

طراحی طبقه بندی کننده‌های چند هدفه با استفاده از روش CFO

سعیده شیخ پور^۱، سیدحمید 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 طراحی 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 کننده‌هایی معرفی 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 ابر صفحه‌ها 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 «جهت پرتو» مجموعه‌ای از انتخاب‌های متنوع و بهینه از ابر صفحه‌های جدا کننده کلاس‌های مختلف را برای برپایی شرایط دلخواه کاربر در خصوص انتخاب شاخص‌های فوق‌الذکر، فراهم می‌آورد.

واژه های کلیدی: تشخیص الگو، روش هوشمند CFO، طبقه بندی کننده های چند هدفه.

۱- مقدمه

کننده‌های متنوعی برای استفاده در سیستم‌های بازشناسی الگو مطرح شده است که از میان آنها می‌توان به طبقه‌بندی کننده‌های بیض، k -نزدیکترین همسایه^۱، شبکه عصبی و فازی^۳ 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»^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

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 طبقه بندی کننده های چند هدفه با استفاده از روش CFO

پدیده «فوق-برازش»^۱ یا «فوق-آموزش»^۲ خوانده می شود و به عنوان یک پارامتر نامطلوب در طبقه بندی کننده ها به شمار می رود.

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

کاستی های فوق الذکر به همراه محدودیت پژوهش های انجام گرفته در موضوع مورد نظر از یک سو، و حضور روش های نوین هوش جمعی از سوی دیگر، انگیزه های قوی برای طراحی و معرفی نوع جدیدی از طبقه بندی کننده های هوش جمعی چند هدفه به شمار می روند.

اخیراً عضوی جدید از روش های هوش جمعی با نام «الگوریتم بهینه سازی نیروی مرکزی» (CFO) معرفی شده است که مکانیزم آن بر مبنای تاثیر نیروهای نیوتنی بر اجرامی است که در فضای جستجو به عنوان پاسخ های احتمالی مسئله پراکنده اند. 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 می شود. در مرحله بعد، با استفاده از روش بهینه سازی چند هدفه پیشنهادی، طبقه بندی کننده چند منظوره ای به نام «طبقه بندی کننده چند هدفه نیروی مرکزی» "MOCFO-classifier" پیشنهاد شده است که به طور همزمان به بهینه سازی سه پارامتر زیر می پردازد:

۱- تعداد نقاط آموزشی که توسط ابرصفحه های معرفی شده به وسیله هر «عامل» از «جمعیت» به اشتباه طبقه بندی می شود.

۲- تعداد ابرصفحه های 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- نزدیکترین همسایه است [۱]. در مرحله بعد با افزودن یک کنترل کننده فازی به طبقه بندی کننده مذکور نوع کارآمدتر آن به نام «طبقه بندی کننده هوشمند گروه ذرات» معرفی شد [۲]. نتایج عملی نشان داد که این طبقه بندی 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 بازشناسی بالاتری نیز به دست آمد. همه این تحقیقات گام های متوالی برای بهبود طبقه بندی کننده های نوظهور مبتنی بر روش های هوش جمعی به شمار می روند.

پژوهش های اشاره شده دارای نکات مشترکی به شرح زیر هستند:

- در همه تحقیقات فوق الذکر تنها ملاکی که مبنای ارزیابی عملکرد طبقه بندی کننده طراحی شده، «نرخ تشخیص صحیح»^۳ است. این در حالی است که شاخص های مهم دیگری نیز وجود دارند که می توانند در ارزیابی عملکرد یک طبقه بندی کننده به همان اندازه و حتی بیش از آن حائز اهمیت باشند. شاخص هایی مانند «قابلیت اطمینان»^۴ که میزان اعتبار تصمیم یک طبقه بندی کننده را تعیین می کند، مثال بارزی از این شاخص هاست. باید دانست که در بسیاری از موارد ممکن است «نرخ تشخیص» صحیح الگوهای یک کلاس در یک طبقه بندی کننده مقدار در خور توجهی باشد، اما «قابلیت اطمینان» آن طبقه بندی کننده در خصوص همان کلاس چندان زیاد نباشد. این حالت بیشتر در مواقعی رخ می دهد که نمونه هایی از کلاس های دیگر در ناحیه متعلق به کلاس مذکور حاضر می شوند. عکس این موضوع نیز صادق است؛ یعنی مواردی پیش می آیند که در آن «نرخ تشخیص» کم است، اما اعتبار یا «قابلیت اطمینان» به تصمیم اتخاذ شده زیاد است.

- تعداد ابرصفحه های لازم برای تقسیم بندی فضای ویژگی در همه تحقیقات یاد شده به عنوان یک پیش فرض و با سعی و خطا به دست آمده است. بی تردید با به کار گیری تعداد زیادی از ابرصفحه ها، الگوهای «آموزشی» با دقت بیشتری طبقه بندی می شوند، اما در غالب اوقات چنین دقتی در مواجهه با داده های آزمایشی به دست نمی آید. 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 مسأله «بهینه سازی چند هدفه» عبارت است از یافتن پاسخی برای x که $f(x)$ 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 خواهند آمد که بهینه ساز همه توابع هدف نبوده، بلکه ممکن است از دید تک تک آنها جواب‌های «نزدیک بهینه» تلقی شوند.

یک مفهوم مهم در روش‌های بهینه سازی چند منظوره «تسلط یا چیرگی»^{۱۲} 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 به تعریف «بهینگی پرتو»^{۱۳} منجر می‌شود. $x_i \in U$ (مجموعه مرجع همه پاسخ‌هاست) را «بهینه پرتو» گویند اگر 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 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 مسأله معروف طبقه بندی «داده‌های گل‌های زنبق» و «داده‌های مایعات شیمیایی» در کنار مسأله کاربردی و پیچیده طبقه‌بندی «اهداف رادار»، 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 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 مسأله انتخابی فوق‌الذکر 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 طبقه‌بندی 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.

۲-۱- 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 مسأله 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 طبقه بندی کننده های چند هدفه با استفاده از روش CFO

جبهه بهینه (همان جبهه پرتو) به دست می آید. در نوع دیگر، ضرایب به صورت دینامیکی در طی فرایند جستجو و بهینه سازی تغییر می کنند. به این روش «تجمیع وزندار دینامیکی» (DWA^{۱۸}) اطلاق می شود. نحوه تغییر ضرایب برای دو تابع هدف، هنگام اجرای الگوریتم از روابط زیر تبعیت می کند:

$$\begin{aligned} a_1(t) &= |\sin(2\pi \nu t)| \\ a_2(t) &= 1 - a_1(t) \end{aligned} \quad (۴)$$

که در آن، U فرکانس تغییرات ضرایب، و t تعداد تکرار را نشان می دهد.

با توجه به عملکرد مطلوب روش DWA نسبت به روش CWA [۹و۸]، 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 می کنیم.

۳- طبقه بندی کننده چند هدفه نیروی مرکزی

(MOCFO-classifier)

در این بخش با استفاده از ابزار جستجوی چند منظوره ای که در بخش قبل معرفی شد، به طراحی طبقه بندی کننده ای مبادرت می شود که ضمن تخمین ضرایب ابرصفحه های جدا کننده کلاس های مختلف قادر به بهینه سازی شاخص های مهم «نرخ تشخیص صحیح»، «قابلیت اطمینان» و «تعداد ابرصفحه های لازم» برای مرزبندی موثر کلاس های متفاوت در فضای ویژگی است. روش های مختلف استفاده از ابرصفحه ها برای جداسازی کلاس های مختلف در [۱۰] آمده است.

۳-۱- نحوه تعریف پروبها

در طبقه بندی کننده پیشنهادی، پروبها آرایه هایی از ابرصفحه های جدا کننده کلاسها هستند که در ابتدا کاملاً به صورت تصادفی ایجاد می شوند. به عبارت دیگر، هر

تجمیعی^{۱۶} بتوان آن را برای مواجهه با مسایل 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 بهینه سازی 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 طراحی طبقه بندی کننده های چند هدفه است، ابتدا لازم است این روش به گونه بهینه سازی چند هدفه ارتقا پیدا کند. یکی از روش های ارتقای الگوریتم های 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 واحد است) ضرب می شوند و ترکیب خطی آنها به عنوان یک تابع جدید، که همان تابع تجمیعی است، تعریف می شود. سپس همین تابع روش بهینه سازی انتخاب شده برای بهینه سازی تابع تک هدفه تجمیعی به کار گرفته می شود. بدیهی است مثلاً برای مینیم کردن تابع تجمیعی لازم است کلیه مؤلفه های سازنده آن مینیم شوند.


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

$$F_a(X) = \sum_{i=1}^K a_i f_i(X) \quad (۳)$$

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 می دهند. همان طور که قبلاً اشاره شد $\sum_{i=1}^K a_i = 1$. این

ضرایب می توانند در طول فرایند بهینه سازی، ثابت و یا متغیر باشند. اگر ضرایب ثابت فرض شوند، روش تجمیع توابع، «تجمیع وزندار معمولی» (CWA^{۱۷}) نامیده می شود 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 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 طبقه بندی کننده در خصوص تعلق یک الگو به کلاس سفید ۸۳٪ (۵۶) است.



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

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

$$R_i = \frac{T_i}{T} \quad (۶)$$

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 ابر صفحه 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 طراحی طبقه‌بندی کننده

پروپ به شکل $P = [W_1, W_2, K, W_i, K, W_H]'$ تعریف می‌شود که در آن ابرصفحه در فضای ویژگی n بعدی و H تعداد ابر صفحه‌هاست. پس هر سطر در یک پروپ، در بردارنده ضرایب یک ابرصفحه است و تعداد سطرها بیانگر تعداد ابرصفحه‌هاست. با توجه به اینکه یکی از اهداف مورد نظر در طراحی طبقه‌بندی کننده پیشنهادی، یافتن تعداد بهینه ابرصفحه‌هاست، 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.

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 هنگام پردازش، پروپ‌ها به سمت بهترین مقادیر این توابع گرایش پیدا کنند.

الف) نرخ تشخیص صحیح

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

$$fit_1(P_i) = \frac{T - Miss(P_i)}{T} \quad (۵)$$

در رابطه فوق P_i نشان‌دهنده نامین پروپ، $Miss(P_i)$ تعداد نقاط آموزشی است که توسط P_i به اشتباه طبقه‌بندی شده‌است، T تعداد کل نقاط آموزش و $fit_1(P_i)$ مقدار تابع برازندگی P_i برای دستیابی به نرخ تشخیص صحیح ماکزیمم است.

ب) قابلیت اطمینان

«قابلیت اطمینان» شاخص مهم دیگری در پردازش الگو است به نوعی میزان اعتبار تصمیم نهایی طبقه بندی 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 i امین ابرصفحه است. پس هر سطر در یک پروب، در بردارنده ضرایب یک ابر صفحه است و تعداد سطرها بیانگر تعداد ابرصفحه‌هاست. باید دانست برای دستیابی به بهترین تعداد ابر صفحه‌ها تعداد سطرها متغیر فرض شده‌اند. به عبارت بهتر، پروب‌ها دارای فرم‌هایی متغیر از $P = [W_1, W_2, K, W_{H_{\min}}]'$ تا $P = [W_1, W_2, K, W_{H_{\max}}]'$ هستند؛ به طوری که $H_{\min} = \log_2^M$ حداقل تعداد ابرصفحه‌ها (برای M کلاس مجزا) است و H_{\max} حداکثر تعداد ابرصفحه‌ها است و به صورت پیش فرض انتخاب می‌شود. به این ترتیب، با توابع برازندگی که در روابط (۵) و (۷) معرفی شدند، می‌توان بهترین تعداد ابرصفحه‌ها را برای پیشگیری از مسأله «فوق-آموزش» و «فوق-برازش» تخمین زد. در صورتی که در هنگام تخمین ابرصفحه‌ها، انجام عملیات همزمان روی پروب‌هایی با تعداد سطرها متفاوت ضرورت یابد، ابعاد پروب‌های با تعداد سطر کمتر را با افزودن تعداد مناسب سطرها صفر با پروب‌های دیگر هم بعد می‌کنیم.

۴- نتایج عملی

در این فصل به گزارش نتایج به دست آمده از حل سه مسأله 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 مسأله متداول عبارتند از: طبقه‌بندی داده‌های گل‌های زنبق^{۱۹} و طبقه‌بندی داده‌های انواع مایعات شیمیایی^{۲۰} و مسأله کاربردی خاص عبارت است از: «تشخیص خودکار اهداف رادار^{۲۱}» که ذیلاً در مورد هر یک توضیح می‌دهیم.

داده‌های گل‌های زنبق: داده‌های گل‌های زنبق شامل پنجاه اندازه گیری از چهار ویژگی سه نوع گل زنبق به نام‌های *Setosa*، *Versicolor* و *Vergenica* است [۱۱]. این ویژگی‌ها عبارتند از: طول کاسبرگ، عرض کاسبرگ، طول گلبرگ و عرض گلبرگ. بنابراین، در این مسأله سه کلاس موجود است و هرکلاس دارای پنجاه الگو با بردارهای ویژگی چهار بعدی است.

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

$$fit_2(P_i) = \prod_{j=1}^M R_j \quad (۷)$$

در این رابطه P_i نشان دهنده i امین پروب، R_j قابلیت اطمینان کلاس j ام است که به وسیله پروب P_i به دست آمده است، M تعداد کل کلاس‌ها و $fit_2(P_i)$ 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، مسأله «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 مسأله 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، به افزایش آن منجر شود.

آنچه مسلم است، این است که یکی از عوامل مؤثر در بروز مسأله «فوق-آموزش» استفاده بی رویه از تعداد زیاد ابر صفحه‌ها در طبقه بندی داده‌هاست. در طراحی طبقه‌بندی کننده پیشنهادی، «تعداد ابر صفحه‌ها» متغیر فرض شده‌اند. همان طور که در بخش (۳-۱) اشاره شد، پروب‌ها در طبقه‌بندی کننده پیشنهادی به شکل کلی $P = [W_1, W_2, K, W_i, K, W_H]'$ تعریف می‌شوند 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 نقطه ای 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.

۴-۱ نتایج طبقه‌بندی داده‌های مرجع

این بخش شامل نتایج طبقه‌بندی داده‌های گل‌های زنیق، 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-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 Pentium IV 1600 و در محیط نرم افزار MATLAB 7.0 انجام گرفته‌اند. جمعیت تصادفی اولیه برای همه طبقه‌بندی کننده‌های فوق‌الذکر ۲۰ در نظر گرفته شده‌است. 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 مؤلفه الکل، اسید مالیک (C4H6O5)، اش^{۲۲}، میزان الکالین بودن اش، منیزیم، فنل^{۲۳} مجموع، فلامانوئیدها^{۲۴}، فنل‌های غیر فلامانوئیدی، پروتوکیانین^{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 تشدید اهداف، تغییرات قطبش^{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، 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 را در زاویه دید ۲۰° 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 شاهدهی 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 مسأله 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-برازش» 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-برازش» 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 یک تابع برازندگی، آن هم برای به حداقل رساندن تعداد نقاط آموزشی که به اشتباه طبقه بندی شده اند، تعریف

داده های گل های زنیق 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 کاملاً به صورت تصادفی و مشابه با مراجع [۱] و [۲] انتخاب شده اند تا مقایسات 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 برازندگی بی تاثیر 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 روشهای هوش جمعی سنجیده شود؛ ضمن آنکه تعداد ابر صفحه های در نظر گرفته شده برای طبقه بندی کننده های گروه ذرات PS-classifier، IPS1-classifier و IPS2-classifier صرفاً به 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 شده‌است. این رویداد را نیز می‌توان به رخداد مسأله «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=۳		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 طبقه بندی کننده هوش جمعی در کنار طبقه‌بندی کننده چند منظوره 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 شده‌است. سایر طبقه‌بندی کننده‌ها قادر به تخمین تعداد ابرصفحه‌ها نیستند بنابراین، تعداد ابر صفحه‌ها 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 مسأله طبقه‌بندی اهداف رادار، سیگنال‌های بازگشتی 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 کرده‌ایم. 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 طبقه بندی 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	۱۳/۱	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	۸/۳	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 دهند.

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

۵- نتیجه گیری و پیشنهادها

در این تحقیق با استفاده از روش «بهینه سازی نیروی مرکزی» الگوریتمی برای بهینه سازی چند هدفه از طریق تعریف تابع تجمیعی بیان شد. سپس، روش بهینه سازی چند هدفه پیشنهادی به عنوان ابزاری کارآمد برای طراحی طبقه‌بندی کننده‌های چند هدفه معرفی 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» مهمتر 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 عمده آن بهینه سازی چند تابعی برازندگی 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 طبقه بندی داده‌های آموزشی به تنهایی نمی‌تواند گویای عملکرد بهتر یک روش نسبت به سایر روش‌ها باشد، زیرا ممکن است در مرحله آموزش با به کارگیری تعداد زیادی از توابع تصمیم (در این جا ابرصفحه‌ها) مقدار خطا کم باشد، اما طبقه‌بندی کننده دچار مسأله "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 کننده MOCFO-classifier نسبت به سایر 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 برازندگی دیگر در طبقه بندی 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.

۴-۲ 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 طبقه بندی کننده های IPS2-classifier و IPS1-classifier بهتر بود. این نتیجه از دو جهت قابل تامل است: نخست اینکه رتبه دوم همگرایی در این روش از آن جهت حایز اهمیت است که در روش پیشنهادی به جای یک تابع برازندگی، در واقع دو تابع برازندگی (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 کنندگان عمدتاً 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

- 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 methaheuristic with application in applied electromagnetics", Progress in Electromagnetics Research, PIER, 77, pp. 425-491, 2007.
- [8] Y. Jin, M. Olhopher, 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-Wesely, 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.
- [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 فاقد 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 بیض» (به عنوان یک طبقه بندی کننده بهینه)، به همراه مطالعه پیرامون نحوه تاثیر گذاری پارامترهای الگوریتم بهینه سازی نیروی مرکزی بر عملکرد طبقه بندی کننده چند هدفه پیشنهادی، می تواند 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 ntelligence 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، طبقه بندی کننده چند منظوره
گروه ذرات، نشریه مهندسی برق و مهندسی کامپیوتر ایران،
سال ۴، شماره ۲، پاییز وزمستان ۱۳۸۵، صص. ۹۱-۹۸.

زیرنویس

-
- ¹Decision functions
 - ²K-nearest neighbor
 - ³Fuzzy classifiers
 - ⁴Particle swarm classifier
 - ⁵Score of recognition
 - ⁶Reliability
 - ⁷Hyperplane
 - ⁸Over fitting
 - ⁹Over learning
 - ¹⁰ Multi-objective Central Force Optimization
 - ¹¹Conflict
 - ¹²Domination
 - ¹³Pareto-optimality
 - ¹⁴Evolutionary algorithms
 - ¹⁵Ant colony optimization
 - ¹⁶ Aggregation function
 - ¹⁷ Conventional Weighted Aggregation
 - ¹⁸ Dynamic Weighted Aggregation
 - ¹⁹ Iris data
 - ²⁰ Wine data
 - ²¹ Automatic target recognition
 - ²² Ash
 - ²³ Phenol
 - ²⁴ Flamanoids
 - ²⁵ Proanthocyanin
 - ²⁶ Proline
 - ²⁷ Radar cross section
 - ²⁸ Polarization
 - ²⁹ Fast Fourier transform (FFT)

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