

معرفی یک الگوریتم ترکیبی در هم‌تنیده برای آموزش نگاشت‌های ادراکی فازی

سید محمدرضا موسوی^۱، اکرم محسنی^۲، عبدالله امیرخانی^۳

^۱استاد دانشکده مهندسی برق دانشگاه علم و صنعت ایران، m_mosavi@iust.ac.ir

^۲دانشجوی کارشناسی ارشد، دانشگاه علم و صنعت ایران، amohseni@iust.ac.ir

^۳دانشجوی دکتری، دانشگاه علم و صنعت ایران، amirkhani@ieee.org

چکیده

نگاشت‌های ادراکی فازی (FCM) که از تکنیک‌های محاسبات نرم محسوب می‌شوند، با ترکیب منطق فازی و تئوری شبکه‌های عصبی، به عنوان ابزاری قدرتمند برای مدل‌سازی سیستم‌های پیچیده معرفی گشته‌اند. استفاده از الگوریتم‌های یادگیری مختلف برای غلبه بر ضعف‌های این مدل، یکی از حوزه‌های فعال علمی است. در این مقاله یک الگوریتم ترکیبی جدید مبتنی بر الگوریتم یادگیری هیبن غیرخطی (NHL) و الگوریتم ژنتیک کدحقیقی (RCGA) معرفی می‌شود که به صورت درهم‌تنیده عمل کرده و با بهبود مشخصه‌های هر یک از این دو الگوریتم، قابلیت به کارگیری در مدل‌های مختلف تصمیم‌گیری را با دقت بالا دارد. مدل پیشنهادشده بر روی یک مسئله‌ی کنترل فرآیند پیاده‌سازی شده است.

کلیدواژه

الگوریتم یادگیری ترکیبی، نگاشت ادراکی فازی، الگوریتم ژنتیک، یادگیری هیبن غیرخطی.

مقدمه

نگاشت ادراکی فازی (FCM) از تکنیک‌های محاسبات نرم محسوب می‌شود که در شرایطی کاملاً مشابه فرآیند ذهنی انسان و با استفاده از روند استدلالی، توانایی مواجهه با سیستم‌های پیچیده را دارد. FCM با توصیف حوزه‌ی مربوطه با استفاده از مفاهیم و روابط بین آن‌ها، از روش‌های مدل‌سازی امیدبخش می‌باشد [۲]. در واقع FCM نمایش گرافیکی مدل یک سیستم است [۳] که از نقطه‌نظر شبکه‌های عصبی، می‌توان آن را یک سیستم فازی-عصبی با یادگیری نظارت‌شده نامید [۴].

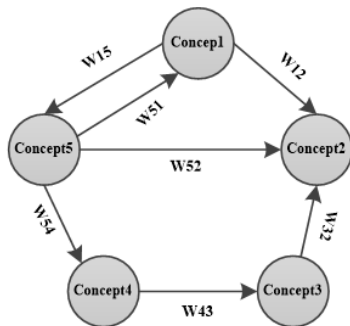
معرفی نگاشت‌های ادراکی فازی توسط کاسکو در سال ۱۹۸۶ به عنوان توسعه‌ای از نگاشت‌های ادراکی که توسط اکسلراد پیشنهاد شد [۵]، دریچه‌ای تازه‌ای را برای مدل‌سازی سیستم‌های پیچیده و مبهم گشود. FCM با بهره‌گیری از مزایای سیستم‌های فازی (قواعد اگر-آن‌گاه) و شبکه‌های عصبی (تعلیم و یادگیری) توانست به سرعت کارآیی خود را در حوزه‌های مختلف اثبات کند؛ به طوری که می‌توان حضور موفق آن را در سیاست، اقتصاد، مهندسی، پزشکی، محیط‌زیست و

افراد درگیر در حوزه‌ی تصمیم‌گیری، در هنگام مواجهه با سیستم‌های پویا، با مشکلات عمده‌ای روبه‌رو هستند. پیچیدگی‌های موجود در مدل‌سازی سیستم‌های پویا را می‌توان از جنبه‌های مختلف مورد بررسی قرار داد. این کار از نقطه‌نظر محاسباتی می‌تواند مشکل‌ساز باشد. دستیابی به یک مدل ریاضی، در اکثر موارد فرآیندی دشوار، پرهزینه و حتی در بعضی موارد غیرممکن است. مدل‌های ریاضی مزیت ارائه‌ی نتایج به صورت کمی را پیشنهاد می‌دهند، اما از معایب مختلفی رنج می‌برند. اولاً، توسعه‌ی چنین مدلی معمولاً به تلاش‌های فراوان و دانش تخصصی در خارج از محدوده‌ی مورد نظر نیاز دارد. ثانیاً، این سیستم‌ها شامل فیدبک‌های قابل توجهی هستند که معمولاً غیرخطی‌اند؛ در نتیجه به کارگیری مدل کمی امکان‌پذیر نیست. در نهایت، دستیابی به داده‌های عددی ممکن است دشوار و غیرقطعی باشد. تمامی این موارد سبب شده است که در غیاب مدل‌های کیفی، تلاش برای درک صحیح سیستم بر اساس استدلال‌های زبانی پیشنهاد گردد [۱].

1 Fuzzy Cognitive Map

می‌کنند. در پیاده‌سازی FCM به صورت ریاضی، دو دسته متغیر باید تعریف گردند:

- مجموعه‌ی مفاهیم که با بردار $C=[c_1, c_2, \dots, c_N]$ (تعداد کل مفاهیم سیستم است) تعیین می‌شود. هر مفهوم دارای یک مقدار فعال‌ساز است که با $A=[a_1, \dots, a_N]$ مشخص می‌گردد. $a_i \in [0,1]$
- مجموعه‌ی وزن یال‌ها که با یک ماتریس $W_{N \times N}$ با مؤلفه‌های $w_{ij} \in [-1,1]$; $i,j=1, \dots, N$ می‌شود. علامت این وزن‌ها، نوع رابطه‌ی بین دو مفهوم را مشخص می‌کند. اگر $w_{ij} > 0$ باشد، یعنی افزایش مفهوم i سبب افزایش مفهوم j می‌شود و کاهش آن موجب کاهش مفهوم j می‌گردد. اگر $w_{ij} < 0$ باشد، افزایش مفهوم i سبب کاهش مفهوم j و بالعکس می‌شود. $w_{ij} = 0$ بر عدم تأثیر این دو مفهوم بر یکدیگر اشاره دارد.



شکل ۱. ساختار یک FCM نمونه.

ماتریس وزن‌های FCM نشان داده شده در شکل ۱، در جدول ۱ استخراج گشته است.

جدول ۱. ماتریس وزن FCM نشان‌داده شده در شکل ۱.

مفهوم ۱	مفهوم ۲	مفهوم ۳	مفهوم ۴	مفهوم ۵
مفهوم ۱	0	0	0	w_{15}
مفهوم ۲	0	0	0	0
مفهوم ۳	0	0	w_{32}	0
مفهوم ۴	0	w_{43}	0	0
مفهوم ۵	w_{51}	0	w_{52}	w_{54}

با انتخاب مفاهیم و تعیین وزن‌ها، مقدار فعال‌ساز هر مفهوم در هر گام $k+1$ را می‌توان با استفاده از معادله‌ی استدلال که در رابطه‌ی ۱ آمده، مشخص نمود:

غیره مشاهده نمود [۶]. با این حال مدل اولیه‌ی FCM دارای کمبودهایی است که در مواردی سبب محدودیت کاربرد آن می‌گردد. علاوه بر این، این مدل در تطبیق دانش متخصصان از طریق بهینه‌سازی و تکنیک‌های یادگیری که در بسیاری از کاربردها ضروری است، ناکارآمد عمل می‌کند. از این رو باید به واسطه‌ی جلوگیری از نقاط ضعفی چون وابستگی به نظر کارشناسان در طراحی، مدل اولیه‌ی FCM را بهبود بخشید. به همین منظور از الگوریتم‌های یادگیری مختلفی برای افزایش قابلیت FCM استفاده شده است [۷-۱۲].

هدف این مقاله معرفی یک الگوریتم ترکیبی مبتنی بر روش یادگیری غیرخطی هبین^۲ (NHL) و الگوریتم ژنتیک کدحقیقی^۳ (RCGA) برای آموزش مدل FCM می‌باشد. این روش که به صورت همزمان از هر دو الگوریتم استفاده می‌کند، با بهره‌گیری از مزایای هر یک از روش‌ها، مدل مناسبی را برای تعلیم FCM ارائه می‌دهد.

ساختار ادامه‌ی مقاله به شرح زیر است: در بخش دوم، ساختار کلی FCM و روند شکل‌گیری آن به تفصیل تشریح می‌شود. در بخش سوم با معرفی انواع روش‌های موجود برای تعلیم مدل FCM، الگوریتم‌های NHL و RCGA تشریح می‌گردند. بخش چهارم به معرفی الگوریتم پیشنهادی اختصاص خواهد یافت. در بخش پنجم، مدل پیشنهادی به یک مسئله‌ی کنترل اعمال می‌شود و نتایج آن با دو الگوریتم NHL و RCGA و همچنین سایر الگوریتم‌های ترکیبی موجود مقایسه می‌گردد. نتیجه‌گیری و جمع‌بندی نیز در بخش آخر ارائه خواهد شد.

نگاشت ادراکی فازی

فرمول‌بندی ریاضی

ساختار FCM متشکل از مفاهیم نشان‌دهنده‌ی اطلاعات سازنده‌ی سیستم و روابط علی بین این مفاهیم می‌باشد. این مفاهیم می‌توانند کمیت‌های فیزیکی، مشخصه‌های کیفی، ایده‌های انتزاعی و به طور کلی نهادهای مفهومی باشند [۱۳]. مدل FCM دارای مشخصه‌های مطلوب فراوانی است؛ از جمله، استفاده از آن در ارائه‌ی دانش ساختاریافته نسبتاً ساده می‌باشد و عملیات استنتاج در آن به وسیله‌ی ماتریس عددی محاسبه می‌شود [۵].

مدل عملی یک FCM با ۵ مفهوم و ۴ وزن در شکل ۱ آورده شده است. همان‌طور که مشخص است در کاربرد واقعی، FCM یک گراف جهت‌دار محسوب می‌شود [۱۴] که گره‌های این گراف بر اساس مفاهیم اساسی سیستم تعیین می‌شوند و یال‌های آن، جهت و میزان تأثیر مفاهیم بر یکدیگر را مشخص

2 Nonlinear Hebbian Learning
3 Real Code Genetic Algorithm

فازی زدای مرکز سطح^۴ (CoA) به مقدار عددی متناظر تبدیل می‌شود [۱۸]. متغیر زبانی کلی در بازه $[-1, 1]$ محدود می‌گردد. چنین فرآیندی برای تمامی وزن‌های بین مفاهیم اعمال شده و ماتریس وزن اولیه محاسبه می‌شود [۱۹]. مزیت این روش در این است که از کارشناسان خواسته می‌شود تا رابطه‌ی علی بین مفاهیم را با استفاده از متغیرهای زبانی تعیین کنند و نیاز به تخصیص وزن‌های عددی ندارند [۱۶]. به این ترتیب ماتریس وزن اولیه به دست می‌آید:

$$W_{initial} = \begin{bmatrix} w_{11} & w_{12} & \dots & w_{1N} \\ w_{21} & w_{22} & \dots & w_{2N} \\ \vdots & \vdots & \ddots & \vdots \\ w_{N1} & w_{N2} & \dots & w_{NN} \end{bmatrix}$$

روش‌های آموزش FCM

آموزش FCM شامل به‌روزرسانی وزن روابط علی می‌باشد. هدف یک الگوریتم یادگیری، تنظیم وزن‌های اولیه با روشی مشابه شبکه‌های عصبی است تا قابلیت مدل‌سازی FCM را بهبود بخشد. الگوریتم‌های موجود برای آموزش FCM را می‌توان در سه دسته‌ی کلی تقسیم‌بندی کرد [۲۰]:

- روش‌های مبتنی بر قانون هبین؛ هدف از آموزش FCM با استفاده از الگوریتم‌های مبتنی بر هبین، تولید ماتریس وزنی بر اساس دانش متخصصان است که به همگرایی مدل به نقاط مطلوب منجر گردد.
 - روش‌های یادگیری مبتنی بر جمعیت؛ هدف استفاده از این روش‌ها، محاسبه‌ی ماتریس وزن بر اساس داده‌های پیشین است، به گونه‌ای که بهترین تطبیق را با الگوی ورودی داشته باشد.
 - الگوریتم‌های ترکیبی؛ همان‌طور که از نامشان مشخص است، این الگوریتم‌ها از مزیت هر دو روش قبلی بهره می‌برند و هدفشان تصحیح/به‌روزرسانی ماتریس وزن‌ها بر اساس دانش متخصصان و داده‌های پیشین می‌باشد.
- در بین سه روش کلی یادشده، روش ترکیبی یا هیبرید با بهره‌گیری از مزایای هر دو روش قبلی، روش کارآمدتری برای تعلیم FCM محسوب می‌شود. روش‌های هیبرید عمده‌ای که تاکنون پیشنهاد شدند، معمولاً به صورت دو طبقه و یا دو مرحله‌ای عمل کرده‌اند. به این معنا که هر یک از روش‌های

$$a_i(k+1) = f \left[a_i(k) + \sum_{j=1}^N (a_j(k) w_{ji}) \right] \quad (1)$$

در رابطه‌ی ۱، f تابع تبدیلی است که بسته به نوع کاربرد برای محدود کردن مفاهیم فعال‌ساز در بازه‌ی دلخواه به کار می‌رود. در مرجع [۱۵] مرور کاملی بر انواع توابع تبدیل صورت گرفته است. پرکاربردترین انواع این توابع در روابط (۲) الی (۴) آورده شده‌اند.

$$f_{sign}(x) = \begin{cases} 1 & x > 0 \\ 0 & x \leq 0 \end{cases} \quad (2)$$

$$f_m(x) = \begin{cases} +1 & x \geq 0.5 \\ 0 & -0.5 < x < 0.5 \\ -1 & x \leq -0.5 \end{cases} \quad (3)$$

$$f(x) = \frac{1}{1 + e^{-\alpha x}} \quad \alpha \geq 0 \quad (4)$$

در رابطه‌ی ۴، α درجه‌ی همگرایی تابع را مشخص می‌کند و معمولاً از طریق سعی و خطا به دست می‌آید.

فرآیند تشکیل مدل FCM

روش توسعه و تشکیل FCM تأثیر زیادی در کارایی مدل نهایی سیستم دارد. روش‌های پیشنهادی وابسته به نظرات گروهی از کارشناسان می‌باشند که وظیفه‌ی نظارت بر سیستم را بر عهده داشته و رفتار آن را می‌شناسند. این روش، دانش کارشناسان را استخراج کرده و تجربه‌ی آن‌ها را در مدل سیستم به کار می‌گیرد [۱۶]. به این منظور و با هدف عدم وابستگی مدل به نظر یک شخص، از گروهی از متخصصان خواسته می‌شود که ابتدا مفاهیم اساسی سیستم را با توجه به دانش و تجربه‌ی خود مشخص کنند. در نهایت، مشخصه‌هایی که در بین نظر تمامی کارشناسان مشترک است، به عنوان مفاهیم سیستم انتخاب می‌شوند. در مرحله‌ی بعد، متخصصان با آگاهی از وجود یا عدم وجود رابطه‌ی بین دو مفهوم، وزن‌های غیرصفر مدل را مشخص کرده و نوع وزن از نظر افزایشی یا کاهش‌ی بودن را تعیین می‌کنند. سپس از هر یک به صورت مجزا خواسته می‌شود که میزان تأثیر متغیرها بر یکدیگر را با استفاده از متغیرهای زبانی چون "قوی"، "متوسط"، "ضعیف" و غیره توصیف کنند [۱۷]. این متغیرهای زبانی در قالب توابع عضویت فازی بیان می‌گردند.

در نتیجه برای هر وزن، N متغیر زبانی توسط N متخصص مشخص می‌شود. این متغیرها با استفاده از روش‌های منطق فازی مثل SUM، MAX، MIN و غیره با هم ترکیب شده و وزن کیفی کلی به دست می‌آید که در نهایت با روش

متفاوت برای NHL شانس دستیابی به حالت بهینه را بیشتر از سایر الگوریتمهای ترکیبی مشابه می‌کند.

مدلی که ما در این مقاله پیشنهاد داده‌ایم، یک روش ترکیبی درهمنهاده مبتنی بر NHL و RCGA می‌باشد که با به‌کارگیری ایده‌های مطرح شده در [۲۱] و [۲۲]، سعی بر استفاده از مزایای هر دو الگوریتم دارد. قبل از تشریح الگوریتم مربوطه، به طور مختصر الگوریتمهای NHL و RCGA را توصیف می‌کنیم تا بتوان به راحتی در تشریح الگوریتم از آن‌ها استفاده کرد.

الگوریتم یادگیری هیبن غیرخطی برای آموزش FCM

الگوریتم NHL که در [۱۰] پیشنهاد شده، بر این فرض استوار است که همه‌ی مفاهیم مدل FCM در هر گام زمانی تحریک شده و مقادیرشان تغییر می‌کند. در طول فرآیند محرک‌سازی وزن w_{ji} متناسب به ارتباط علی بین مفاهیم مربوطه، وزن $w_{ji}(k)$ به دست آمده در گام k ام به‌روزرسانی و تصحیح می‌شود.

بنابراین، در شکل کامل‌تر رابطه‌ی ۱، مقدار $a_i(k+1)$ مربوط به مفهوم C_i ، در گام $k+1$ ام با استفاده از رابطه‌ی ۵ محاسبه می‌شود:

$$a_i(k+1) = f \left[a_i(k) + \sum_{j=1}^N a_j(k) w_{ji}(k) \right] \quad (5)$$

علاوه بر این، بعضی از مفاهیم به‌عنوان مفاهیم خروجی (OC) تعریف می‌شوند. این مفاهیم مربوط به مؤلفه‌ها و مشخصه‌هایی از سیستم هستند که مورد توجه ما می‌باشند و ما می‌خواهیم مقادیر آن‌ها را تخمین زده و حالت نهایی سیستم را ارائه می‌کنند. طبقه‌بندی مفاهیم FCM به عنوان ورودی و خروجی توسط گروه متخصصان انجام می‌شود. هر یک از مفاهیم FCM ممکن است ورودی یا خروجی باشند؛ با این حال، کارشناسان مفاهیم خروجی را انتخاب کرده و فرض می‌کنند سایر مفاهیم، محرک‌های اولیه‌ی سیستم هستند.

قاعده‌ی NHL، دارای فرم عمومی به صورت رابطه‌ی ۶ می‌باشد:

$$\Delta w_{ji} = \eta_k a_j (a_i - a_j w_{ji}) \quad (6)$$

که در آن، η_k یک فاکتور مثبت بسیار کوچک است و پارامتر یادگیری نامیده می‌شود. این ضریب عموماً با استفاده از آزمایش‌های سعی و خطا تعیین شده و راه‌حل نهایی را بهینه می‌کند.

تکاملی و هیبن را به صورت مجزا ولی به دنبال هم اعمال نموده‌اند.

پاپاگورجیو^۶ و گرومپوس^۷ با استفاده‌ی دو مرحله‌ای از الگوریتم تکاملی تفاضلی^۸ (DE)، الگوریتم ترکیبی کارایی را معرفی کردند [۲۱]. در این مقاله وزن‌های اولیه ابتدا توسط NHL آموزش دیده و پس از یافتن جواب نهایی الگوریتم NHL، جمعیت اولیه‌ی DE در همسایگی این جواب تشکیل شده و بهینه‌سازی می‌گردند. در واقع این روش، ضمن به‌کارگیری از دانش متخصصان در تعیین وزن‌های اولیه و آموزش آن‌ها با استفاده از الگوریتم NHL، این امکان را در نظر می‌گیرد که شاید در همسایگی این جواب به دست آمده، بتواند به جواب بهتری دست یابد. در نظر گرفتن این شانس در این الگوریتم سبب می‌شود که مدل پیشنهاد شده در این مقاله علاوه بر دارا بودن مزایای روش‌های مبتنی بر هیبن و تکاملی به صورت همزمان، قابلیت دستیابی به جواب بهتری را نیز داشته باشد. با توجه به محدود نمودن فضای جستجوی الگوریتم DE، مدت زمان اجرای این روش نسبت به دیگر روش‌های ترکیبی موجود کوتاه‌تر می‌باشد. در کار بعدی، یان‌چان^۹ و وی الگوریتم ترکیبی دیگری را با استفاده از NHL و RCGA پیشنهاد دادند که از RCGA به منظور تشکیل مدل اولیه بدون نیاز به دانش انسانی بهره گرفته شد و سپس با استفاده از NHL وزن‌های مدل تعلیم دیدند [۲۲]. مزیت اصلی این روش در عدم نیاز به دانش متخصصان در تعیین وزن‌های اولیه است که همین مسئله سبب کارایی آن در مواقعی است که چنین دسترسی‌ای وجود ندارد. با این حال این مسئله مدت زمان اجرای الگوریتم را به شدت طولانی می‌کند؛ زیرا در یک فضای جستجوی گسترده به دنبال جواب می‌گردد. جدیدترین الگوریتم ترکیبی ارائه شده که در سال ۲۰۱۵ توسط پنگ^{۱۰} و همکارانش معرفی شد [۲۳]، برای مدل‌سازی سیستم‌های چندبعدی و چندسطحی که با استفاده از FCM چندرابطه‌ای مدل شده‌اند، به کار گرفته شد. در مدل پیشنهادی این مقاله، وزن‌های اولیه مشابه [۲۲] به صورت تصادفی انتخاب می‌شوند؛ سپس هر یک از وزن‌های تصادفی پس از تعلیم توسط NHL، با تابع هدف RCGA مورد ارزیابی قرار می‌گیرند تا جواب بهینه به دست آید. طولانی بودن زمان اجرا به دلیل گستردگی فضای جستجو و عدم به‌کارگیری از تجربه‌ی خبرگان در تعیین وزن‌های اولیه از معایب این روش محسوب می‌شود. با این حال در نظر گرفتن نقاط ابتدایی


6 Papageorgiou
7 Groumpos
8 Differential Evolution
9 Yanchun
10 Wei
11 Peng

می‌گردد. پس از تعیین شایستگی نسل اول، بخشی از این پاسخ‌ها (با توجه به میزان شایستگی‌شان) برای ورود به نسل دوم انتخاب می‌شوند (عملگر انتخاب). در این مرحله، دو عملگر بعدی الگوریتم GA یعنی ادغام و جهش به جمعیت اعمال می‌شوند. عملگر ادغام این امکان را فراهم می‌کند که پاسخ‌ها به صورت دو به دو تصادفی با هم ترکیب شوند؛ به امید اینکه بتوانند پاسخی با شایستگی بالاتر تولید کنند. عملگر جهش برای جلوگیری از توقف الگوریتم در نقطه‌ی بهینه‌ی محلی، ژن‌ها را به صورت تصادفی تغییر می‌دهد. پس از اعمال این دو عملگر، عملیات ارزیابی دوباره انجام شده و شایستگی هر پاسخ دوباره تعیین می‌گردد و نسل بعدی با اعمال دوباره‌ی عملگر انتخاب شروع به کار می‌کند.

همان طور که بیان شد در اینجا قصد داریم از مدل توسعه یافته‌ی الگوریتم ژنتیک یعنی RCGA به عنوان الگوریتم بهینه‌ساز استفاده کنیم که از نظر فرآیند الگوریتم و عملگرها مشابه‌ی GA می‌باشد؛ با این تفاوت که به جای کدگذاری ژن‌ها به صورت باینری، کروموزوم حاوی اعداد ممیز شناور است. در واقع RCGA امکان کار در محیط پیوسته را فراهم می‌کند و از آنجایی که ماهیت اصلی مسئله پیوسته است، با این کار دیگر نیازی به تبدیل از حوزه‌ی گسسته به پیوسته نبوده و در نتیجه قابلیت‌های GA بهبود می‌یابد.

برای استفاده از الگوریتم‌های بهینه‌سازی در تعلیم وزن‌های FCM، اولین مرحله‌ی انتقال FCM به محیط RCGA است. برای این کار باید نگاشت متناظری بین وزن‌های FCM و ژن‌های RCGA صورت گیرد. به این منظور هر یک از کمان‌هایی که از نظر کارشناسان دارای وزنی غیرصفر است، به عنوان یک ژن الگوریتم RCGA در نظر گرفته می‌شوند. برقراری این نگاشت، برای یک FCM ساده با ۳ مفهوم و ۳ وزن غیرصفر در شکل ۲ نشان داده شده است.

مهم‌ترین مسئله در الگوریتم ژنتیک و به تبع آن RCGA، انتخاب مناسب تابع هدف است که باید با توجه به نیاز مسئله به درستی تعریف گردد. تابع هدف تعریف شده برای آموزش وزن‌های FCM در رابطه‌ی ۱۰ معرفی گشته است:



شکل ۲. نگاشت وزن‌های مدل FCM به کروموزوم‌های الگوریتم RCGA.

$$\text{fitness} = \frac{1}{\beta e + 1} \quad (10)$$

این قاعده‌ی ساده بیان می‌کند که اگر $a_i(k)$ مقدار مفهوم C_i در گام k ام باشد و a_j مقدار محرک‌ساز مفهوم C_j باشد که مفهوم C_i را تحریک می‌کند، وزن w_{ji} از C_j به سمت C_i ، متناسب با حاصل ضرب آن‌ها در نرخ یادگیری، منهای وزن کاسته شده در گام k ام، افزایش می‌یابد.

در نهایت الگوریتم آموزش وزن‌ها به صورت زیر است:

$$w_{ij}(k) = w_{ij}(k-1) + \eta_k \times a_j(k-1) \cdot [a_i(k-1) - [a_j(k-1) \times w_{ji}(k-1)]] \quad (7)$$

در هر گام شبیه‌سازی، مقدار هر مفهوم FCM با استفاده از رابطه‌ی ۵ به‌روزرسانی می‌شود که مقدار وزن $w_{ji}(k)$ با استفاده از رابطه‌ی ۷ محاسبه می‌گردد.

همچنین، دو تابع معیار برای این الگوریتم تعریف می‌شود. معیار اول، حداکثرسازی تابع هدف J می‌باشد که برای الگوریتم NHL، مقادیر مطلوب مفاهیم خروجی را ارزیابی می‌کند؛ بنابراین J به صورت زیر تعریف می‌گردد:

$$J = \sum_{i=1}^l (OC_i)^2 \quad (8)$$

که در آن، l تعداد مفاهیم خروجی است. معیار دوم، حداقل‌سازی تغییرات مقادیر متوالی مفاهیم خروجی است که در رابطه‌ی ۹ آورده شده است:

$$|OC_j(k+1) - OC_j(k)| < e \quad (9)$$

اصطلاح e سطح انحراف مجازی است که تغییرات مقادیر خروجی را تا حد ممکن پایین نگه می‌دارد. این معیارها تعیین می‌کنند که فرآیند تکرار شونده‌ی الگوریتم یادگیری چه زمانی به پایان برسد. با استفاده از این فرآیند و هنگامی که شرایط خاتمه‌ی الگوریتم تحقق یافت، ماتریس وزن نهایی به دست می‌آید.

الگوریتم RCGA

الگوریتم ژنتیک^۳ (GA)، تکنیک بهینه‌سازی الهام گرفته شده از نظریه‌ی داروین در طبیعت می‌باشد [۲۴]. برای انتخاب راه‌حل بهینه‌ی مسئله، از تعدادی پاسخ تصادفی (جمعیت اولیه) استفاده می‌کند. هر یک از این پاسخ‌های اولیه که کروموزوم نامیده می‌شوند، متشکل از ژن‌هایی است که به صورت باینری کد می‌شوند. هر یک از این پاسخ‌ها بر اساس تابع هدف تعیین شده برای مسئله، ارزیابی شده و شایستگی آن‌ها مشخص

انتخاب شده و پس از اعمال الگوریتم یادگیری NHL، کمترین خطا را با توجه به تابع هدف تعریف شده تولید کند. روند کلی الگوریتم به شرح زیر است:

گام اول: دریافت وزن‌های اولیه تعیین شده توسط کارشناسان.

گام دوم: تشکیل جمعیت اولیه RCGA با اعدادی تصادفی در همسایگی معینی از وزن اولیه و تنظیم $t=1$.

گام سوم: در نظر گرفتن هر یک از بردارهای جمعیت اولیه به عنوان بردار وزن اولیه برای ورود به الگوریتم NHL.

گام چهارم: ارزیابی جمعیت تعلیم دیده به کمک NHL با استفاده از تابع شایستگی که در رابطه‌ی ۱۱ آمده است.

گام پنجم: بررسی معیار توقف RCGA؛ اگر شرط توقف برآورده شد، الگوریتم متوقف می‌شود.

گام ششم: در غیر این صورت کروموزوم‌های با شایستگی بهتر را برای ورود به نسل بعد انتخاب کن.

گام هفتم: با اعمال عملگرهای ادغام و جهش، جمعیت جدید را تشکیل بده.

گام هشتم: جمعیت جدید را با جمعیت قبلی جایگزین کن.

گام نهم: $t=t+1$ قرار بده و به مرحله‌ی ۳ برگرد.

همان طور که بیان شد الگوریتم‌های ترکیبی با هدف غلبه بر معایب هر یک از الگوریتم‌های مبتنی بر هبیین و جمعیت و استفاده از مزایای هر دو طراحی می‌شوند. به منظور ارائه‌ی مقایسه‌ای از مزایا و معایب و شرایط به کارگیری انواع الگوریتم‌های ترکیبی موجود و الگوریتم پیشنهادی، در جدول ۲ این معیارها مورد بررسی قرار گرفته‌اند. ستون آخر این جدول، به شرایطی اشاره دارد که الگوریتم ترکیبی قادر است علاوه بر استفاده از مزایای هر دو روش مبتنی بر هبیین و جمعیت، به جواب ایده‌آل تری دست یابد.

در خصوص زمان اجرای الگوریتم‌های مطرح شده در جدول ۲، توجه به این نکته ضروری است که الگوریتم‌های مبتنی بر هبیین، به ویژه NHL، زمان اجرای بسیار کوتاهی دارند و عامل اصلی در طولانی شدن زمان اجرا، تعداد مراحل مورد نیاز الگوریتم تکاملی برای پیدا کردن جواب بهینه است. همین مسئله سبب شده در روش‌هایی که فضای جستجوی الگوریتم تکاملی محدود نشده است، مراحل لازم برای یافتن جواب افزایش یافته و مدت زمان کلی اجرای الگوریتم بیشتر شود. از آنجایی که زمان اجرای الگوریتم‌ها به شدت به ابعاد مدل FCM مورد بررسی وابسته است، زمان‌های ارائه شده در جدول به صورت عبارات کیفی‌اند. به منظور ارائه‌ی درک دقیق‌تری از این واژه‌های کیفی، در جدول ۳ که نتایج اعمال الگوریتم‌های مورد

که در آن، β یک پارامتر ثابت است و معمولاً در محدوده‌ی $\beta > 10000$ انتخاب می‌شود و e میزان فاصله‌ی مدل پیشنهادی با مدل واقعی را تعیین می‌کند که به صورت زیر تعریف می‌گردد:

$$e = \frac{1}{(T-1)N} \sum_{t=1}^T |a_N(t) - a'_N(t)| \quad (11)$$

در رابطه‌ی ۱۱، N تعداد کل مفاهیم و T طول داده‌های ورودی برای آموزش است. $a_N(t)$ نشان‌دهنده‌ی مقدار واقعی مفهوم خروجی t امین داده‌ی ورودی است و $a'_N(t)$ مفهوم خروجی t امین داده‌ی ورودی است که توسط FCM پیشنهادی و با استفاده از رابطه‌ی ۱ تعیین می‌گردد. در واقع این تابع شایستگی، با تجمع فاصله‌ی مقدار نهایی تخمین زده شده توسط FCM پیشنهادی با مقدار واقعی آن برای همه‌ی داده‌های آموزشی، مدل بهینه را پیدا می‌کند.

شرطی که برای توقف الگوریتم در نظر گرفته شده، بر اساس همگرایی می‌باشد. زمانی که شایستگی بهترین کروموزوم در نسل قبلی از پارامتر مشخص δ بیشتر نشد، الگوریتم متوقف خواهد شد. در غیر این صورت، یک شرط اضافی برای جلوگیری از اجرای دائمی الگوریتم‌های واگرا در نظر گرفته شده است که اگر تعداد نسل‌ها از حد مشخصی بیشتر شود، الگوریتم متوقف می‌گردد.

مدل ترکیبی RCGA-NHL

در این بخش الگوریتم ترکیبی پیشنهادی را تشریح خواهیم کرد. الگوریتم RCGA-NHL درهمننیده که در ادامه معرفی خواهد شد، با این فرض بنا نهاده شده که می‌توان با به‌کارگیری NHL در تابع ارزیابی RCGA، قابلیت هر دو روش را افزایش داد. در واقع در اینجا، به جای تولید جمعیت اولیه‌ی RCGA به صورت تصادفی، آن را در همسایگی ماتریس وزن اولیه‌ی به دست آمده توسط متخصصان تولید می‌کنیم. اولین بهبود در این مرحله صورت می‌گیرد؛ محدود کردن فضای جستجوی RCGA، تعداد دوره‌های مورد نیاز برای یافتن جواب بهینه را به شدت کاهش می‌دهد. سپس برای ارزیابی کروموزوم‌های RCGA در هر مرحله، پیش از به‌کارگیری تابع هدف، کروموزوم‌ها را به عنوان وزن اولیه وارد الگوریتم NHL می‌کنیم. با این کار، این امکان برای NHL فراهم می‌شود که با تغییر مختصری در وزن‌های اولیه، احتمال همگرایی مطلوب‌تری داشته باشد. وزن‌های نهایی NHL مورد ارزیابی قرار می‌گیرند. در نهایت وزن بهینه، وزنی است که در همسایگی وزن اولیه


بررسی بر یک مسئله‌ی کنترل فرآیند آورده شده، زمان‌های کمی ارائه شده اند.

جدول ۲. مقایسه‌ی مزایا، معایب و کاربردهای الگوریتم‌های ترکیبی موجود با الگوریتم پیشنهادی.

مزیت ویژه نسبت روش‌های غیر ترکیبی	شرایط کاربرد	مدت زمان اجرای الگوریتم	به‌کارگیری دانش متخصصان در تشکیل مدل	
			مقایسه	انواع مدل‌ها
-	وجود دسترسی به کارشناسان برای تشکیل وزن اولیه	خیلی کوتاه	بلی	یادگیری مبتنی بر هبیین
-	عدم دسترسی به کارشناسان برای تشکیل وزن اولیه	به دلیل گستردگی فضای جستجو، مدت زمان اجرا نسبتاً طولانی است.	خیر	یادگیری مبتنی بر جمعیت
بررسی احتمال دست‌یابی به جواب بهینه در همسایگی جواب نهایی NHL	وجود دسترسی به کارشناسان برای تشکیل وزن اولیه	به دلیل محدود بودن فضای جستجو، مدت زمان اجرا کوتاه است.	بلی	مدل [۲۱]
-	عدم دسترسی به کارشناسان برای تشکیل وزن اولیه	به دلیل گستردگی فضای جستجو، مدت زمان اجرا نسبتاً طولانی است.	خیر	مدل [۲۲]
بررسی احتمال دست‌یابی به جواب بهینه با تغییر در نقاط اولیه‌ی NHL	عدم دسترسی به کارشناسان برای تشکیل وزن اولیه	به دلیل گستردگی فضای جستجو و همچنین به کارگیری NHL در ارزیابی هر مرحله، مدت زمان اجرا خیلی طولانی است.	خیر	مدل [۲۳]
بررسی احتمال دست‌یابی به جواب بهینه با تغییر در نقاط اولیه‌ی NHL	وجود دسترسی به کارشناسان برای تشکیل وزن اولیه	اگرچه در مراحل مختلف تعیین شایستگی RCGA از NHL استفاده می‌کند، اما به دلیل محدود بودن فضای جستجو و کم بودن تعداد مراحل مورد نیاز، مدت زمان اجرا نسبتاً کوتاه است.	بلی	مدل پیشنهادی

دیگری بر روی ارتفاع مایع درون مخزن، T وجود دارد که نمی‌تواند از یک مقدار حداکثر T_{max} و یک مقدار حداقل T_{min} تجاوز کند. در نتیجه اهداف کنترلی این مسئله، محدود کردن دو متغیر T و G در محدوده‌ی مطلوب خودشان است:

$$G_{min} \leq G \leq G_{max}, \quad T_{min} \leq T \leq T_{max}$$



شکل ۳. مسئله‌ی کنترلی مورد بررسی [۲۵].

سه متخصص با به‌کارگیری فرآیند ذکرشده در [۲۵]، مدل FCM این فرآیند را استخراج کردند که شامل ۵ مفهوم می‌باشد و به صورت زیر تعریف می‌گردند:

مفهوم ۱ (C_1): میزان مایع موجود در مخزن که به وضعیت عملیاتی دریاچه‌های ۱، ۲ و ۳ بستگی دارد.

پایه‌سازی الگوریتم پیشنهادی به یک مسئله‌ی کنترل فرآیند

در این بخش، الگوریتم پیشنهادی را برای یک مسئله‌ی کنترل فرآیند ساده به کار می‌گیریم [۲۵]. این مسئله به عنوان یکی از مسائل محک استاندارد در بررسی کارایی الگوریتم‌های معرفی‌شده برای آموزش وزن‌های FCM در مقالات مختلف مورد استفاده قرار گرفته است (به عنوان نمونه [۲۱] و [۲۵]). سیستم مورد استفاده در شکل ۳ نشان داده شده است. در این فرآیند، یک مخزن و سه دریاچه وجود دارد که مقدار مایع درون مخزن را تحت تأثیر قرار می‌دهند. دریاچه‌های ۱ و ۲ دو مایع مختلف را وارد مخزن می‌کنند. در طول مخلوط شدن این دو مایع، یک واکنش شیمیایی در مخزن رخ می‌دهد و مایع جدید را تولید می‌کند. هنگامی که مایع جدید به سطح خاصی رسید، دریاچه‌ی سوم مخزن را تخلیه می‌نماید. علاوه بر این، درون مخزن حسگری برای اندازه‌گیری چگالی ویژه مایع تولید شده قرار دارد. وقتی مقدار چگالی ویژه، G ، در بازه‌ی $[G_{min}, G_{max}]$ باشد، مایع مطلوب تولید شده است. همچنین محدودیت

ترکیبی موجود که به ترتیب در مراجع [۲۱]، [۲۲] و [۲۳] معرفی شده‌اند و همچنین الگوریتم پیشنهادی در این مقاله تعلیم می‌دهیم. معیارهایی که برای ارزیابی مورد استفاده قرار گرفته‌اند، به شرح زیر می‌باشند:

- خطا: اختلاف بین داده‌های موجود و داده‌های تولیدشده با استفاده از مدل آموزش‌دیده برای بردار حالت‌های یکسان. این معیار به صورت خطای میانگین بین مقادیر مفاهیم مربوطه در هر تکرار بین دو دنباله‌ی بردار حالت تعریف می‌شود:

$$error = \frac{1}{(T-1).N} \sum_{t=1}^{K-1} \sum_{n=1}^N |a_n(t) - a'_n(t)| \quad (13)$$

که در آن، مقدار گره‌ی n ام در دوره‌ی n در داده‌های ورودی است، $a'_n(t)$ مقدار گره‌ی n ام در دوره‌ی n با استفاده از مدل آموزش‌دیده می‌باشد و K و N به ترتیب طول بردار ورودی و تعداد کل مفاهیم هستند.

- دقت نهایی: این معیار، میزان دستیابی به محدودیت‌های موجود بر روی OC را تعیین می‌کند. برای استفاده از این معیار، پس از رسیدن به شرایط پایدار، رابطه‌ی ۱۴ مورد استفاده قرار می‌گیرد:

$$Accuracy = \frac{\overline{OC_i}}{OC_i} \quad (14)$$

که در آن، $\overline{OC_i}$ تعداد OC هایی می‌باشند که بعد از پایان شبیه‌سازی به محدودیت‌های تعیین شده دست یافتند و OC_i تعداد کل OC هاست.

- زمان اجرای الگوریتم: در مسائل پیچیده‌تر با تعداد مفاهیم بیشتر، زمان به عنوان اصل‌ترین عامل محدودکننده مطرح است. از این رو باید به عنوان یکی از معیارهای ارزیابی در نظر گرفته شود.

نتایج ارزیابی

پارامترهای RCGA برای انجام شبیه‌سازی به شرح زیر بوده‌اند:

تعداد داده‌های پیشین: ۱۰

جمعیت اولیه: ۲۰

نوع عملگر انتخاب: چرخ رولت

نرخ عملگر ادغام: ۰/۵

نرخ عملگر جهش: ۰/۱

حداکثر تعداد دوره‌ها: ۱۰۰

مفهوم ۲ (C2): وضعیت دریچه‌ی ۱ (که می‌تواند بسته، باز و یا نیمه‌باز باشد).

مفهوم ۳ (C3): وضعیت دریچه‌ی ۲ (که می‌تواند بسته، باز و یا نیمه‌باز باشد).


مفهوم ۴ (C4): وضعیت دریچه‌ی ۳ (که می‌تواند بسته، باز و یا نیمه‌باز باشد).

مفهوم ۵ (C5): چگالی ویژه‌ی مایع درون مخزن.

برای این مسئله، کارشناسان مقادیر اولیه‌ی مفاهیم و وزن‌ها و اینکه کدام مفاهیم به عنوان OC می‌باشند را تعیین نموده‌اند. مفاهیم مطلوب خروجی در اینجا C1 و C5 می‌باشند. برای تعیین مقادیر اولیه‌ی وزن‌ها همان‌طور که در قسمت‌های قبلی تشریح شد، کارشناسان تأثیر هر یک از مفاهیم بر یکدیگر را به صورت دو به دو با استفاده از متغیرهای فازی بیان نمودند. محدوده‌ی وزن‌های اعمال شده با استفاده از متغیرهای فازی به صورت زیر است:

$$\begin{aligned} -0.5 \leq w_{12} \leq -0.3, & \quad -0.4 \leq w_{13} \leq -0.2, \\ 0.2 \leq w_{15} \leq 0.5, & \quad 0.3 \leq w_{31} \leq 0.5, \\ 0.3 \leq w_{31} \leq 0.5, & \quad -1 \leq w_{41} \leq -0.7, \\ -1 \leq w_{52} \leq -0.5, & \quad 0.2 \leq w_{54} \leq -0.3, \end{aligned} \quad (12)$$

در نهایت سه متغیر فازی پیشنهاد شده برای هر وزن با استفاده از روش SUM ترکیب شده و نتیجه با روش CoA به صورت وزن‌های عددی در آمده است که در شکل ۴ آورده شده است.



شکل ۴. مدل FCM مسئله‌ی کنترلی [۲۱].

همان‌طور که در شکل ۴ نشان داده شده، ماتریس وزن‌های اولیه به صورت زیر است:

$$W_{initial} = \begin{bmatrix} 0 & -0.4 & -0.25 & 0 & 0.3 \\ 0.36 & 0 & 0 & 0 & 0 \\ 0.45 & 0 & 0 & 0 & 0 \\ -0.9 & 0 & 0 & 0 & 0 \\ 0 & 0.6 & 0 & 0.3 & 0 \end{bmatrix}$$

مقادیر مطلوب برای دو مفهوم خروجی به صورت زیر می‌باشد:

$$0.74 \leq G \leq 0.80$$

$$0.68 \leq H \leq 0.70$$

به منظور درک بهتر قابلیت آموزش الگوریتم پیشنهادی، مدل اولیه را با استفاده از الگوریتم‌های NHL، RCGA، سه روش

بین روش‌های موجود برای آموزش وزن‌های FCM، الگوریتم‌های ترکیبی با بهره‌گیری از مزایای روش‌های مبتنی بر قانون هبین و روش‌های مبتنی بر جمعیت به صورت همزمان، از توانایی بالاتری برخوردارند. در این مقاله، یک الگوریتم ترکیبی جدید بر اساس روش‌های NHL و RCGA معرفی گردید. الگوریتم پیشنهادی که از الگوریتم NHL و RCGA به صوت همزمان استفاده می‌کند، با محدود کردن فضای جست‌وجوی RCGA و در نتیجه کاهش مدت زمان بهینه‌سازی و همچنین فراهم نمودن امکان تغییر نقطه‌ی آغاز به کار NHL برای دستیابی به نقاط مطلوب خروجی، ویژگی‌های هر یک از این الگوریتم‌ها را بهبود می‌بخشد. از الگوریتم معرفی شده می‌توان در کاربردهای مختلف FCM برای مدل‌سازی و تصمیم‌گیری استفاده نمود. مدل پیشنهادی به یک مسئله‌ی کنترل فرآیند اعمال شد که نتایج آن در مقایسه با هر یک از الگوریتم‌های NHL و RCGA و سایر الگوریتم‌های ترکیبی موجود از نظر معیارهای دقت و خطای تعریف‌شده، موفق عمل کرده است. علاوه بر این، زمان اجرای الگوریتم پیشنهادی نیز در مقایسه با سایر روش‌های ترکیبی قابل قبول می‌باشد.

مراجع

- [1] J. Aguilar, "A survey about fuzzy cognitive maps papers," *International Journal of Computational Cognition*, vol. 3, no. 2, pp. 27-33, 2005.
- [2] E. I. Papageorgiou, C. D. Stylios, and P. P. Groumpos, "Active Hebbian learning algorithm to train fuzzy cognitive maps," *International Journal of Approximate Reasoning*, vol. 37, no. 3, pp. 219-249, 2004.
- [3] P. Beena and R. Ganguli, "Structural damage detection using fuzzy cognitive maps and Hebbian learning," *Applied Soft Computing*, vol. 11, no. 1, pp. 1014-1020, 2011.
- [4] J. L. Salmeron, "Fuzzy cognitive maps for artificial emotions forecasting," *Applied Soft Computing*, vol. 12, no. 12, pp. 3704-3710, 2012.
- [5] B. Kosko, "Fuzzy cognitive maps," *International Journal of Man-Machine Studies*, vol. 24, no. 1, pp. 65-75, 1986.
- [6] E. I. Papageorgiou and J. L. Salmeron, "A review of fuzzy cognitive maps research during the last decade," *IEEE Transactions on Fuzzy Systems*, vol. 21, no. 1, pp. 66-79, 2013.
- [7] A. V. Hueriga, "A balanced differential learning algorithm in fuzzy cognitive maps," *Proceedings of the 16th International Workshop on Qualitative Reasoning*, Barcelona, Spain, pp. 1-7, 2002.
- [8] E. I. Papageorgiou, C. D. Stylios, and P. P. Groumpos, "Activation Hebbian learning rule for fuzzy cognitive maps," *Proceedings of 15th*

با توجه به کمبود تعداد داده‌های پیشین، در به‌کارگیری الگوریتم‌هایی که حاوی روش‌های تکاملی می‌باشند، هر بار ۹ داده برای تعلیم و یک داده برای ارزیابی مورد استفاده قرار گرفته‌اند.

جدول ۳ نتایج مربوط به به‌کارگیری هر شش الگوریتم را با استفاده از معیارهای تعریف‌شده ارائه کرده است. شبیه‌سازی‌ها با استفاده از نرم‌افزار متلب بر روی یک پردازنده‌ی مرکزی Intel(R) Core i5 @ 2/53 GHZ انجام شده است.

جدول ۳. نتایج ارزیابی مسئله‌ی کنترل فرآیند با استفاده از شش الگوریتم یادگیری.

معیار ارزیابی	دقت	خطا	تعداد دوره‌های اجرا	زمان اجرای (ثانیه)	مدل
					NHL
NHL	۷۰	۰/۱۴۳	-	۱	
RCGA	۱۰۰	۰/۱۳۵	۱۰۰	۵۰۰	
مدل [۲۱]	۱۰۰	۰/۱۱۹	۵۰	۲۵۰	
مدل [۲۲]	۱۰۰	۰/۱۳۰	۱۰۰	۵۰۰	
مدل [۲۳]	۱۰۰	۰/۱۲۳	۸۸	۵۲۸	
مدل پیشنهادی	۱۰۰	۰/۱۲۱	۴۱	۲۴۸	

با تحلیل نتایج جدول ۳ می‌توان دریافت که معیار دقت که قرارگیری خروجی هر یک از داده‌های آزمایشی را در بازه‌ی مطلوب تعیین‌شده مشخص می‌کند، برای همه‌ی روش‌ها به جز NHL برآورده شده است. این مسئله نشان می‌دهد که به‌کارگیری الگوریتم تکاملی و استفاده از اطلاعات موجود در داده‌های پیشین، دستیابی به محدوده‌ی مطلوب خروجی را تضمین می‌کند. معیار بعدی خطای میانگین مقادیر مفاهیم در دو تکرار متوالی است که از نتایج جدول می‌توان به مناسب بودن مدل‌های [۲۱]، [۲۳] و مدل پیشنهادی در این مقاله در این زمینه پی برد. دو ستون آخر، معیار زمان را مورد بررسی قرار می‌دهند. همان‌طور که اشاره شد، زمان اجرای الگوریتم NHL بسیار ناچیز بوده و الگوریتم تکاملی تعیین‌کننده‌ی مدت زمان اجرا می‌باشد. نتایج زمانی الگوریتم‌ها با تحلیل‌های مورد انتظار در بخش قبلی کاملاً موافقت دارد و الگوریتم پیشنهادی در بین سایر الگوریتم‌های ترکیبی، دارای زمان اجرای قابل قبولی می‌باشد. جمع‌بندی همه‌ی معیارهای ارزیابی نشان می‌دهد که روش معرفی شده، با روش‌های موجود قابل رقابت بوده و قابلیت معرفی تحت عنوان یک الگوریتم ترکیبی جدید را دارد.

نتیجه‌گیری

با به‌کارگیری یک الگوریتم یادگیری مناسب می‌توان از مهم‌ترین ضعف‌های مدل FCM که وابستگی به نظر کارشناسان و پتانسیل همگرایی به نقاط نامطلوب است، جلوگیری کرد. در

- Fuzzy Systems: Applications in Engineering and Technology, vol. 8, no. 2, pp. 83-98, 2000.
- [17] E. I. Papageorgiou, P. P. Spyridonos, D. T. Glotsos, C. D. Stylios, P. Ravazoula, G. N. Nikiforidis, and P. P. Groumpos, "Brain tumor characterization using the soft computing technique of fuzzy cognitive maps," *Applied Soft Computing*, vol. 8, no. 1, pp. 820-828, 2008.
- [18] C. T. Lin and C. S. G. Lee, *Neural Fuzzy Systems: A Neuro-Fuzzy Synergism to Intelligent Systems*, Upper Saddle River, Prentice-Hall, 1996.
- [19] C. D. Stylios, P. P. Groumpos, and V. C. Georgopoulos, "A fuzzy cognitive approach to process control systems," *Journal of Advanced Computational Intelligence and Intelligent Informatics*, vol. 3, no. 5, pp. 409-417, 1999.
- [20] E. I. Papageorgiou, "Learning algorithms for fuzzy cognitive maps- A review study," *IEEE Transactions on Systems, Man, and Cybernetics- Part C: Applications and Reviews*, vol. 42, no. 2, pp. 150-163, 2012.
- [21] E. I. Papageorgiou and P. P. Groumpos, "A new hybrid method using evolutionary algorithms to train fuzzy cognitive maps," *Applied Soft Computing*, vol. 5, no. 4, pp. 409-431, 2005.
- [22] Z. Yanchun and Z. Wei, "An integrated framework for learning fuzzy cognitive map using RCGA and NHL algorithm," 4th International Conference on Wireless Communications, Networking and Mobile Computing, Dalian, China, pp. 1-5, 2008.
- [23] Z. Peng, L. Wu, and Z. Chen, "NHL and RCGA based multi-relational fuzzy cognitive map modeling for complex systems," *Applied Sciences*, vol. 5, no. 4, pp. 1399-1411, 2015.
- [24] W. Stach, L. Kurgan, W. Pedrycz, and M. Reformat, "Genetic learning of fuzzy cognitive maps," *Fuzzy Sets and Systems*, vol. 153, no. 3, pp. 371-401, 2005.
- [25] C. D. Stylios, P. P. Groumpos, and V. C. Georgopoulos, "An fuzzy cognitive maps approach to process control systems," *Journal of Advanced Computational Intelligence*, vol. 3, no. 5, pp. 409-417, 1999.
- IFAC World Congress of International Federation of Automatic Control, Barcelona, Spain, pp. 1-6, 2002.
- [9] J. Aguilar, "Adaptive random fuzzy cognitive maps," in *Adaptive Random Fuzzy Cognitive Maps*, F. J. Garijio, J. C. Riquelme, and M. Toro, Eds. Berlin, Germany: Springer, pp. 402-410, 2002.
- [10] E. I. Papageorgiou, C. D. Stylios, and P. P. Groumpos, "Fuzzy cognitive map learning based on nonlinear Hebbian rule," in *AI 2003: Advances in Artificial Intelligence*, T. D. Gedeon and L. C. C. Fung, Eds. Berlin, Germany: Springer, pp. 254-266, 2003.
- [11] E. I. Papageorgiou, K. E. Parsopoulos, P. P. Groumpos, and M. N. Vrahatis, "Fuzzy cognitive maps learning through swarm intelligence," in *Artificial Intelligence and Soft Computing- ICAISC 2004*, L. Rutkowski, J. H. Siekmann, R. Tadeusiewicz, and L. A. Zadeh, Eds. Berlin, Germany: Springer, pp. 344-349, 2004.
- [12] D. E. Koulouriotis, I. E. Diakoulakis, and D. M. Emiris, "Learning fuzzy cognitive maps using evolution strategies: A novel schema for modeling a simulating high-level behavior," *Proceedings of IEEE Congress on Evolutionary Computation*, Seoul, Korea, pp. 364-371, 2001.
- [13] E. I. Papageorgiou and C. D. Stylios, "Fuzzy cognitive maps," in *Handbook of Granular Computing*, W. Pedrycz, A. Skowron, and V. Kreinovich, Eds. Hoboken, John Wiley & Sons, pp. 756-774, 2008.
- [14] Y. Chen, L. J. Mazlack, A. A. Minai, and L. J. Lu, "Inferring casual networks using fuzzy cognitive maps and evolutionary algorithms with application to gene regulatory network reconstruction," *Applied Soft Computing*, vol. 37, pp. 667-679, 2015.
- [15] S. Bueno and J. Salmeron, "Benchmarking main activation functions in fuzzy cognitive maps," *Expert Systems with Applications*, vol. 36, no. 3, pp. 5221-5229, 2009.
- [16] C. D. Stylios and P. P. Groumpos, "Fuzzy cognitive maps in modeling supervisory control systems," *Journal of Intelligent &*