هنگام مواجهه با توابع آزمون پیچیده از خود نشان داده است در پایه‌ریزی طبقه‌بندی کننده پیشنهاد شده در این تحقیق از همین روش استفاده شده است. این راهکار که به نام روش بهینه‌سازی چندمنظوره گروه ذرات خوانده شده است دارای مرحله‌ای است که به طور خلاصه در زیر آورده شده است^۵ (برای توضیحات کاملتر درباره این روش به [۴] مراجعه شود).

۱) ایجاد جمعیت اولیه (POP)

در این مرحله یک گروه اولیه شامل تعداد مورد نظری از اجزا (حداکثر MAX) کاملاً به طور تصادفی ایجاد می‌شود

For $i = 1$ to MAX

Initialize $POP[i];$

End For;

۲) تعیین سرعت اولیه هر یک از اجزا

در این قسمت سرعت اولیه صفر برای هر یک از اجزا تعیین می‌شود

For $i = 1$ to MAX

$VEL[i] = 0;$

End For;

۳) ارزیابی هر یک از گروه ذرات و محاسبه توابع برازندگی آنها

Evaluate (POP);

۴) ذخیره‌سازی موقعیت‌های اجزای غیر چیره شده^۶ در یک

1. G-best
2. L-best
3. Cognitive Parameter
4. Social Parameter

۵. نرم‌افزار Multi Objective Particle Swarm Optimization (MOPSO) را می‌توان از سایت <http://www.liana.mx/~ccoello/EMOsoftware.html> اخذ کرد.

6. Nondominated

7. Hypercubes

8. Roulette Wheel

بیشتر شکل (۱) را در نظر بگیرید. در این شکل دو کلاس متفاوت که نمونه‌های آنها در فضای ویژگی دوبعدی با گلوله‌های سفید و سیاه از یکدیگر متمایز شده‌اند به وسیله $d(x)$ از یکدیگر جدا شده‌اند. تابع تصمیم $d(x)$ یکی از الگوهای سیاه را به کلاس سفید نسبت داده است. بنابراین نرخ تشخیص گلوله‌های سیاه به وسیله $d(x)$ معادل ۸۰٪ است. این در حالی است که قابلیت اطمینان کلاس سیاه ۱۰۰٪ است. برعکس اگرچه نرخ تشخیص صحیح گلوله‌های سفید به وسیله $d(x)$ ۱۰۰٪ است اما میزان اطمینان به تصمیم این طبقه‌بندی کننده در خصوص تعلق یک الگو به کلاس سفید ۸۳٪ (یعنی ۵ از ۶) است.

میزان قابلیت اطمینان هر کلاس را به صورت زیر تعریف می‌کنیم

$$R_i = \frac{T_i}{T} \quad (5)$$

که در آن T_i تعداد کل نقاط آموزشی کلاس i ام است که به وسیله ابرصفحه‌های موجود درست طبقه‌بندی شده‌اند. T تعداد کل نقاط آموزشی است که توسط یک ابرصفحه در ناحیه متعلق به این کلاس قرار گرفته است و R_i قابلیت اطمینان i ام است.

یکی از توابع برازندگی مناسبی که می‌توان برای رسیدن به بیشترین قابلیت اطمینان در طبقه‌بندی کننده چندمنظوره گروه ذرات تعریف کرد به صورت حاصلضرب قابلیت‌های اطمینان به دست آمده برای هر کلاس است


$$fit_r(P_i) = \prod_{j=1}^M R_j \quad (6)$$

در این رابطه P_i نشان‌دهنده i امین جزء، R_j قابلیت اطمینان کلاس j ام است که به وسیله جزء P_i به دست آمده است، M تعداد کل کلاس‌ها و $fit_r(P_i)$ مقدار تابع برازندگی P_i بر اساس ملاک قابلیت اطمینان است.

(ج) تعداد ابرصفحه‌ها

یکی از مسایل مهم که لازم است در یافتن توابع تصمیم مورد توجه قرار گیرد مسئله فوق-آموزش یا فوق-برازش است. این پدیده عبارت است از استفاده از تعداد توابع تصمیم زیاد یا سازماندهی پیچیده به منظور به حداقل رساندن خطای آموزش، در حالیکه خطای آزمایش ممکن است مقدار درخور توجهی باشد. این مسئله معمولاً ناشی از یک سواس غیر منطقی در طبقه‌بندی داده‌های آموزشی است به گونه‌ای که برای به حداقل رساندن خطای آموزش طبقه‌بندی کننده، از توابع تصمیم بیش از اندازه و با جایابی‌هایی بسیار نزدیک به هم استفاده می‌شود. واضح است که سازماندهی توابع تصمیم با تعداد زیاد و با موقعیت‌هایی که نواحی کدگذاری شده به وسیله آنها مناطق کوچک و گاه بسیار محدودی از فضای ویژگی را شامل می‌شود، نه تنها هیچ تضمینی را در خصوص کاهش خطای آزمایش طبقه‌بندی کننده در بر ندارد بلکه ممکن است خود، منجر به افزایش آن شود.

آنچه مسلم است این است که یکی از عوامل مؤثر در بروز مسئله فوق-آموزش استفاده بی‌رویه از تعداد زیاد ابرصفحه‌ها در طبقه‌بندی داده‌ها است. در طراحی طبقه‌بندی کننده پیشنهادی، تعداد ابرصفحه‌ها متغیر فرض شده‌اند. همانطور که در بخش (۳-۱) اشاره شد، اجزاء در طبقه‌بندی کننده‌های گروه ذرات که تاکنون معرفی شده‌اند [۱] تا [۳]، به شکل $P = [W_1, W_2, \dots, W_i, \dots, W_H]'$ تعریف می‌شوند که در آن $W_i = (w_{i1}, w_{i2}, \dots, w_{in}, w_{in+1})$ بردار اوزان i امین ابرصفحه است. پس هر سطر در یک جزء در بردارنده ضرایب یک ابرصفحه است و تعداد



شکل ۱: نرخ تشخیص صحیح کلاس سفید ۱۰۰٪ و قابلیت اطمینان آن ۸۳٪ و نرخ تشخیص صحیح کلاس سیاه ۸۰٪ و قابلیت اطمینان آن ۱۰۰٪ است.

بهینه‌سازی شاخص‌های مهم نرخ تشخیص صحیح، قابلیت اطمینان و تعداد ابرصفحه‌های لازم برای مرزبندی موثر کلاس‌های متفاوت در فضای ویژگی است. روشهای مختلف استفاده از ابرصفحه‌ها برای جداسازی کلاس‌های مختلف در [۱۰] آمده است.

۳-۱ نحوه تعریف اجزا

در طبقه‌بندی کننده‌های معمولی گروه ذرات، اجزا آرایه‌هایی از ابرصفحه‌های جداکننده کلاس‌ها هستند که در ابتدا کاملاً به صورت تصادفی ایجاد می‌شوند [۱] تا [۳]. به عبارت دیگر هر جزء به شکل $W_i = (w_{i1}, w_{i2}, \dots, w_{in}, w_{in+1})$ که در آن $P = [W_1, W_2, \dots, W_i, \dots, W_H]'$ بردار اوزان i امین ابرصفحه در فضای ویژگی n بعدی و H تعداد ابرصفحه‌ها است. پس هر سطر در یک جزء در بردارنده ضرایب یک ابرصفحه است و تعداد سطرها بیانگر تعداد ابرصفحه‌ها است. در طبقه‌بندی کننده پیشنهاد شده نیز اجزا دارای ساختاری مشابه هستند، با این تفاوت که تعداد سطرها (و در نتیجه تعداد ابرصفحه‌ها) متغیر فرض شده‌اند. توضیحات تکمیلی در خصوص این تفاوت در ادامه همین بخش خواهد آمد.

۳-۲ تعریف توابع هدف

در طبقه‌بندی کننده جدید لازم است هر یک از شاخص‌های مورد نظر به صورت توابع برازندگی مناسبی معرفی شوند تا در حین پردازش، اجزا به سمت بهترین مقادیر این توابع سوق داده شوند.

(الف) نرخ تشخیص صحیح

تابع برازندگی که برای بهینه‌سازی نرخ تشخیص صحیح معرفی می‌شود به شکل زیر است

$$fit_r(P_i) = \frac{T - Miss(P_i)}{T} \quad (4)$$

در رابطه فوق P_i نشان‌دهنده i امین جزء، $Miss(P_i)$ تعداد نقاط آموزشی است که توسط P_i به اشتباه طبقه‌بندی شده است، T تعداد کل نقاط آموزش و $fit_r(P_i)$ مقدار تابع برازندگی P_i برای دستیابی به نرخ تشخیص صحیح ماکزیمم است.

(ب) قابلیت اطمینان

قابلیت اطمینان شاخص مهم دیگری در پردازش الگو است که به نوعی میزان اعتبار تصمیم نهایی طبقه‌بندی کننده در مواجهه با یک الگو را مشخص می‌کند. گفتنی است بسیار اتفاق می‌افتد که یک طبقه‌بندی کننده توانایی تشخیص صحیح همه الگوهای آموزشی یک کلاس خاص را دارد ولی به دلیل ورود الگوهای دیگر به منطقه کلاس مذکور، قابلیت اطمینان تصمیم اتخاذ شده را کاهش می‌دهد. برای توضیح

الکترومغناطیسی بازگشتی از هدف و مدولاسیون قسمت‌های چرخان اهداف بر روی سیگنال ارسالی رادار اشاره کرد که به ترتیب در [۱۳] تا [۱۶] گزارش شده‌اند.

در این تحقیق از روش مدولاسیون قسمت‌های چرخان اهداف استفاده شده است. اغلب اهداف دارای قسمت‌های چرخنده‌ای هستند که بر روی سیگنال سینوسی ارسالی رادار نوعی عمل مدولاسیون انجام می‌دهند. پره‌های موتورهای جت، پره‌های ملخ هواپیما و پره‌های هلیکوپتر مثال‌هایی از قسمت‌های چرخان اهداف مختلف هستند.

یک مدل ریاضی با دقت خوب برای شبیه‌سازی سیگنال‌های بازگشتی از قسمت‌های چرخان هواپیما در [۱۷] پیشنهاد شده است. این مدل تئوری با استفاده از ویژگی‌های توپولوژیک قسمت‌های چرخان و برخی پارامترهای دیگر سیگنال برگشتی از هدف را به دست می‌دهد. با استفاده از این مدل ابتدا سیگنال بازگشتی از ۱۰ هدف مرجع در زاویه دید 20° شبیه‌سازی می‌شوند (اهداف مرجع همان‌هایی هستند که در [۲] و [۳] استفاده شده‌اند). پس از نمونه‌برداری از سیگنال شبیه‌سازی شده و انجام یک سری عملیات پیش‌پردازش اقدام به اعمال تبدیل فوریه سریع^۸ ۱۲۸ نقطه‌ای روی سیگنال حاصل می‌شود. بردارهای ویژگی در واقع همین بردارهای به دست آمده ۱۲۸ بعدی به دست آمده از تبدیل فوریه سریع روی سیگنال‌های نمونه‌برداری شده در حوزه زمان هستند.

۴-۱ نتایج طبقه‌بندی داده‌های مرجع

این قسمت شامل طبقه‌بندی داده‌های گل‌های زنبق، شراب و اهداف رادار به وسیله سه طبقه‌بندی کننده مبتنی بر روش‌های هوش جمعی است که در تحقیقات اخیر گزارش شده‌اند. در کنار آنها نتایج حاصل از حل مسایل مذکور به وسیله طبقه‌بندی کننده چندمنظوره گروه ذرات (MOPS-Classifer) نیز گزارش خواهد شد. طبقه‌بندی کننده‌های ارائه شده در تحقیقات قبل عبارتند از طبقه‌بندی کننده گروه ذرات (PS-Classifer) [۱]، طبقه‌بندی کننده هوشمند گروه ذرات با وزن اینرسی (IPS۱-Classifer) [۲] و طبقه‌بندی کننده هوشمند گروه ذرات با عامل محدودکننده (IPS۲-Classifer) [۳]. کلیه شبیه‌سازی‌ها و آزمایش‌های انجام گرفته به وسیله رایانه با واحد پردازش مرکزی Pentium IV ۱۶۰۰ و در محیط نرم‌افزار Matlab[®] ۷٫۰ انجام گرفته‌اند. جمعیت تصادفی اولیه برای همه طبقه‌بندی کننده‌های فوق‌الذکر ۲۰ در نظر گرفته شده است. سایر ویژگی‌های طبقه‌بندی کننده‌ها دقیقاً همان‌هایی هستند که در تحقیقات یادشده گزارش شده‌اند. داده‌های آموزشی در کلیه شبیه‌سازی‌ها کاملاً به صورت تصادفی و به تعداد مساوی از هر کلاس انتخاب شده‌اند. بقیه داده‌های موجود به عنوان داده‌های آزمایشی تلقی شده‌اند.

جداول (۱) و (۲) به ترتیب نتایج مقایسه‌ای طبقه‌بندی داده‌های گل‌های زنبق و داده‌های شراب را برای ۳۰ داده آموزشی (۱۰ نمونه از هر کلاس) در بر دارد. این جداول شاخص‌های نرخ تشخیص صحیح و قابلیت اطمینان به دست آمده از سه نوع طبقه‌بندی کننده مبتنی بر روش‌های هوش جمعی گزارش شده، در کنار طبقه‌بندی کننده پیشنهادی در این تحقیق را در بردارند. این مقادیر هم برای داده‌های آموزشی و هم برای

سطرها بیانگر تعداد ابرصفحه‌ها است. می‌توان برای دستیابی به بهترین تعداد ابرصفحه‌ها تعداد سطرها را متغیر اختیار نمود. به این ترتیب در طبقه‌بندی کننده جدید فرم اجزا به صورت آرایه‌هایی با تعداد سطرهای متغیر فرض می‌شود. به عبارت بهتر اجزا دارای فرم‌هایی متغیر از $P = [W_1, W_2, \dots, W_{H_{\max}}]'$ تا $P = [W_1, W_2, \dots, W_{H_{\min}}]'$ هستند به طوری که $H_{\min} = \log^M$ حداقل تعداد ابرصفحه‌ها (برای M کلاس مجزا) می‌باشد و H_{\max} حداکثر تعداد ابرصفحه‌ها است و به صورت پیش فرض انتخاب می‌شود. به این ترتیب با توابع برازندگی که در (۴) و (۶) معرفی شدند می‌توان بهترین تعداد ابرصفحه‌ها را برای پیشگیری از مسئله فوق-آموزش و فوق-برازش تخمین زد. در صورتی که در حین تخمین ابرصفحه‌ها، نیاز به انجام عملیات همزمان روی اجزایی با تعداد سطرهای متفاوت روی دهد ابعاد اجزای با تعداد سطر کمتر را با افزودن تعداد مناسب سطرهای صفر با اجزای دیگر هم‌بعد می‌شوند.

۴-۲ نتایج عملی

در این فصل به گزارش نتایج به دست آمده از حل سه مسئله تشخیص الگو به وسیله طبقه‌بندی کننده پیشنهادی خود و مقایسه آنها با سایر طبقه‌بندی کننده‌های مشابه می‌پردازیم.

دو مسئله متداول در تشخیص الگو به همراه یک زمینه خاص کاربردی، مسایل برگزیده در این تحقیق هستند. دو مسئله متداول عبارتند از طبقه‌بندی داده‌های گل‌های زنبق و طبقه‌بندی داده‌های انواع شراب و مسئله کاربردی خاص عبارت است از تشخیص خودکار اهداف رادار که ذیلاً در مورد هر یک توضیح می‌دهیم.

داده‌های گل‌های زنبق - داده‌های گل‌های زنبق شامل ۵۰ اندازه‌گیری از چهار ویژگی سه نوع گل زنبق به نام‌های Versicolor، Setosa و Vergenica است [۱۱]. این ویژگی‌ها عبارتند از طول کاسبرگ، عرض کاسبرگ، طول گلبرگ و عرض گلبرگ. بنابراین در این مسئله سه کلاس موجود است و هر کلاس دارای ۵۰ الگو با بردارهای ویژگی چهاربعدی است.

داده‌های انواع شراب - این مجموعه متشکل از آنالیز شیمیایی عناصر رشد داده شده شراب‌های یکسان در شرایط مساوی است [۱۲]. بردارهای ویژگی دارای ۱۳ مولفه الکل، اسیدمالیک ($C_4H_6O_5$)، خاکستر^۱، میزان کالین بودن خاکستر، منیزیم، فنل^۲ مجموع، فلامانوتیدها^۳، فنل‌های غیر فلامانوتیدی، پروتوکاتانین^۴، شدت رنگ، مشخصه ظاهری، میزان OD_{280}/OD_{315} شراب‌های رقیق شده و پرولین^۵ هستند. در مجموع ۱۷۸ الگو از سه کلاس مجزا در این مجموعه داده وجود دارد.

طبقه‌بندی خودکار اهداف رادار - طبقه‌بندی کننده خودکار اهداف رادار یکی از مسایل کاربردی تشخیص الگو است که هدف از آن تجهیز رادارهای موج پیوسته به سیستمی است که بتوان با آن علاوه بر موقعیت و سرعت هدف به نوع هدف نیز آگاهی پیدا کرد. روش‌های متفاوتی به این منظور معرفی شده‌اند که از آن جمله می‌توان به استفاده از سطح مقطع راداری^۶، فرکانس‌های تشدید اهداف، تغییرات قطبش^۷ سیگنال

1. Ash
2. Phenol
3. Flamanoids
4. Proanthocyanin
5. Proline
6. Radar Cross Section
7. Polarization

8. Fast Fourier Transform (FFT)

جدول ۱: نتایج مقایسه‌ای به دست آمده برای سه طبقه‌بندی کننده هوش جمعی در کنار طبقه‌بندی کننده چندمنظوره پیشنهادی (MOPS-CLASSIFIER) برای داده‌های گل‌های زنبق، به ازای ۳۰ نقطه آموزش.

	MOPS-Classifer H=۳		IPS۱-Classifer H=۵		IPS۲-Classifer H=۵		PS-Classifer H=۵	
	نقاط آموزش	نقاط آزمایش	نقاط آموزش	نقاط آزمایش	نقاط آموزش	نقاط آزمایش	نقاط آموزش	نقاط آزمایش
متوسط قابلیت اطمینان (%)	۹۳٫۳	۸۸٫۹	۸۳٫۳	۷۷٫۸	۸۴٫۱	۸۰٫۲	۷۳٫۹	۶۸٫۴
متوسط نرخ تشخیص (%)	۹۶٫۴	۹۴٫۶	۹۵٫۷	۸۹٫۹	۹۷٫۷	۹۰٫۳	۸۴٫۴	۷۷٫۵

جدول ۲: نتایج مقایسه‌ای به دست آمده برای سه طبقه‌بندی کننده هوش جمعی در کنار طبقه‌بندی کننده چندمنظوره پیشنهادی (MOPS-CLASSIFIER) برای داده‌های شراب، به ازای ۳۰ نقطه آموزش.

	MOPS-Classifer H=۳		IPS۱-Classifer H=۵		IPS۲-Classifer H=۵		PS-Classifer H=۷	
	نقاط آموزش	نقاط آزمایش	نقاط آموزش	نقاط آزمایش	نقاط آموزش	نقاط آزمایش	نقاط آموزش	نقاط آزمایش
متوسط قابلیت اطمینان (%)	۹۰٫۷	۸۲٫۱	۷۸٫۳	۷۲٫۹	۸۱٫۳	۷۶٫۶	۷۵٫۴	۶۳٫۵
متوسط نرخ تشخیص (%)	۹۲٫۳	۹۱٫۴	۹۶٫۲	۸۳٫۴	۹۵٫۵	۸۹٫۳	۸۷٫۸	۷۲٫۳

شاخص قابلیت اطمینان صورت نگرفته است.

در برخی موارد نرخ تشخیص صحیح نقاط آموزشی برای طبقه‌بندی کننده‌های قبلی، نسبت به طبقه‌بندی کننده پیشنهادی از مقادیر بهتری برخوردار است. اما در تمامی موارد نرخ تشخیص صحیح نقاط آزمایشی برای طبقه‌بندی کننده معرفی شده از سایر روشها بهتر گزارش شده است. این رویداد را نیز می‌توان به رخداد مسئله فوق-آموزش در طبقه‌بندی کننده‌های دیگر مرتبط دانست.

در مسئله طبقه‌بندی اهداف رادار، سیگنال‌های بازگشتی متعددی از اهداف معرفی شده در [۲] و [۳] را با افزودن توانهای مختلفی از نویز سفید گوسی شبیه‌سازی کرده، به عنوان نمونه‌های آموزشی استفاده کرده‌ایم. نمونه‌های آزمایشی نیز به روش مشابه و به تعداد لازم شبیه‌سازی می‌شوند. جداول ۳ و ۴ به ترتیب مقادیر متوسط نرخ تشخیص صحیح و قابلیت اطمینان حاصل از اعمال طبقه‌بندی کننده‌های مختلف را در نسبت‌های مختلف سیگنال به نویز، برای نقاط آموزشی نشان می‌دهند. جداول ۵ و ۶ همین مقادیر را برای نقاط آزمایشی نشان می‌دهند. تعداد نقاط آموزشی ۱۰۰ (ده نقطه از هر کلاس) و تعداد نقاط آزمایشی نیز برابر با همین مقدار است. تعداد ابرصفحه‌ها برای طبقه‌بندی کننده چندمنظوره گروه ذرات به وسیله خود این طبقه‌بندی کننده برابر ۵ تخمین زده شده است. سایر طبقه‌بندی کننده‌ها قادر به تخمین تعداد ابرصفحه‌ها نیستند بنابراین تعداد ابرصفحه‌ها برای آنها با چندین بار آزمایش و به صورت تجربی به دست آمده‌اند. این تعداد برای طبقه‌بندی کننده هوشمند گروه ذرات با وزن اینرسی و طبقه‌بندی کننده هوشمند گروه ذرات با عامل محدودکننده برابر با ۸ و برای طبقه‌بندی کننده گروه ذرات برابر با ۱۰ انتخاب شده است.

نتایج میسوطی که به ترتیب در جداول ۳ تا ۶ آمده است صحت ادعاهای منتج شده از آزمایشات قبل را در مواجهه با یک مسئله عملی بازشناسی الگو با بردارهای ویژگی ۱۲۸ عضوی نشان می‌دهند.

متوسط نرخ تشخیص داده‌های آموزشی برای طبقه‌بندی کننده پیشنهادی (MOPS-Classifer) در برخی موارد کمتر از طبقه‌بندی کننده‌های IPS۱-Classifer و IPS۲-Classifer است (جدول ۳). بیشترین تفاوت در عملکرد بین طبقه‌بندی کننده‌های یاد شده در سیگنال به نویز صفر و برابر با ۸/۷٪ دیده می‌شود. ولی باید به یاد داشت که طبقه‌بندی داده‌های آموزشی به تنهایی نمی‌تواند گویای عملکرد بهتر یک روش نسبت به سایر روشها باشد. نتایج مقایسه‌ای به دست آمده از

داده‌های آزمایشی گزارش شده‌اند. تعداد ابرصفحه‌ها در طبقه‌بندی کننده پیشنهادی ۳ و در سایر طبقه‌بندی کننده‌ها برای دستیابی به نتایج بهتر به صورت پیش فرض ۵ و یا ۷ در نظر گرفته شده است. نکته قابل توجه این است که تعداد ۳ ابرصفحه برای طبقه‌بندی کننده پیشنهادی به وسیله خود طبقه‌بندی کننده به دست آمده و در واقع می‌توان گفت این تعداد به همراه سایر نتایج مربوط به این طبقه‌بندی کننده در واقع مؤلفه‌های تشکیل دهنده یکی از نقاط جبهه پرتو است.

مقادیر جداول ۱ و ۲ معانی در خور توجهی را در بر دارند:

- طبقه‌بندی کننده چندمنظوره گروه ذرات عمل طبقه‌بندی را با تعداد ابرصفحه‌های کمتری انجام داده است. این در حالی است که متوسط نرخ تشخیص صحیح برای نقاط آزمایشی و متوسط قابلیت اطمینان با این تعداد ابرصفحه از همه موارد مشابه در سایر طبقه‌بندی کننده‌ها در این جداول بهتر است. این مسئله شاهدهی بر این واقعیت است که ابرصفحه‌های محاسبه شده به وسیله سایر روشهای طبقه‌بندی کننده، ابرصفحه‌های بهینه نبوده از پاسخ‌های غیر چیره شده به شمار نمی‌آیند.

- در اغلب مقادیر گزارش شده در این جداول تفاوت فاحشی بین نرخ تشخیص نقاط آموزشی و آزمایشی در طبقه‌بندی کننده‌های قبلی وجود دارد (از ۵ تا ۱۵ درصد). این مسئله نشأت گرفته از گزینش تعداد ابرصفحه‌های زیاد برای طبقه‌بندی داده‌های آموزشی است که در واقع همان پدیده فوق-آموزش یا فوق-برازش است. این در حالی است که تفاوت بین نرخ تشخیص نقاط آموزشی و آزمایشی در طبقه‌بندی کننده پیشنهادی (MOPS_Classifer) مقدار ناچیزی در حدود ۲٪ است. به عبارت بهتر مشکلات فوق-آموزش و فوق-برازش در طبقه‌بندی کننده چند منظوره گروه ذرات به چشم نمی‌خورد و این طبقه‌بندی کننده می‌تواند مقدار بهینه تعداد ابرصفحه‌ها را نیز تخمین بزند.

- آنچه در این جداول بیش از سایر موارد جلب توجه می‌کند بهبود قابل توجهی است که در شاخص قابلیت اطمینان برای طبقه‌بندی کننده پیشنهادی، نسبت به سایر طبقه‌بندی کننده‌ها رخ داده است. علت اصلی این بهبود آن است که در طبقه‌بندی کننده‌های هوش جمعی که تاکنون گزارش شده‌اند، تنها ملاکی که برای تخمین ابرصفحه‌ها در نظر گرفته شده است، نرخ تشخیص صحیح داده‌ها در مرحله آموزش است. به عبارت دیگر در این طبقه‌بندی کننده‌ها تنها یک تابع برازندگی، آن هم برای به حداقل رساندن تعداد نقاط آموزشی که به اشتباه طبقه‌بندی شده‌اند، تعریف گردیده است و هیچ تلاشی برای ساماندهی ابرصفحه‌ها در جهت افزایش

جدول ۵: متوسط نرخ تشخیص صحیح نقاط آموزش (%) در طبقه‌بندی اهداف رادار برای ۱۰۰ داده آزمایشی در نسبت‌های مختلف سیگنال به نویز.

	نسبت‌های سیگنال به نویز (dB)					
	-۱۰	-۵	۰	۵	۱۰	۱۵
MOPS-Classifier	۱۰,۳	۱۶,۵	۳۳,۳	۵۷,۸	۷۲,۲	۸۹,۶
IPS۱-Classifier	۱۱,۴	۱۳,۱	۲۵,۴	۴۴,۷	۶۳,۸	۸۰,۴
IPS۲-Classifier	۱۰,۱	۱۴,۳	۲۷,۴	۴۷,۶	۶۱,۵	۷۸,۳
PS-Classifier	۸,۳	۱۳,۹	۲۰,۷	۴۱,۶	۵۷,۳	۷۴,۶

جدول ۶: متوسط قابلیت اطمینان محاسبه‌شده در مرحله آزمایش (%) در طبقه‌بندی اهداف رادار برای ۱۰۰ داده آزمایشی در نسبت‌های مختلف سیگنال به نویز.

	نسبت‌های سیگنال به نویز (dB)					
	-۱۰	-۵	۰	۵	۱۰	۱۵
MOPS-Classifier	۴,۴	۱۳,۴	۲۰,۶	۵۰,۲	۶۶,۶	۷۳,۱
IPS۱-Classifier	۷,۵	۹,۱	۱۵,۴	۴۱,۷	۵۱,۰	۶۲,۴
IPS۲-Classifier	۸,۷	۱۰,۱	۱۶,۴	۳۹,۳	۵۶,۳	۶۱,۷
PS-Classifier	۹,۳	۱۱,۱	۱۲,۳	۲۷,۶	۴۸,۹	۵۴,۴

البته باید اذعان کرد که در قبال توانایی‌های افزوده‌شده به طبقه‌بندی کننده پیشنهاد شده هزینه محاسباتی آن نیز افزایش یافته است که دلیل عمده آن بهینه‌سازی چند تابع برازندگی به صورت همزمان است. اما با توجه به اینکه هزینه‌های محاسباتی در مرحله آموزش لحاظ می‌شود، از این رو می‌توان گفت پس از تحمل این محاسبات و تخمین ابرصفحه‌ها، در مرحله آزمایش طبقه‌بندی کننده پیشنهاد شده نسبت به انواع مشابه خود هیچ‌گونه بار اضافه محاسباتی را تحمل نمی‌کند. در واقع در مرحله آزمایش کافی است معلوم شود الگوی ناشناس به کدامیک از نواحی کد شده به وسیله ابرصفحه‌های محاسبه‌شده تعلق دارد.

نکته مهم دیگری که ذکر آن لازم است پیچیدگی سیستماتیک کمتری است که طبقه‌بندی کننده پیشنهاد شده نسبت به سایر موارد مشابه (طبقه‌بندی کننده‌های هوشمند گروه ذرات) دارد. باید به یاد آورد که طبقه‌بندی کننده‌های هوشمند گروه ذرات با وزن اینرسی و با فاکتور محدودکننده هر دو دارای کنترل کننده فازی اضافه‌ای هستند که نقش کنترل پارامترهای مؤثر در روشهای بهینه‌سازی را در هر بار تکرار حلقه جستجو بر عهده دارند. این کنترل کننده‌های فازی اگرچه به جستجوی مؤثر برای یافتن ابرصفحه‌ها کمک می‌کنند و تعداد تکرار حلقه اصلی را به نحو قابل ملاحظه‌ای کاهش می‌دهند، اما به پیچیدگی سیستماتیک طبقه‌بندی کننده‌های هوشمند گروه ذرات نیز منجر می‌شوند. طبقه‌بندی کننده پیشنهاد شده در این تحقیق فاقد هرگونه کنترل کننده اضافی است و از این رو دارای سادگی بیشتری نسبت به انواع مشابه خود می‌باشد.

بررسی تئوریک عملکرد طبقه‌بندی کننده پیشنهادشده برای دستیابی به ملاکی مقایسه‌ای با طبقه‌بندی کننده بیز (به عنوان یک طبقه‌بندی کننده بهینه)، همچنین اتخاذ تدابیری جدید برای نزدیک کردن عملکرد طبقه‌بندی کننده‌های گروه ذرات به عملکرد طبقه‌بندی کننده بهینه بیز می‌تواند موضوعات در خور توجهی برای تحقیقات بعدی در زمینه طبقه‌بندی کننده‌های گروه ذرات باشند.

جدول ۳: متوسط نرخ تشخیص صحیح نقاط آموزش (%) در طبقه‌بندی اهداف رادار برای ۱۰۰ داده آموزشی در نسبت‌های مختلف سیگنال به نویز.

	نسبت‌های سیگنال به نویز (dB)					
	-۱۰	-۵	۰	۵	۱۰	۱۵
MOPS-Classifier	۱۳,۳	۲۳,۵	۴۷,۸	۶۲,۶	۷۵,۳	۹۰,۱
IPS۱-Classifier	۱۰,۱	۱۹,۱	۵۳,۲	۶۷,۸	۸۰,۱	۹۲,۳
IPS۲-Classifier	۱۴,۴	۲۴,۱	۵۶,۵	۷۰,۱	۷۹,۹	۹۴,۴
PS-Classifier	۱۲,۲	۱۶,۷	۳۷,۵	۵۶,۳	۶۱,۴	۷۳,۲

جدول ۴: متوسط قابلیت اطمینان محاسبه‌شده در مرحله آموزش (%) در طبقه‌بندی اهداف رادار برای ۱۰۰ داده آموزشی در نسبت‌های مختلف سیگنال به نویز.

	نسبت‌های سیگنال به نویز (dB)					
	-۱۰	-۵	۰	۵	۱۰	۱۵
MOPS-Classifier	۱۱,۱	۲۰,۷	۴۳,۲	۷۱,۹	۷۷,۳	۸۴,۳
IPS۱-Classifier	۹,۱	۱۷,۴	۲۷,۸	۵۸,۵	۶۰,۵	۷۵,۲
IPS۲-Classifier	۸,۲	۱۸,۴	۳۳,۳	۶۴,۷	۶۷,۵	۷۳,۳
PS-Classifier	۱۰,۱	۱۳,۱	۲۱,۲	۴۲,۱	۵۰,۳	۶۶,۶

طبقه‌بندی داده‌های آزمایشی حاکی از توانایی بیشتر طبقه‌بندی کننده MOPS-Classifier نسبت به سایر طبقه‌بندی کننده‌های مشابه خود می‌باشد (جدول ۵). این نتایج به خوبی نشان می‌دهند که ابرصفحه‌های تخمین زده شده به وسیله طبقه‌بندی کننده پیشنهادی در مواجهه با داده‌های آزمایشی از کارایی بیشتری برخوردارند. تعداد بیشتر ابرصفحه‌ها در طبقه‌بندی کننده‌های دیگر می‌تواند به نحوی بیانگر بروز مسئله فوق-آموزش در آنها باشند. نکته مهم دیگر اضافه شدن شاخص قابلیت اطمینان به عنوان یک تابع برازندگی دیگر در طبقه‌بندی کننده پیشنهادی است و همانطور که از جداول ۴ و ۶ قابل استنباط است در هر دو مرحله آموزش و آزمایش طبقه‌بندی کننده MOPS-Classifier از قابلیت اطمینان بیشتری برخوردار است.

۵- نتیجه‌گیری

در این تحقیق با تکیه بر قابلیت جستجو و بهینه‌سازی همزمان چندین تابع هدف در روش بهینه‌سازی گروه ذرات طبقه‌بندی کننده جدید و چندمنظوره‌ای پیشنهاد شده است که قادر به تخمین توابع تصمیمی است که در محاسبه آنها شاخص‌های مختلف و مهم نرخ تشخیص صحیح، قابلیت اطمینان و تعداد ابرصفحه‌ها لحاظ شده‌اند. طبقه‌بندی کننده چندمنظوره گروه ذرات پیشنهادشده نه تنها فاقد معایبی نظیر فوق-آموزش و فوق-برازش است بلکه میزان اطمینان به تصمیمات اتخاذشده در آن به میزان قابل توجهی نسبت به سایر موارد مشابه، افزایش یافته است.

همچنین طبقه‌بندی کننده چندمنظوره طراحی شده قابلیت آن را دارد که به جای یک مجموعه از ابرصفحه‌ها مجموعه‌هایی از پاسخ‌های متنوع با مقادیر شاخص‌های مختلف را در اختیار کاربر قرار دهد. به این ترتیب امکان برپایی شرایط مورد نظر کاربر در مواردی خاص نیز فراهم می‌گردد. مواردی که در آنها ممکن است نرخ تشخیص صحیح مهمتر از قابلیت اطمینان باشد (و یا بالعکس).

- [10] J. T. Tou and R. C. Gonzalez, *Pattern Recognition Principles*, Addison-Wesely, Reading MA, 1974.
- [11] R. A. Fisher, "The use of multiple measurements in taxonomic problems," *Ann. Eugen.*, vol. 7, pp. 179-188, 1936.
- [12] -, *UCI Machine Learning Databases*, University of California, Irvine, via anonymous ftp:ftp.ics.uci.edu/pub/machine-learning-databases.
- [13] D. J. Strausberger, F. D. Garber, N. F. Chamberlain, and E. K. Walton, "Modeling and performance of HF/OTH radar target classification systems," *IEEE Trans. on Aerospace and Electronic Systems*, vol. 28, no. 2, pp. 396-402, Apr. 1992.
- [14] M. A. Morgan, "Target I. D. using natural resonance, a new concept for future radar systems," *IEEE Potential*, pp. 11-14, Dec. 1993.
- [15] N. F. Chamberlain, E. K. Walton, and F. D. Garber, "Radar target identification of aircraft using polarization-diverse features," *IEEE Trans. on Aerospace and Electronic Systems*, vol. 27, no. 1, pp. 58-66, Jan. 1991.
- [16] M. R. Bell and R. A. Grubbs, "JEM modeling and measurement for radar target identification," *IEEE Trans. on Aerospace and Electronic Systems*, vol. 29, no. 1, pp. 73-87, Jan. 1993.
- [17] J. Martin and B. Mulgrew, "Analysis of the theoretical radar returned signal from aircraft propeller blades," in *Proc. of the IEEE Int. Radar Conf.*, pp. 569-572, 1990.

سید حمید ظهیری تحصیلات خود را در مقاطع کارشناسی و کارشناسی ارشد مهندسی برق-الکترونیک بترتیب در سالهای ۱۳۷۱ و ۱۳۷۴ در دانشگاه صنعتی شریف و دانشگاه تربیت مدرس و دوره دکتری مهندسی برق-الکترونیک را در سال ۱۳۸۴ در دانشگاه فردوسی مشهد به پایان رسانده است. او هم اکنون استادیار دانشکده مهندسی دانشگاه بیرجند می‌باشد. زمینه‌های تحقیقاتی مورد علاقه ایشان عبارتند از: پردازش الگو (تصویر، سیگنال و ...)، تشخیص الگو، روشهای بهینه‌سازی زیستی و طبیعی، محاسبات نرم و کاربردهای آنها.

۶- سپاسگزاری

از حمایت‌های معاونت پژوهشی دانشگاه بیرجند که مؤلف را در انجام این تحقیق یاری کردند تشکر و قدردانی می‌شود.

مراجع

- [1] S. H. Zahiri and S. A. Seyedin, "Particle swarm classifiers," in *Proc. of the 13th Iranian Conf. of Elec. Eng., ICEE 2005*, pp. 454-458, Zanjan, Iran, 2005.
- [2] S. H. Zahiri and S. A. Seyedin, "Intelligent particle swarm classifier," *Iranian J. of Electrical and Computer Engineering*, vol. 4, no. 5, Winter-Spring, 2005.
- [3] S. H. Zahiri and S. A. Seyedin, "Swarm intelligence based classifiers," *Accepted for Publication by the J. of the Franklin Institute*, Available online at Elsevier scindirect from May 2006.
- [4] C. A. C. Coello and M. S. Lechuga, "MOPSO: a proposal for multiple objective particle swarm optimization," in *Proc of the 2002 Congress on Evolutionary Computation*, CEC '02, vol. 2, pp. 1051-1056, May 2002.
- [5] S. L. Ho, S. Yang, N. Guangzheng, E. W. C. Lo, and H. C. Wong, "A particle swarm optimization-based method for multiobjective design optimizations," *IEEE Trans. on Magnetic*, vol. 41, no. 5, pp. 1756-1759, May 2005.
- [6] C. A. C. Coello, G. T. Pulido, and M. S. Lechuga, "Handling multiple objectives with particle swarm optimization," *IEEE Trans. on Evolutionary Computation*, vol. 8, no. 3, pp. 256-279, Jun. 2004.
- [7] J. Kennedy and R. C. Eberhart, "Particle swarm optimization," in *Proc. IEEE Intl. Conf. on Neural Networks IV*, pp. 1942-1948, 1995.
- [8] Y. Shi and R. C. Eberhart, "Empirical study of particle swarm optimization," in *Proc. of the 1999 Cong. on Evolutionary Computation*, pp. 1945-1950, 1999.
- [9] R. C. Eberhart and Y. Shi, "Tracking and optimizing dynamic systems with particle swarms," in *Proc. of the 2001 Cong. on Evolutionary Computation*, vol. 1, pp. 94-100, 2001.

Archive of SID