

طراحی طبقه‌بندی کننده‌های چند هدفه با استفاده از روش CFO

سعیده شیخ پور^۱، سید حمید ظهیری^۲

۱- دانشجوی کارشناسی ارشد مهندسی الکترونیک، دانشکده مهندسی - دانشگاه بیرجند - بیرجند - ایران

Saeide.sheikhpour67@gmail.com

۲- دانشیار گروه الکترونیک و مخابرات، دانشکده مهندسی - دانشگاه بیرجند - بیرجند - ایران

hzahiri@birjand.ac.ir

چکیده: در طراحی طبقه‌بندی کننده‌ها و تخمین توابع تصمیم، غالباً هدف اصلی دسترسی به «نرخ تشخیص صحیح» بالا در فاز آموزش است. این در حالی است که اهداف دیگری نظیر میزان «قابلیت اطمینان» تصمیمات اتخاذ شده و «تعداد بهینه توابع تصمیم» نیز شاخص‌های بسیار مهمی هستند که در هنگام طبقه‌بندی کننده‌ها، هرگز نباید فراموش شوند. در این مقاله، ابتدا الگوریتم «بهینه سازی نیروی مرکزی» (CFO) برای بهینه سازی مسایل چند هدفه ارتقا یافته و سپس با به کارگیری روش ارائه شده طبقه‌بندی کننده‌ای معروفی شده‌اند که به طور همزمان اهداف فوق‌الذکر؛ یعنی «نرخ تشخیص صحیح»، «قابلیت اطمینان»، و «تعداد ابر صفحه‌های لازم» را بهینه سازی می‌نماید. با توجه به انتخاب مقدار بهینه تعداد ابرصفحه‌ها در روش پیشنهادی، 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 چند منظوره پیشنهادی با تخمین «جبهه پرتو» مجموعه‌ای از انتخاب‌های متنوع و بهینه از ابرصفحه‌های جدا کننده کلاس‌های مختلف را برای برپایی شرایط دلخواه کاربر در خصوص انتخاب شاخص‌های فوق‌الذکر، فراهم می‌آورد.

واژه‌های کلیدی: تشخیص الگو، روش هوشمند CFO، طبقه‌بندی کننده‌های چند هدفه.

کننده‌های متنوعی برای استفاده در سیستم‌های بازشناسی الگو مطرح شده است که از میان آنها می‌توان به طبقه‌بندی

کننده‌های بیز، k-نردیکترین همسایه^۱، شبکه عصبی و فازی^۲ اشاره کرد. در کنار این طبقه‌بندی کننده‌ها، انواع دیگری نیز بر اساس روش‌های هوش جمعی و تکاملی پیشنهاد شده‌اند ([۱]-[۳]).

پیشینه طراحی طبقه‌بندی کننده‌های مبتنی بر روش‌های جمعی چندان طولانی نیست و موضوعی است که به تازگی توجه محققان حوزه بازشناسی الگو را به خود معطوف کرده است. در گام نخست این پژوهش‌ها، یک «طبقه‌بندی کننده گروه ذرات»^۳ 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

۱- مقدمه

در طراحی یک سیستم تشخیص الگو پس از انجام مراحل مربوط به اخذ داده، عملیات پیش پردازش و استخراج ویژگی نوبت به استفاده از یک طبقه‌بندی کننده می‌رسد که با استفاده از بردارهای ویژگی توابع تصمیم^۱ را یافته، فضای ویژگی را به نواحی مختلفی که هر یک از آنها متعلق به یک کلاس خاص است، تقسیم کند. طبقه‌بندی

۱- تاریخ ارسال مقاله : ۱۳۹۱/۲/۲۴
تاریخ پذیرش مقاله : ۱۳۹۲/۰۱/۱۹
نام نویسنده مسؤول : سعیده شیخ پور
نشانی نویسنده مسؤول : ایران - بیرجند - شوکت آباد - دانشگاه بیرجند -
دانشکده مهندسی برق و کامپیوتر - گروه مهندسی الکترونیک

طراحی طبقه‌بندی کننده‌های چند هدفه با استفاده از روش CFO

پدیده «فوق-برازش^۱» یا «فوق-آموزش^۲» خوانده می‌شود و به عنوان یک پارامتر نامطلوب در طبقه‌بندی کننده‌ها به شمار می‌رود.

نتیجه جستجوی مؤلفان برای یافتن تحقیقاتی که در بردارنده طبقه‌بندی کننده‌های مبتنی بر روش‌های هوش جمعی باشند و ضمناً ایرادات فوق را هم مرتفع کرده باشند، نشان داد که در سال ۱۳۸۵، یک طبقه‌بندی کننده چند هدفه با استخدام روش بهینه سازی گروه ذرات، گزارش شده است [۱۸].

کاستی‌های فوق‌الذکر به همراه محدودیت پژوهش‌های انجام گرفته در موضوع مورد نظر از یک سو، و حضور روش‌های نوین هوش جمعی از سوی دیگر، انگیزه‌های قوی برای طراحی و معرفی نوع جدیدی از طبقه‌بندی کننده‌های هوش جمعی چند هدفه به شمار می‌روند.

اخیراً عضوی جدید از روش‌های هوش جمعی با نام «الگوریتم بهینه سازی نیروی مرکزی» (CFO) معرفی شده است که مکانیزم آن بر مبنای تاثیر نیروهای نیوتونی بر اجرامی است که در فضای جستجو به عنوان پاسخ‌های احتمالی مسئله پراکنده‌اند. این روش توانایی خود را در بهینه سازی توابع محک بسیار پیچیده و همچنین، در مواجهه با مسایل دشوار کاربردی نشان داده است [۷].

در این تحقیق، ابتدا نسخه «بهینه سازی چند هدفه» مربوط به «الگوریتم بهینه سازی نیروی مرکزی» با عنوان "MOCFO" معرفی می‌شود. در مرحله بعد، با استفاده از روش بهینه سازی چند هدفه پیشنهادی، طبقه‌بندی کننده چند منظوره‌ای به نام «طبقه‌بندی کننده چند هدفه نیروی مرکزی» "MOCFO-classifier" پیشنهاد شده است که به طور همزمان به بهینه سازی سه پارامتر زیر می‌پردازد:

۱- تعداد نقاط آموزشی که توسط ابرصفحه‌های معرفی شده به وسیله هر «عامل» از «جمعیت» به اشتباه طبقه‌بندی می‌شود.

۲- تعداد ابرصفحه‌های لازم برای تقسیم بندی مناسب فضای ویژگی و تخصیص هر منطقه به یک کلاس خاص.

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

شبکه عصبی و K -نژدیکترین همسایه است [۱]. در مرحله 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 ناشناس است. همین رهیافت با به کارگیری نوع جدیدتری از روش هوش جمعی در [۳] تجربه شد و نرخ بازنگشتنی بالاتری نیز به دست آمد. همه این تحقیقات گام‌های متواالی برای بهبود طبقه‌بندی کننده‌های نوظهور مبتنی بر روش‌های هوش جمعی به شمار می‌روند.

پژوهش‌های اشاره شده دارای نکات مشترکی به شرح زیر هستند:

- در همه تحقیقات فوق‌الذکر تنها ملاکی که مبنای ارزیابی عملکرد طبقه‌بندی کننده طراحی شده، «نرخ تشخیص صحیح^۳» 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. شاخص‌هایی مانند «قابلیت اطمینان^۴» که میزان اعتبار تصمیم یک طبقه‌بندی کننده را تعیین می‌کند، مثال بارزی از این شاخص‌های 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» به تصمیم اتخاذ شده زیاد است.

- تعداد ابرصفحه^۵‌های لازم برای تقسیم بندی فضای ویژگی در همه تحقیقات یاد شده به عنوان یک پیش فرض و با سعی و خططا به دست آمده است. بی‌تردید با به کارگیری 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

$$\begin{aligned} g_i(x) &\leq 0 \quad j = 1, 2, K, J \\ h_k(x) &= 0 \quad k = 1, 2, K, K \end{aligned} \quad (2)$$

$f_i(x)$ ، i امین تابع هدف، $g_i(x)$ ، j 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 است. در این صورت مسئله «بهینه سازی چند هدفه» عبارت است از یافتن پاسخی برای x که f را بهینه کند.

اغلب اوقات توابع هدف با یکدیگر در مغایرت^{۱۱} هستند؛ 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 خواهد آمد که بهینه ساز همه توابع هدف نبوده، بلکه ممکن است از دید تک تک آنها جواب‌های «نژدیک بهینه» تلقی شوند.

- یک مفهوم مهم در روش‌های بهینه سازی چند منظوره «سلط یا چیرگی^{۱۲}» است. پاسخ x را «سلط» بر x می‌خوانند؛ اگر شرایط زیر محقق شود:
- پاسخ x از دید هیچ یک از توابع هدف از x بدتر نباشد.
 - پاسخ x حداقل در یکی از توابع هدف از x بهتر باشد.

تعریف فوق به نوبه خود به تعریف «بهینگی پرتو^{۱۳}» منجر می‌شود. $U_i \in U$ مجموعه مرجع همه پاسخ‌های را «بهینه پرتو» گویند اگر و تنها اگر هیچ $x \in U$ وجود نداشته باشد که «سلط» بر x باشد. مجموعه همه پاسخ‌های x را مجموعه «بهینه پرتو» یا «جبهه پرتو» می‌خوانند.

روش‌های بهینه سازی مختلفی مانند روش‌های تکاملی^{۱۴}، روش «بهینه سازی گروه مورچگان^{۱۵}» و «بهینه سازی گروه ذرات» برای بهینه سازی چند هدفه به کار گرفته شده‌اند (برای مثال [۴]-[۶]). با توجه به توانایی روش نوظهور «بهینه سازی نیروی مرکزی» در مواجهه با مسایل پیچیده تک هدفه، به نظر می‌رسد با تعریف یک تابع

دو مسئله معروف طبقه بندی «داده‌های گل‌های زنق» و «داده‌های مایعات شیمیایی» در کنار مسئله کاربردی و پیچیده طبقه بندی «اهداف رادار» سه موضوع انتخاب شده برای بررسی عملکرد طبقه بندی 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 دوم به معرفی روش پیشنهادی بهینه سازی چند هدفه نیروی مرکزی خواهد پرداخت. سپس طبقه بندی کننده پیشنهادی با نام «طبقه بندی کننده چند هدفه نیروی مرکزی» در بخش سوم معرفی خواهد شد. بخش چهار نتایج عملی و مقایسه‌ای حاصل از حل سه مسئله انتخابی فوق الذکر را در بر دارد. نهایتاً بخش پنجم با جمع بندی و بحث در خصوص نتایج به دست آمده مقاله را به پایان خواهد رساند.

۲- معرفی روش بهینه سازی چند هدفه

نیروی مرکزی

در این بخش با به کارگیری روش بهینه سازی نیروی مرکزی، روش بهینه سازی چند هدفه تازه ای پایه ریزی می‌شود. این روش که به نام MOCFO-classifier خوانده می‌شود، در ادامه در طراحی طبقه بندی کننده‌های چند هدفه به کار گرفته خواهد شد. در ابتدا مفاهیم اصلی مربوط به «بهینه سازی چند هدفه» و الگوریتم «بهینه سازی نیروی مرکزی» (CFO) توضیح داده می‌شود.

۱-۱- مفهوم بهینه سازی چند منظوره

نیاز به بهینه سازی همزمان چندین تابع هدف در بسیاری از مسایل واقعی به چشم می‌خورد. حل این گونه مسایل غالباً به یافتن یک پاسخ یا (احتمالاً) مجموعه ای از پاسخ‌ها خواهد شد که مقادیر قابل قبولی از توابع هدف را دربر دارد. یک مسئله بهینه سازی با M هدف خاص را در حالت کلی می‌توان به صورت زیر تعریف کرد:

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

در حالی که شرایط زیر نیز باید رعایت شوند:

طراحی طبقه‌بندی کننده‌های چند هدفه با استفاده از روش CFO

جبهه بهینه (همان جبهه پرتو) به دست می‌آید. در نوع دیگر، ضرایب به صورت دینامیکی در طی فرایند جستجو و بهینه سازی تغییر می‌کنند. به این روش «تجمیع وزن‌دار دینامیکی» (DWA^{۱۸}) اطلاق می‌شود. نحوه تغییر ضرایب برای دوتابع هدف، هنگام اجرای الگوریتم از روابط زیر تعیت می‌کند:

$$\begin{aligned} a_1(t) &= |\sin(2\pi\omega t)| \\ a_2(t) &= 1 - a_1(t) \end{aligned} \quad (4)$$

که در آن، ω فرکانس تغییرات ضرایب، و t تعداد تکرار را نشان می‌دهد.

با توجه به عملکرد مطلوب روش DWA نسبت به روش CWA [۹۸]، در این مقاله از روش اخیر برای تعریف تابع تجمیعی استفاده شده است.

پس به طور خلاصه، برای ارتقای روش CFO تک هدفه به نوع چند هدفه، ابتدا مطابق روابط بالا ضرایب و تابع تجمیعی را تعریف کرده، با استفاده از روش CFO تک هدفه که در قسمت قبل به طور مبسوط توضیح داده شد، به بهینه سازی آن اقدام می‌کنیم.

۳- طبقه‌بندی کننده چند هدفه نیروی مرکزی (MOCFO-classifier)

در این بخش با استفاده از ابزار جستجوی چند منظوره‌ای که در بخش قبل معرفی شد، به طراحی طبقه‌بندی کننده‌ای مبادرت می‌شود که ضمن تخمین ضرایب ابرصفحه‌های جدا کننده کلاس‌های مختلف قادر به بهینه سازی شاخص‌های مهم «نرخ تشخیص صحیح»، «قابلیت اطمینان» و «تعداد ابرصفحه‌های لازم» برای مربی‌نیز موثر کلاس‌های متفاوت در فضای ویژگی است. روش‌های مختلف استفاده از ابرصفحه‌ها برای جداسازی کلاس‌های مختلف در [۱۰] آمده است.

۱-۳- نحوه تعریف پروب‌ها

در طبقه‌بندی کننده پیشنهادی، پروب‌ها آرایه‌هایی از ابرصفحه‌های جدا کننده کلاس‌ها هستند که در ابتدا کاملاً به صورت تصادفی ایجاد می‌شوند. به عبارت دیگر، هر

تجمیعی^{۱۶} بتوان آن را برای مواجهه با مسائل چند هدفه نیز به کار بست. توضیحات تکمیلی در ادامه این بخش آمده است.

۲-۲- روش بهینه سازی چند هدفه نیروی مرکزی

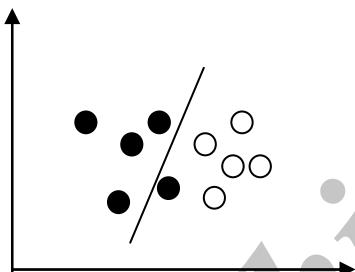
الگوریتم CFO، یک الگوریتم بهینه‌سازی هوش جمعی است که توسط ریچارد فورماتو در سال ۲۰۰۷ معرفی شد. این روش برای بهینه سازی توابع تک هدفه و بر مبنای نیروی گرانش بین پروب‌ها (عوامل جستجو) معرفی شده است [۷]. با توجه به اینکه هدف اصلی در این مقاله، بهره گیری از روش CFO برای طبقه‌بندی کننده‌های چند هدفه است، ابتدا لازم است این روش به گونه‌بهینه سازی چند هدفه ارتقا پیدا کند. یکی از روش‌های ارتقای الگوریتم‌های بهینه سازی تک هدفه به چند هدفه، استفاده از تابع تجمیعی است. در این روش همه توابعی که نیاز به بهینه سازی آنهاست در اوزانی (که مجموع آنها به عنوان یک تابع) ضرب می‌شوند و ترکیب خطی آنها به عنوان یک تابع جدید، که همان تابع تجمیعی است، تعریف می‌شود. سپس همین تابع روش بهینه سازی انتخاب شده برای بهینه سازی تابع تک هدفه تجمیعی به کار گرفته می‌شود. بدینه است مثلاً برای مینیمم کردن تابع تجمیعی لازم است کلیه مؤلفه‌های سازنده آن مینیمم شوند.

برای توضیح بیشتر فرض کنید هدف مینیمم کردن $f_i(x)$ ، $i = 1, K, M$ باشد. در این صورت، تابع تجمیعی به صورت زیر تعریف می‌شود:

$$F_a(X) = \sum_{i=1}^K a_i f_i(X) \quad (3)$$

که در آن a_i ها ضرایب غیر منفی f_i ها بوده، وزن هر یک از توابع هدف را در تابع تجمیعی $(F_a(X))$ نشان می‌دهند. همان طور که قبل اشاره شد $\sum_{i=1}^K a_i = 1$. این ضرایب می‌توانند در طول فرایند بهینه سازی، ثابت و یا متغیر باشند. اگر ضرایب ثابت فرض شوند، روش تجمیع توابع، «تجمیع وزن‌دار معمولی» (CWA^{۱۷}) نامیده می‌شود و در هر بار اجرای الگوریتم بهینه سازی تنها یک نقطه از

را دارد، ولی به علت ورود الگوهایی از کلاس‌های دیگر به منطقه کلاس مذکور، قابلیت اطمینان تصمیم اتخاذ شده کاهش می‌یابد. برای توضیح بیشتر شکل (۲) را در نظر بگیرید. در این شکل دو کلاس متفاوت که نمونه‌های آنها در فضای ویژگی دو بعدی 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 80% است. این در حالی است که قابلیت اطمینان کلاس سیاه 100% است. بر عکس اگرچه نرخ تشخیص صحیح گلوله‌های سفید به وسیله $d(x)$ 100% است، اما میزان اطمینان به تصمیم این طبقه‌بندی کننده در خصوص تعلق یک الگو به کلاس سفید $56\% / 83\%$ است.



شکل (۱): نرخ تشخیص صحیح کلاس سفید 100% و قابلیت اطمینان آن 83% و نرخ تشخیص صحیح کلاس سیاه 80% و قابلیت اطمینان آن 100% است

میزان قابلیت اطمینان هر کلاس را به صورت زیر تعریف می‌کنیم:

$$R_i = \frac{T_i}{T} \quad (6)$$

که در آن T_i تعداد کل نقاط آموزشی کلاس i 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 است.

یکی از توابع برآزنده‌گی مناسبی که می‌توان برای رسیدن به بیشترین قابلیت اطمینان در طراحی طبقه‌بندی کننده

پربوب به شکل $P = [W_1, W_2, K, W_i, K, W_H]'$ تعریف می‌شود که در آن $W_i = (w_{i1}, w_{i2}, K, w_{in}, w_{in+1})$ بردار اوزان i ابرصفحه در فضای ویژگی n بعدی و H تعداد ابرصفحه‌های است. پس هر سطر در یک پربوب، در بردارانده ضرایب یک ابرصفحه است و تعداد سطرها بیانگر تعداد ابرصفحه‌های است. با توجه به اینکه یکی از اهداف مورد نظر در طراحی طبقه‌بندی کننده پیشنهادی، یافتن تعداد بهینه ابرصفحه‌های است، باید توجه داشت که تعداد سطرها (و در نتیجه تعداد ابرصفحه‌ها) متغیر فرض شده‌اند. توضیحات تکمیلی در خصوص نحوه اضافه شدن و یا کم شدن تعداد سطرها در ادامه همین بخش خواهد آمد.

۲-۳- تعریف توابع هدف

در طبقه‌بندی کننده جدید لازم است هر یک از شاخص‌های مورد نظر به صورت توابع برآزنده‌گی مناسبی معرفی شوند تا هنگام پردازش، پربوب‌ها به سمت بهترین مقادیر این توابع گرایش پیدا کنند.

الف) نرخ تشخیص صحیح

تابع برآزنده‌گی که برای بهینه سازی نرخ تشخیص صحیح معرفی می‌شود، به شکل زیر است:

$$fit_1(P_i) = \frac{T - Miss(P_i)}{T} \quad (5)$$

در رابطه فوق P_i نشان‌دهنده آمین پربوب، $Miss(P_i)$ تعداد نقاط آموزشی است که توسط P_i به اشتباه طبقه‌بندی شده‌است، T تعداد کل نقاط آموزش و $fit_1(P_i)$ مقدار تابع برآزنده‌گی i برای دستیابی به نرخ تشخیص صحیح ماکریم است.

ب) قابلیت اطمینان

«قابلیت اطمینان» شاخص مهم دیگری در پردازش الگو است به نوعی میزان اعتبار تصمیم نهایی طبقه‌بندی کننده در مواجهه با یک الگو را مشخص می‌کند. شایان ذکر است که بسیار اتفاق می‌افتد که یک طبقه‌بندی کننده توانایی تشخیص صحیح همه الگوهای آموزشی یک کلاس خاص

طراحی طبقه بندی کننده های چند هدفه با استفاده از روش CFO

اوزان α امین ابرصفحه است. پس هر سطر در یک پروب، در بردارنده ضرایب یک ابرصفحه است و تعداد سطرها بیانگر تعداد ابرصفحه هاست. باید دانست برای دستیابی به بهترین تعداد ابرصفحه ها تعداد سطرها متغیر فرض شده اند. به عبارت بهتر، پروب ها دارای فرم هایی متغیر از $P = [W_1, W_2, K, W_{H_{\min}}]'$ هستند؛
به طوری که $H_{\min} = \log_2^M$ حداقل تعداد ابرصفحه ها (برای M کلاس مجزا) است و H_{\max} حداقل تعداد ابرصفحه ها است و به صورت پیش فرض انتخاب می شود.
به این ترتیب، با توابع برآوردگی که در روابط (۵) و (۷) معرفی شدند، می توان بهترین تعداد ابرصفحه ها را برای پیشگیری از مسئله «فوق-آموزش» و «فوق-برازش» تخمین زد. در صورتی که در هنگام تخمین ابرصفحه ها، انجام عملیات همزمان روی پروب هایی با تعداد سطرهای متفاوت ضرورت یابد، ابعاد پروب های با تعداد سطر کمتر را با افزودن تعداد مناسب سطرهای صفر با پروب های دیگر هم بعد می کنیم.

۴- نتایج عملی

در این فصل به گزارش نتایج به دست آمده از حل سه مسئله تشخیص الگو به وسیله طبقه بندی کننده پیشنهادی خود و مقایسه آنها با سایر طبقه بندی کننده های مشابه می پردازیم.

دو مسئله متداول در تشخیص الگو به همراه یک زمینه خاص کاربردی، مسایل برگزیده در این تحقیق هستند. دو مسئله متداول عبارتند از: طبقه بندی داده های گل های زنبق^{۱۹} و طبقه بندی داده های انواع مایعات شیمیایی^{۲۰} و مسئله کاربردی خاص عبارت است از: «تشخیص خودکار اهداف رادار»^{۲۱} که ذیلا در مورد هریک توضیح می دهیم.

داده های گل های زنبق: داده های گل های زنبق شامل پنجاه اندازه گیری از چهار ویژگی سه نوع گل زنبق به نام های *Versicolor* و *Setosa* و *Vergenica* است[۱۱]. این ویژگی ها عبارتند از: طول کاسبرگ، عرض کاسبرگ، طول گلبرگ و عرض گلبرگ. بنابراین، در این مسئله سه کلاس موجود است و هر کلاس دارای پنجاه الگو با بردارهای ویژگی چهار بعدی است.

پیشنهادی یعنی MOCFO-Classifier تعریف کرد، به صورت حاصلضرب قابلیت های اطمینان به دست آمده برای هر کلاس است:

$$fit_2(P_i) = \prod_{j=1}^M R_j \quad (7)$$

در این رابطه P_i نشان دهنده α امین پروب، R_j قابلیت اطمینان کلاس j است که به وسیله پروب i به دست آمده است، M تعداد کل کلاس ها و (P_i) مقدار تابع برآزندگی i بر اساس ملاک قابلیت اطمینان است.

ج) تعداد ابرصفحه ها

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 با سازماندهی پیچیده به منظور به حداقل رساندن خطای آموزش، در حالی که خطای آزمایش ممکن است مقدار در خور توجهی باشد. این مسئله معمولا ناشی از یک وسواس غیر منطقی در طبقه بندی داده های آموزشی است؛ به گونه ای که برای به حداقل رساندن خطای آموزش طبقه بندی کننده، از توابع تصمیم بیش از اندازه و با جایابی هایی بسیار نزدیک به هم استفاده می شود. واضح است که سازماندهی توابع تصمیم با تعداد زیاد و با موقعیت هایی که نواحی کدگذاری شده به وسیله آنها مناطق کوچک و گاه بسیار محدودی از فضای ویژگی را شامل می شود، نه تنها هیچ تضمینی را در خصوص کاهش «خطای آزمایش» طبقه بندی کننده در بر ندارد، بلکه ممکن است خود، به افزایش آن منجر شود.

آنچه مسلم است، این است که یکی از عوامل مؤثر در بروز مسئله «فوق-آموزش» استفاده بی رویه از تعداد زیاد ابرصفحه ها در طبقه بندی داده هاست. در طراحی طبقه بندی کننده پیشنهادی، «تعداد ابرصفحه ها» متغیر فرض شده اند. همان طور که در بخش (۱-۳) اشاره شد، پروب ها در طبقه بندی کننده پیشنهادی به شکل کلی $P = [W_1, W_2, K, W_i, K, W_H]'$ تعریف می شوند که در آن $(W_i = (w_{i1}, w_{i2}, K, w_{in}, w_{in+1})$ بردار

(اهداف مرجع همان‌هایی هستند که در [۲] و [۳] استفاده شده‌اند). پس از نمونه برداری از سیگنال شبیه سازی شده و انجام یک سری عملیات پیش پردازش اقدام به اعمال تبدیل فوریه سریع^{۲۹} 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 نمونه برداری شده در حوزه زمان هستند.

۱-۴ نتایج طبقه‌بندی داده‌های مرجع

این بخش شامل نتایج طبقه‌بندی داده‌های گل‌های زنبق، مایعات شیمیایی 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 روش پیشنهادی؛ یعنی «طبقه‌بندی کننده چند هدفه نیروی مرکزی» (MOCFO-) و «طبقه‌بندی کننده هوشمند گروه ذرات با وزن اینرسی» (IPS1-classifier) (classifier) نیز گزارش خواهد شد. طبقه‌بندی کننده‌های ارائه شده در تحقیقات قبل عبارتند از: «طبقه‌بندی کننده گروه ذرات» (PS-classifier) [۱]، «طبقه‌بندی کننده هوشمند گروه ذرات با وزن اینرسی» (IPS1-classifier) [۲] و «طبقه‌بندی کننده هوشمند گروه ذرات با عامل محدود کننده» (IPS2-classifier) [۳]. کلیه شبیه سازی‌ها و آزمایش‌های انجام گرفته به وسیله رایانه با واحد پردازش مرکزی IV 1600 Pentium و در محیط نرم افزار MATLAB 7.0 انجام گرفته‌اند. جمعیت تصادفی اولیه برای همه طبقه‌بندی کننده‌های فوق الذکر ۲۰ در نظر گرفته شده است. سایر ویژگی‌های طبقه‌بندی کننده‌ها دقیقاً همان‌هایی هستند که در تحقیقات یاد شده گزارش شده‌اند. داده‌های آموزشی در کلیه شبیه سازی‌ها 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 مایعات شیمیایی: این مجموعه متشکل از آنالیز شیمیایی عناصر رشد داده شده مایعات شیمیایی یکسان در شرایط مساوی است [۱۲]. بردارهای ویژگی دارای ۱۳ مؤلفه‌الکل، اسید مالیک (C4H6O5)، اش^{۲۲}، میزان الکالین بودن اش، منیزیم، فنل^{۲۳} مجموع، فلامانوئیدها^{۲۴}، فنل‌های غیر فلامانوئیدی، پرونوتونکیانین^{۲۵}، شدت رنگ، مشخصه ظاهری، میزان OD280/OD315 مایعات شیمیایی رقیق شده و پرولین^{۲۶} 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^{۲۷}، فرکانس‌های تشادید اهداف، تغییرات قطبیش^{۲۸} سیگنال الکترومغناطیسی بازگشتی از هدف و مدولاسیون قسمت‌های چرخان اهداف بر روی سیگنال ارسالی رادار اشاره کرد که به ترتیب در [۱۳]، [۱۴]، [۱۵] و [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 شبیه سازی سیگنال‌های بازگشتی از قسمت‌های چرخان هواپیما در [۱۷] پیشنهاد شده است. این مدل، تصوری با استفاده از ویژگیهای توبولوژیک 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 را در زاویه^{۲۰} دید. شبیه سازی می‌شوند

طراحی طبقه بندی کننده های چند هدفه با استفاده از روش CFO

بر دارند:

طبقه بندی کننده پیشنهادی (MOCFO-classifier) عمل طبقه بندی را با تعداد ابر صفحه های کمتری انجام داده است. این در حالی است که متوسط نرخ تشخیص صحیح برای نقاط آزمایشی و متوسط قابلیت اطمینان با این تعداد ابر صفحه از همه موارد مشابه در سایر طبقه بندی کننده ها در این جداول بهتر است. این مسئله شاهدی بر این واقعیت است که ابر صفحه های محاسبه شده به وسیله سایر طبقه بندی کننده ها، ابر صفحه های بهینه نبوده از پاسخ های غیر چیره شده به شمار نمی آیند.

در اغلب مقادیر گزارش شده در این جداول تفاوت فاحشی بین نرخ تشخیص نقاط آموزشی و آزمایشی در طبقه بندی کننده های قبلی وجود دارد (از ۵ تا ۱۵ درصد). این مسئله نشأت گرفته از گزینش تعداد ابر صفحه های زیاد برای طبقه بندی داده های آموزشی است که در واقع همان پدیده «فوق - آموزش» یا «فوق - برآزش» است. این در حالی است که تفاوت بین نرخ تشخیص نقاط آموزشی و آزمایشی در طبقه بندی کننده پیشنهادی (MOCFO-classifier) مقدار ناچیزی در حدود ۲/۴٪ است. به عبارت بهتر، مشکلات «فوق - آموزش» و «فوق - برآزش» در طبقه بندی کننده «چند منظوره گروه ذرات» به چشم نمی خورد و این طبقه بندی کننده می تواند مقدار بهینه تعداد ابر صفحه ها را نیز تخمین بزند.

آنچه در این جداول بیش از سایر موارد جلب توجه می کند بهبود قابل توجهی است که در شاخص «قابلیت اطمینان» برای طبقه بندی کننده پیشنهادی، نسبت به سایر طبقه بندی کننده ها رخ داده است. علت اصلی این بهبود آن است که در طبقه بندی کننده های IPS1-classifier و IPS2-classifier، تنها ملاکی که برای تخمین ابر صفحه ها در نظر گرفته شده، نرخ تشخیص صحیح داده ها در مرحله آموزش است. به عبارت دیگر، در این طبقه بندی کننده ها تنها یکتابع برآزندگی، آن هم برای به حداقل رساندن تعداد نقاط آموزشی که به اشتباه طبقه بندی شده اند، تعریف

داده های گل های زنق و داده های مایعات شیمیایی را برای ۳۰ داده آموزشی (۱۰ نمونه از هر کلاس که به طور تصادفی انتخاب شده اند) در بر دارد. این جداول شاخص های «نرخ تشخیص صحیح» و «قابلیت اطمینان» به دست آمده از سه نوع طبقه بندی کننده مبتنی بر روش های هوش جمعی گزارش شده را در کنار نتایج حاصل از طبقه بندی کننده MOCFO-classifier نشان می دهند. این مقادیر هم برای داده های آموزشی و هم برای داده های آزمایشی گزارش شده اند. تعداد ابر صفحه ها در طبقه بندی کننده پیشنهادی ۳ و در سایر طبقه بندی کننده ها 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 سه ابر صفحه برای طبقه بندی کننده پیشنهادی به وسیله خود طبقه بندی کننده به دست آمده و در واقع، می توان گفت این تعداد به همراه سایر نتایج مربوط به این طبقه بندی کننده در واقع مولفه های تشکیل دهنده یکی از نقاط «جبهه پرتو» است.

نقاط آموزش و آزمایش کاملا به صورت تصادفی و مشابه با مراجع [۱] و [۲] انتخاب شده اند تا مقایسه صورت گرفته معنادار باشند. شایان ذکر است افزایش یا کاهش تعدد الگوهای آموزشی تنها در مکان و معادلات ابر صفحه های محاسبه شده مؤثر است و بر روی نحوه تعریف پروب ها و توابع برآزندگی بیتاثیر است. نحوه سازماندهی ابر صفحه ها نیز با یک طرح اولیه و تعیین وظیفه تقسیم بندی فضای ویژگی به مناطق مطلوب انجام گرفته است. علت اصلی مقایسه روش پیشنهادی با سه روش طبقه بندی کننده گروه ذرات آن است که توانایی روش بهینه سازی نیروی مرکزی نسبت به روش های هوش جمعی سنجیده شود؛ ضمن آنکه تعداد ابر صفحه های در نظر گرفته شده برای طبقه بندی کننده های گروه ذرات PS-IPS2-classifier، IPS1-classifier، IPS2-classifier، IPS1-classifier صورت سعی و خطا و با استفاده از مراجع [۱]، [۲] و [۱۸] انجام گرفته است.

مقادیر جداول (۱) و (۲) معانی در خور توجهی را در

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.

شده و هیچ تلاشی برای ساماندهی ابرصفحه‌ها در جهت افزایش 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

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

	MOCFO-Classifier		IPS1-classifier		IPS2-classifier		PS-classifier	
	H=۲		H=۵		H=۵		H=۵	
	نقاط آموزش	نقاط آزمایش	نقاط آموزش	نقاط آزمایش	نقاط آموزش	نقاط آزمایش	نقاط آموزش	نقاط آزمایش
متوسط قابلیت اطمینان(%)	۹۴/۲	۸۷/۵	۸۳/۳	۷۷/۸	۸۴/۱	۸۰/۲	۷۳/۹	۶۸/۴
متوسط نرخ تشخیص(%)	۹۵/۵	۹۵/۰	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 چند هدفه پیشنهادی (MOCFO-classifier) برای داده‌های مایعات شیمیایی، به ازای ۳۰ نقطه آموزش.

	MOCFO-classifier		IPS1-classifier		IPS2-classifier		PS-classifier	
	H=۳		H=۵		H=۵		H=۷	
	نقاط آموزش	نقاط آزمایش	نقاط آموزش	نقاط آزمایش	نقاط آموزش	نقاط آزمایش	نقاط آموزش	نقاط آزمایش
متوسط قابلیت اطمینان(%)	۹۰/۰	۸۴/۲	۷۸/۳	۷۲/۹	۸۱/۳	۷۶/۶	۷۵/۴	۶۳/۵
متوسط نرخ تشخیص(%)	۹۵/۱	۹۲/۷	۹۶/۲	۸۳/۴	۹۵/۵	۸۹/۳	۸۷/۸	۷۲/۳

نقاط آزمایشی نیز برابر با همین مقدار است. تعداد ابرصفحه‌ها برای طبقه‌بندی کننده پیشنهادی، 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 محدود کننده» برابر با ۸ و برای «طبقه‌بندی کننده گروه ذرات» برابر با ۱۰ انتخاب شده است.

در مسئله طبقه‌بندی اهداف رادار، سیگنال‌های بازگشته متعددی از اهداف معرفی شده در [۲] و [۳] را با افزودن توان‌های مختلفی از نویز سفید گوسی شبیه سازی و به عنوان نمونه‌های آموزشی استفاده کردایم. نمونه‌های آزمایشی نیز به روش مشابه و به تعداد لازم شبیه سازی 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

طراحی طبقه بندی کننده های چند هدفه با استفاده از روش CFO

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

	نسبت های سیگنال به نویز (dB)					
	-۱۰	-۵	۰	۵	۱۰	۱۵
MOCFO-classifier	۱۵/۴	۲۱/۷	۵۰/۰	۶۱/۹	۷۷/۱	۹۰/۸
IPS1-classifier	۱۰/۱	۱۹/۱	۵۳/۲	۶۷/۸	۸۰/۱	۹۲/۳
IPS2-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 محاسبه شده در مرحله آموزش (%) در طبقه بندی اهداف رادار برای ۱۰۰ داده آموزشی در نسبت های مختلف سیگنال به نویز.

	نسبت های سیگنال به نویز (dB)					
	-۱۰	-۵	۰	۵	۱۰	۱۵
MOCFO-classifier	۱۰/۷	۲۳/۰	۴۲/۱	۷۰/۱	۷۸/۱	۸۲/۹
IPS1-classifier	۹/۱	۱۷/۴	۲۷/۸	۵۸/۵	۶۰/۵	۷۵/۲
IPS2-classifier	۸/۲	۱۸/۴	۳۳/۳	۶۴/۷	۶۷/۵	۷۳/۳
PS-classifier	۱۰/۱	۱۲/۱	۲۱/۲	۴۲/۱	۵۰/۳	۶۶/۶

جدول (۵): متوسط نرخ تشخیص صحیح نقاط آزمایش (%) در طبقه بندی اهداف رادار برای ۱۰۰ داده آزمایشی در نسبت های مختلف سیگنال به نویز.

	نسبت های سیگنال به نویز (dB)					
	-۱۰	-۵	۰	۵	۱۰	۱۵
MOCFO-classifier	۱۲/۳	۱۵/۱	۳۵/۸	۵۶/۹	۷۰/۸	۸۸/۶
IPS1-classifier	۱۱/۴	۱۳/۱	۲۵/۴	۴۴/۷	۶۳/۸	۸۰/۴
IPS2-classifier	۱۰/۱	۱۴/۳	۲۷/۴	۴۷/۶	۶۱/۵	۷۸/۳
PS-classifier	۸/۲	۱۳/۹	۲۰/۷	۴۱/۶	۵۷/۳	۷۴/۶

جدول (۶): متوسط قابلیت اطمینان محاسبه شده در مرحله آزمایش (%) در طبقه بندی اهداف رادار برای ۱۰۰ داده آزمایشی در نسبت های مختلف سیگنال به نویز.

	نسبت های سیگنال به نویز (dB)					
	-۱۰	-۵	۰	۵	۱۰	۱۵
MOCFO-classifier	۹/۸	۱۲/۶	۲۲/۱	۵۱/۷	۶۴/۸	۷۲/۴
IPS1-classifier	۷/۵	۹/۱	۱۵/۴	۴۱/۷	۵۱/۰	۶۲/۴
IPS2-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

همان طور که از نتایج درج شده در جدول (۳) مشاهده می شود، متوسط نرخ تشخیص داده های آموزشی برای طبقه بندی کننده پیشنهادی (MOCFO-classifier) در برخی موارد کمتر از طبقه بندی کننده های IPS1-classifier

نتایج مبسوطی که به ترتیب در جداول (۳) تا (۶) آمده است، صحت ادعاهای منتج از آزمایش های قبل را در مواجهه با یک مسئله عملی بازشناسی الگو با بردارهای ویژگی ۱۲۸ عضوی نشان می دهد.

الگو در منطقه خاصی که ابرصفحه‌ها تعیین می‌کنند، وابسته است. پس سرعت پردازش در مرحله آزمایش برای هر چهار روش بسیار بالاست.

۵- نتیجه‌گیری و پیشنهادها

در این تحقیق با استفاده از روش «بهینه سازی نیروی مرکزی» الگوریتمی برای بهینه سازی چند هدفه از طریق تعریف تابع تجمعی بیان شد. سپس، روش بهینه سازی چند هدفه پیشنهادی به عنوان ابزاری کارآمد برای طراحی طبقه‌بندی کننده‌های چند هدفه معروفی و به طبقه‌بندی کننده چند هدفه MOCFO-classifier منجر گشت. این طبقه‌بندی کننده، 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 پیشنهاد شده نه تنها فاقد معایبی نظیر «فوق-آموزش» و «فوق-برازش» است، بلکه میزان اطمینان به تصمیمات اتخاذ شده در آن به میزان قابل توجهی نسبت به سایر موارد مشابه، افزایش یافته است.

همچنین، طبقه‌بندی کننده چند منظوره 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» مهتر از «قابلیت اطمینان» باشد (و یا بالعکس). البته، باید اذعان کرد که در قبال توانایی‌های افزوده شده به طبقه‌بندی کننده پیشنهاد شده «هزینه محاسباتی» آن نیز افزایش یافته است که دلیل عده آن بهینه سازی چند تابع برآzendگی به صورت همزمان است، اما با توجه به اینکه هزینه‌های محاسباتی در مرحله آموزش لحاظ می‌شود، می‌توان گفت پس از تحمل این محاسبات و تخمین ابرصفحه‌ها در مرحله آزمایش طبقه‌بندی کننده پیشنهاد شده نسبت به انواع مشابه خود، هیچ گونه بار اضافه محاسباتی را تحمل نمی‌کند. در واقع، در مرحله آزمایش کافی است معلوم شود الگوی ناشناس به کدام یک از نواحی کد شده به وسیله ابرصفحه‌های محاسبه شده تعلق دارد.

و IPS2-classifier است، ولی باید به یاد داشت که طبقه‌بندی داده‌های آموزشی به تنهایی نمی‌تواند گویای عملکرد بهتر یک روش نسبت به سایر روش‌ها باشد، زیرا ممکن است در مرحله آموزش باه کارگیری تعداد زیادی از توابع تصمیم (در اینجا ابرصفحه‌ها) مقدار خطأ کم باشد، اما طبقه‌بندی کننده دچار مسئله "فوق-آموزش" شده باشد. نتایج مقایسه‌ای به دست آمده از طبقه‌بندی داده‌های آزمایشی صحت این موضوع را اثبات می‌کند (جدول ۵). نتایج مندرج در جدول (۵) حاکی از توانایی بیشتر طبقه‌بندی کننده‌های مشابه خود است. 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. نکته مهم دیگر اضافه شدن شاخص «قابلیت اطمینان» به عنوان یک تابع برآzendگی دیگر در طبقه‌بندی کننده پیشنهادی است و همان طور که از جداول ۴ و ۶ قابل استنباط است، در هر دو مرحله آموزش و آزمایش طبقه‌بندی کننده MOCFO-classifier از «قابلیت اطمینان» بیشتری برخوردار است.

۲-۴ مقایسه زمان لازم برای همگرایی

طبق مشاهدات و اندازه گیری‌های صورت گرفته، متوسط زمان همگرایی برای روش ارائه شده از روش PS-classifier بیشتر و از طبقه‌بندی کننده‌های IPS2-classifier و IPS1-classifier بهتر بود. این نتیجه از دو جهت قابل تأمل است: نخست اینکه رتبه دوم همگرایی در این روش از آن جهت حائز اهمیت است که در روش پیشنهادی به جای یک تابع برآzendگی، در واقع دو تابع برآzendگی (یکی نرخ تشخیص صحیح و دیگری قابلیت اطمینان) به طور همزمان ارزیابی و بهینه سازی می‌شوند. با این حال، روش ارائه شده با نیاز به ابرصفحه‌های کمتر، توانسته است رتبه دوم همگرایی را کسب کند.

از سوی دیگر، باید توجه داشت که استفاده از این طبقه‌بندی کننده‌ها عمدها به صورت offline است و پس از مرحله آموزش و یافتن ابرصفحه‌ها، تصمیم در مورد تعلق و یا عدم تعلق یک الگوی ناشناس تنها به قرار گرفتن آن

طراحی طبقه بندی کننده های چند هدفه با استفاده از روش CFO

- 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, June 2004.
- [7] R.A. Formato, "Central force optimization: a new metaheuristic with application in applied electromagnetics", Progress in Electromagnetics Research, PIER, 77, pp. 425-491, 2007.
- [8] Y. Jin, M. Olhoffer, B. Sendhoff, "Dynamic weighted aggregation for evolutionary multiobjective optimization: why does it work and how?", In Proc. GECCO 2001.
- [9] R. C. Eberhart, Y. Shi, "Tracking and optimizing dynamic systems with particle swarms," Proc. of the 2001 Congress on Evolutionary Computation,2001.
- [10] J.T. Tou and R.C. Gonzalez, "Pattern Recognition Principles," Addison-Wesley, Reading MA, 1974.
- [11] R. A. Fisher, "The use of multiple measurements in taxonomic problems," Ann. Eugen, Vol. 7, No.3, pp. 179-188, 1936.
- [12] University of California, Irvine, via anonymous ftp [ftp.ics.uci.edu/pub/machine-learning-databases](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, April 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," Proc. Of the IEEE International Radar Conference, 1990.

نکته مهم دیگری که ذکر آن لازم است، پیچیدگی سیستماتیک کمتری است که طبقه بندی کننده پیشنهاد شده نسبت به سایر موارد مشابه (طبقه بندی کننده های هوشمند گروه ذرات) دارد. باید به یاد آورد که طبقه بندی کننده های هوشمند گروه ذرات با وزن اینرسی و با فاکتور محدود کننده هر دو دارای کنترل کننده فازی اضافه ای هستند که نقش کنترل پارامترهای مؤثر در روش های بهینه سازی را در هر بار تکرار حلقه جستجو بر عهده دارند. این کنترل کننده های فازی اگرچه به جستجوی مؤثر برای یافتن ابرصفحه ها کمک می کنند و تعداد تکرار حلقه اصلی را به نحو قابل ملاحظه ای کاهش می دهند، اما به پیچیدگی سیستماتیک طبقه بندی کننده های هوشمند گروه ذرات نیز منجر می شوند. طبقه بندی کننده پیشنهاد شده در این تحقیق قادر هرگونه کنترل کننده اضافی است و از این رو، دارای سادگی بیشتری نسبت به انواع مشابه خود است.

بررسی تئوریک عملکرد طبقه بندی کننده پیشنهاد شده برای دستیابی به ملاکی مقایسه ای با «طبقه بندی کننده بیز» (به عنوان یک طبقه بندی کننده بهینه)، به همراه مطالعه پیرامون نحوه تاثیر گذاری پارامترهای الگوریتم بهینه سازی نیز مرکزی بر عملکرد طبقه بندی کننده چند هدفه پیشنهادی، می توانند موضوع های در خور توجهی برای تحقیقات بعدی باشند.

مراجع

- [1] S.H. Zahiri and S.A. Seyedin, "Particle swarm classifiers," Proc. of the 13th Iranian Conf. of Elec. Eng., ICEE 2005, pp. 454-458,
- [2] S.H. Zahiri and S. A. Seyedin, "Intelligent particle swarm classifier," Iranian Journal of Electrical and Computer Engineering, Vol.4, No. 5, pp. 63-70, Winter-Spring 2005.
- [3] S.H. Zahiri and S.A. Syedin, "Swarm intelligence based classifiers," Accepted for publication by the Journal of the Franklin Institute, Oct. 2005.
- [4] C.A.C Coello and M.S. Lechuga, "MOPSO: a proposal for multiple objective particle swarm optimization," Proceedings of the 2002 Congress on Evolutionary Computation, ,CEC '02, Vol. 2, No.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

[] سید‌حمید ظهیری، طبقه‌بندی کننده چند منظوره گروه ذرات، نشریه مهندسی برق و مهندسی کامپیوتر ایران، سال ۴، شماره ۲، پاییز و زمستان ۱۳۸۵، صص. ۹۸-۹۱.

زیرنویس

-
- ^۱Decision functions
 - ^۲K-nearest neighbor
 - ^۳Fuzzy classifiers
 - ^۴Particle swarm classifier
 - ^۵Score of recognition
 - ^۶Reliability
 - ^۷Hyperplane
 - ^۸Over fitting
 - ^۹Over learning
 - ^{۱۰}Multi-objective Central Force Optimization
 - ^{۱۱}Conflict
 - ^{۱۲}Domination
 - ^{۱۳}Pareto-optimality
 - ^{۱۴}Evolutionary algorithms
 - ^{۱۵}Ant colony optimization
 - ^{۱۶}Aggregation function
 - ^{۱۷}Conventional Weighted Aggregation
 - ^{۱۸}Dynamic Weighted Aggregation
 - ^{۱۹}Iris data
 - ^{۲۰}Wine data
 - ^{۲۱}Automatic target recognition
 - ^{۲۲}Ash
 - ^{۲۳}Phenol
 - ^{۲۴}Flamanoids
 - ^{۲۵}Proanthocyanin
 - ^{۲۶}Proline
 - ^{۲۷}Radar cross section
 - ^{۲۸}Polarization
 - ^{۲۹}Fast Fourier transform (FFT)