



نقش روش‌های ابتکاری با طول متغیر در طراحی و آموزش بهینه شبکه‌های ANFIS

امیر سلطانی محبوب* و سید حمید ظهیری ممقانی

گروه الکترونیک، دانشکده مهندسی برق و کامپیوتر، دانشگاه بیرجند، بیرجند، ایران

چکیده

سامانه‌های ANFIS به دلیل عملکرد قابل قبولی که در زمینه ایجاد و آموزش طبقه‌بند فازی داده دارند، بسیار مورد توجه واقع شده‌اند. یک چالش اصلی در طراحی یک سامانه ANFIS رسیدن به یک روش کارآمد، با دقت بالا و قابلیت تفسیر مناسب است. بدون تردید نوع و مکان توابع عضویت و همچنین نحوه آموزش یک شبکه ANFIS تأثیر به‌سزایی در عملکرد آن دارد. تاکنون پژوهش‌های مرتبط تنها به یافتن نوع و مکان توابع عضویت و یا پیشنهاد روشی برای آموزش این شبکه‌ها بسنده کرده‌اند. علت اصلی عدم به‌کارگیری هم‌زمان تعیین نوع و مکان توابع عضویت و آموزش یک شبکه ANFIS در ثابت بودن طول نسخه‌های استاندارد روش‌های ابتکاری است. در این مقاله، ابتدا نسخه جدیدی از روش بهینه‌سازی صفحات شیب‌دار با قابلیت متغیر بودن عوامل جستجو در آن، معرفی می‌شود؛ سپس قابلیت به‌وجود آمده، برای تعیین نوع و مکان توابع عضویت و آموزش هم‌زمان یک طبقه‌بند مبتنی بر سامانه استنتاج عصبی-فازی تطبیقی به‌کار بسته می‌شود. نتایج بر روی چند پایگاه داده مشهور با تعداد رده‌های مرجع متفاوت و طول بردارهای ویژگی مختلف مورد آزمایش قرار گرفته و با نتایج روش پیشنهادی به‌صورت مقایسه‌ای گزارش شده است، این آزمایشات نشان‌دهنده عملکرد بهتر روش پیشنهادی است.

واژگان کلیدی: بازشناسی الگو، طبقه‌بندی، سامانه استنتاج عصبی - فازی تطبیقی، بهینه‌ساز صفحات شیب‌دار با طول متغیر

Role of Heuristic Methods with variable Lengths In ANFIS Networks Optimum Design and Training

Amir Soltany Mahboob* & Seyed Hamid Zahiri Mamaghani

Faculty of Electrical and Computer Engineering, University of Birjand, Birjand, Iran

Abstract

ANFIS systems have been much considered due to their acceptable performance in terms of creation of fuzzy classifier and training. One main challenge in designing an ANFIS system is to achieve an efficient method with high accuracy and appropriate interpreting capability. Undoubtedly, type and location of membership functions and the way an ANFIS network is trained are of considerable effect on its performance. Up to present time, related researches have just found type and location of membership functions, and or suggested methods to train these networks. Main reason for lack of simultaneous determination of type and location of membership functions and training an ANFIS network is the length of standard versions of Heuristic methods being fixed. In this paper, a new version of optimization method of inclined planes will be introduced, primarily, while search factors could be variable. Then, achieved capability will be used for specifying type and location of membership functions and simultaneous training of a classifier based on adaptive neuro-fuzzy inference system (ANFIS). The proposed method on five benchmark datasets iris, Breast Cancer, Bupa Liver, Wine and Pima from the UCI database has been tested, which has different number of reference classes, different length of attribute vectors with appropriate complexity. Initially, the accuracy of the test dataset for each of the selected datasets was compared using the standard 10 folded cross validation method using the

* Corresponding author

*نویسنده عهده‌دار مکاتبات

سال ۱۳۹۸ شماره ۴ پیاپی ۴۲

● تاریخ ارسال: ۹۶/۱۱/۱۸ ● تاریخ پذیرش: ۹۷/۱۱/۰۶ ● تاریخ انتشار: ۹۸/۱۲/۲۸

فصل ۱



۱۱۳

standardized version of the standard length. Then the same experiments were repeated by the proposed method and the results of applying the proposed method on the five aforementioned datasets were compared with the results of the heuristic methods with the standard length version. The comparative results show that the optimal and intelligent design of ANFIS classifier by variable length heuristics on five well-known datasets yields good and satisfactory results and in each of the five problems it has provided better answers than other design methods in the ANFIS classification system.

Keywords: Pattern Recognition, Classifier, adaptive neuro fuzzy inference system, variable Length Inclined Planes System Optimization algorithm

مختلفی برای ایجاد طبقه‌بند فازی پیشنهاد شده است، ساختار طبقه‌بند از روی داده‌هایی با برجسب رده مشخص طراحی می‌شود. در روش‌های پیشنهادی برای طراحی رده‌بند فازی روش‌های هوشمندی نظر الگوریتم ژنتیک، بهینه‌ساز گروه ذرات، الگوریتم کلونی مورچگان و ... به چشم می‌خورد [4-13].

از ترکیب موفقیت‌آمیز شبکه عصبی، منطق فازی و محاسبات تکاملی مدل جدیدی به نام ANFIS [14] به وجود آمده است. در واقع این مدل یک سامانه ترکیبی است که در آن هم از توانایی تصمیم‌گیری منطق فازی و هم قابلیت یادگیری شبکه عصبی استفاده شده، به همین دلیل ANFIS در زمینه آموزش، ایجاد و طبقه‌بند فازی دارای توانایی مناسبی است. این مدل شامل قسمت‌هایی از سامانه فازی است که محاسبات در هر گام به وسیله نرون‌های لایه پنهان و قدرت یادگیری شبکه عصبی تولید می‌شود تا باعث افزایش دانش سامانه شود. پارامترهای توابع عضویت این سامانه، در فرآیند روش آموزش ANFIS تنظیم می‌شود. این عملیات تنظیم به سامانه فازی اجازه می‌دهد تا ساختار خود را از مجموعه داده‌ها فراگیرد. اگرچه می‌توان پارامترهای مربوط به تابع عضویت را به صورت دلخواه تعیین کرد، اما باید توجه داشت که انتخاب مناسب این پارامترها تأثیر به‌سزایی در عملکرد سامانه ANFIS خواهد داشت؛ از این رو، شیوه‌های متفاوتی برای یافتن مقادیر بهینه پارامترهای یادشده و روش آموزش آن به منظور رسیدن به بهترین عملکرد سامانه‌های فازی - عصبی پیشنهاد شده است [15].

طراحی یک طبقه‌بند ANFIS شامل یافتن پارامترهای ساختاری جهت رسیدن به عملکرد مطلوب و مناسب است. که در همین اواخر در طراحی این سامانه‌ها برای یافتن این پارامترهای ساختاری از روش‌های تکاملی استفاده می‌شود.

زنگنه و همکاران [16] از الگوریتم تکاملی تفاضلی (DE) به جهت آموزش ANFIS، ناصری و همکاران [17] از الگوریتم ژنتیک (GA) برای آموزش ANFIS به جهت استخراج سیگنال الکتروکاردیوگرام جنین، سارخیلی و همکاران [18] از

۱- مقدمه

در طراحی یک سامانه بازشناسی الگو باید مراحل مختلفی شامل اخذ داده، عملیات پیش‌پردازش، استخراج ویژگی، استفاده از یک طبقه‌بند و بررسی خطای عملکرد سامانه موردنظر قرار گیرد، اگرچه هر یک از مراحل یادشده اثر مستقیمی بر میزان خطای سامانه به‌هنگام با یک الگوی ناشناس دارد، اما انتخاب نوع طبقه‌بند از اهمیت مضاعفی برخوردار است؛ زیرا عمل قیاس الگوی ناشناس با رده‌های مرجع در این مرحله انجام و همچنین مرحله پاسخ نهایی سامانه به ورودی ناشناس ارائه می‌شود. در سامانه‌های بازشناسی الگو طبقه‌بندهای گوناگونی مطرح شده است که از میان آن‌ها می‌توان به طبقه‌بند k نزدیک‌ترین همسایه، بیز، شبکه عصبی و فازی اشاره کرد. در کنار این طبقه‌بندها انواع دیگری بر اساس روش‌های هوش جمعی و تکاملی پیشنهادشده است [3]-[2]-[1].

طبقه‌بند بیز، یک طبقه‌بند بهینه است؛ اما نیاز به پیش‌فرض‌هایی در خصوص توابع چگالی توزیع احتمال الگوها در فضای ویژگی دارد که اغلب در دسترس نیستند.

طبقه‌بند k نزدیک‌ترین همسایه دارای ساختاری ساده و عملکرد به‌نسبه خوب است، اما با افزایش ابعاد ویژگی هزینه محاسباتی آن بیشتر شده، پاسخ سامانه با تأخیر زیاد مواجه می‌شود؛ ضمن آن‌که مقدار k نیز تأثیر به‌سزایی در نتایج به‌دست‌آمده از عملکرد سامانه دارد.

طبقه‌بندهای شبکه عصبی نیز عملکرد خوبی دارند، اما در فضای ویژگی با ابعاد زیاد ناگزیر دچار پیچیدگی ساختار می‌شوند. در این میان محدودیت وابستگی عملکرد این طبقه‌بندها را به ساختار و نوع شبکه عصبی نیز نباید از نظر دور داشت.

طبقه‌بندهای فازی ساختاری ساده و عملکرد مناسبی از خود نشان داده‌اند؛ برخی پارامترهای ساختاری، نظیر شکل و مکان توابع عضویت، نوع عملگرهای فازی استفاده‌شده، تعداد قواعد فازی و تعداد متغیرهای فازی به‌کار گرفته‌شده در مقدمات بر عملکرد طبقه‌بند تأثیرگذار است؛ روش‌های

درحقیقت یکی از جنبه‌های نوآوری تحقیق حاضر ضمن معرفی الگوریتم بهینه‌ساز صفحات شیب‌دار (IPO) [25] به‌عنوان یکی از جدیدترین روش‌های ابتکاری، یک نسخه جدید از این الگوریتم با طول متغیر به‌نام VLIPPO معرفی می‌شود و استفاده از روش‌های ابتکاری با طول متغیر در طبقه‌بند ANFIS بررسی شده است و همچنین یکی دیگر از جنبه‌های نوآوری این پژوهش تعیین بهترین نوع توابع عضویت با توجه به تعداد ورودی‌های ANFIS و آموزش هم‌زمان آن با استفاده از روش‌های ابتکاری با طول متغیر است و نکته قابل توجه دیگر این است که توانایی الگوریتم IPO در آموزش طبقه‌بند ANFIS نیز بررسی شده است.

روش پیشنهادی، برای ارزیابی و مقایسه بهتر توسط دیگر الگوریتم‌های [26] PSO، [27-28] GA، [29] DE و [30] ACOR پیاده‌سازی و بررسی شده و سپس برای ارزیابی نتایج روش پیشنهادی توسط اعمال طبقه‌بند ANFIS بر پنج مجموعه داده‌های محک گل زنبق، مجموعه داده‌های سرطان سینه، داده‌های Pima، داده‌های Bupa Liver و داده‌های Wine از مخزن پایگاه داده (UCI) انجام گرفته و نتایج به‌صورت مقایسه‌ای با یک طبقه‌بند ANFIS ساده، فقط به جهت آموزش آن با روش‌های هوشمند یادشده ترکیب و گزارش شده است. سازمان‌دهی کلی مقاله به‌صورت زیر است: در بخش ۲ به معرفی سامانه استنتاج فازی - عصبی تطبیقی (ANFIS) و الگوریتم بهینه‌ساز صفحات شیب‌دار پرداخته، در بخش ۳ الگوریتم VLIPPO معرفی و نحوه استفاده از آن برای انتخاب نوع و مکان‌یابی توابع عضویت و آموزش هم‌زمان در طبقه‌بند پیشنهادی توصیف، در بخش ۴ عملکرد روش پیشنهادی ارزیابی و در نهایت در بخش ۵ نتیجه‌گیری بیان می‌شود.

۲- سامانه استنتاج فازی-عصبی تطبیقی (ANFIS)

سامانه استنتاج فازی-عصبی تطبیقی (ANFIS) توسط Jang در سال ۱۹۹۳ معرفی شد. ANFIS یک روش فازی-عصبی هیبریدی است که عنوان سامانه استنتاج فازی برای تصمیم‌گیری از متغیرهای زبانی و قواعد آسان برای درک و فهم مفید برای یادگیری دارد و علاوه بر آن از توانایی یادگیری شبکه عصبی نیز برخوردار است. پارامترهای این شبکه، پارامترهای اگر - آنگاه فازی یعنی بخش مقدم (توابع عضویت) و پارامترهای بخش تعالی قواعد فازی سوگنو هستند.

یک نسخه جدید الگوریتم ژنتیک اصلاح‌شده (MGA) به جهت آموزش ANFIS استفاده کرده‌اند و برای نشان دادن قدرت و پویایی روش آموزش پیشنهادی، پیش‌بینی عملکرد فرآیند ماشین‌کاری را موردبررسی قرار داده‌اند. رایینی و همکاران [19] از الگوریتم گروه ذرات (PSO) به جهت دقت و تفسیرپذیری ANFIS استفاده کرده‌اند، منظور از تفسیرپذیری، پیدا کردن قوانین درست و بهینه است و برای بالا بردن دقت از روش PSO به جهت آموزش ANFIS، کارباگا و همکاران [20] از الگوریتم کلونی زنبور هیبریدی به جهت آموزش ANFIS، تانگاول و همکاران [21] از الگوریتم کلونی مورچگان برای آموزش ANFIS به جهت طبقه‌بندی تصاویر ماموگرافی، فاسمی و همکاران [22] از ترکیب ANFIS با الگوریتم بهینه‌ساز گروه ذرات (PSO) به جهت پیش‌بینی سرعت حرکات ذرات در انفجار معادن استفاده کرده‌اند، درحقیقت، الگوریتم PSO به جهت آموزش یا تعیین بهینه پارامترهای ANFIS استفاده شده است. مارزی و همکاران [23] از یک نسخه پیشرفته الگوریتم کلونی زنبور و تخمین کمترین مربعات برای آموزش ANFIS استفاده، تانگاول و همکاران [24] در یک مطالعه مروری، شیوه آموزش ANFIS توسط روش‌های ابتکاری و روش‌های کلاسیک ترکیبی مربعات خطا و گرادیان نزولی و میزان تأثیرگذاری این روش‌های بر ANFIS بررسی کرده‌اند.


پژوهش‌های بسیار زیادی در این حوزه انجام شده است [34,35]. در تمامی مراجع یادشده ضمن معرفی یک الگوریتم ابتکاری جدید از آن به جهت یافتن بهترین پارامترهای ساختاری ANFIS یا روش آموزش آن استفاده شده است و نکته مهم و قابل توجه دیگر این است که در همه موارد یک نوع تابع عضویت ثابت که به‌طور معمول گوسی است در فرآیند آموزش ANFIS به کار گرفته شده است.

در این مقاله، یک روش جدید مبتنی بر الگوریتم‌های ابتکاری به جهت انتخاب و مکان‌یابی بهینه توابع عضویت مختلف با توجه به تعداد ویژگی‌های ورودی ANFIS و آموزش به‌طور هم‌زمان، به منظور رسیدن به دقت بالا و رسیدن به قابلیت تفسیرپذیری مناسب یا درحقیقت کاهش پیچیدگی سامانه طبقه‌بند ANFIS پیشنهاد شده است. برای دست‌یابی به این منظور در ابتدا یک نسخه جدید از الگوریتم بهینه‌ساز صفحات شیب‌دار با طول متغیر^۱ VLIPPO [25] معرفی می‌شود و سپس نحوه اجرای و پیاده‌سازی روش پیشنهادی با VLIPPO بیان می‌شود.

^۱ الگوریتم صفحات شیب‌دار با طول متغیر (Inclined Planes System Optimization algorithm Variable Length)


پارامترهای سامانه فازی به عنوان وزن های شبکه عصبی در نظر گرفته و در طی فرآیند آموزش تنظیم می شوند [31]-[14]. برای ارائه ساختار شبکه ANFIS، دو قاعده فازی بر مبنای مدل مرتبه نخست (sugeno) (اگر-آنگاه) به صورت زیر در نظر گرفته شده است:

قاعده ۱: اگر $(x \text{ آنگاه } B_1)$ و $(x \text{ آنگاه } A_1)$ $(f_1 = p_1x + q_1y + r_1)$
 قاعده ۲: اگر $(x \text{ آنگاه } B_2)$ و $(x \text{ آنگاه } A_2)$ $(f_2 = p_2x + q_2y + r_2)$
 x و y ورودی ها، (A_i) و (B_i) مجموعه فازی، (f_i) خروجی ها با ناحیه فازی مشخص شده با قواعد فازی، (p_i) ، (q_i) ، (r_i) پارامترهای طراحی شبکه که در طول چرخه آموزش تخمین زده می شوند. ساختار کلی این دو قاعده در شکل های (۱) و (۲) نشان داده شده است.



(شکل-۱): ساختار [14] ANFIS

(Figure-1): ANFIS Structure [14]



(شکل-۲): منطق فازی ANFIS [14]

(Figure-2): ANFIS Fuzzy Logic [14]

در لایه نخست، همه گره ها، نوع تطبیقی است. خروجی لایه یک، درجه عضویت ورودی ها است که به صورت زیر بیان شده است:

$$O_i^1 = m_{A_i}(x) \quad i = 1, 2 \quad (1)$$

$$O_i^1 = m_{B_{i-2}}(y) \quad i = 3, 4 \quad (2)$$

$m_{A_i}(x)$ و $m_{B_{i-2}}(y)$ می توانند با هر نوع تابعیت عضویت فازی در نظر گرفته شوند. اگر تابع عضویت زنگی شکل را در نظر بگیریم، می توان $m_{A_i}(x)$ را به صورت زیر در نظر گرفت:

$$m_{A_i}(x) = \frac{1}{1 + \left| \frac{x - c_i}{a_i} \right|^{2hi}} \quad (3)$$

a_i و b_i پارامترهای توابع عضویت هستند.

در لایه دوم، گره ها ثابت هستند. عملکرد این گره ها به صورت عملگر ضرب ساده است. خروجی این لایه ها به صورت زیر به دست می آید:

$$O_i^2 = w_i = m_{A_i}(x)m_{B_i}(y) \quad (4)$$

در لایه سوم، گره ها باز هم ثابت هستند و برای نرمالیزه کردن خروجی لایه های قبلی استفاده می شوند:


$$O_i^3 = \bar{w}_i = \frac{w_i}{w_1 + w_2} \quad i = 1, 2 \quad (5)$$

در لایه چهارم، گره ها به صورت انطباقی است. خروجی آن ضرب ساده وزن های نرمالیزه شده در چند جمله ای مرتبه نخست مدل Sugeno است:

$$O_i^4 = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i) \quad i = 1, 2 \quad (6)$$

۲-۱- معرفی الگوریتم بهینه ساز صفحات شیب دار (IPO)

الگوریتم بهینه سازی صفحات شیب دار (IPO)، الگوریتمی برگرفته از چگونگی حرکت دینامیکی اجسام کروی بر روی سطح شیب دار بدون اصطکاک است، که همگی تمایل رسیدن به پایین ترین نقطه از سطح را دارند.



(شکل-۳): نمونه ای از فضای جستجوی الگوریتم IPO [25]

(Figure-3): A sample of algorithm search space IPO [25]

در فضای جستجو در روش IPO، تعدادی توپ کوچک برای پیدا کردن نقطه بهینه (کمینه) بروی سطح شیب دار در حرکت هستند (شکل ۳). این توپ های کوچک در IPO عامل های جستجو هستند؛ مانند ذرات در الگوریتم بهینه سازی اجتماع ذرات (PSO). ایده اصلی الگوریتم IPO نسبت دادن ارتفاع، نسبت به یک نقطه مرجع به هر توپ است که میزان این ارتفاع بر اساس تابع برازندگی به دست می آید. این مقادیر ارتفاع، در واقع تخمینی هستند، برای انرژی پتانسیل توپ ها که در ارتفاعات مختلفی قرار دارند و با پایین آمدن آن ها، این انرژی به انرژی جنبشی تبدیل و سبب شتاب گرفتن توپ ها به سمت پایین می شوند. در واقع توپ ها تمایل دارند تا انرژی پتانسیل خود را برای رسیدن به نقطه حداقل از دست بدهند؛ لذا توپ ها به صورت مکرر در فضای جستجو برای یافتن پاسخ مطلوب تر حرکت کرده و به تناسب شتابی را به خود اختصاص می دهد. هر توپ در فضای جستجو دارای سه مختصات است:

$$x_i^d(t+1) = k1.rand1.a_i^d(t).\Delta t^2 + \quad (12)$$

$$k2.rand2.v_i^d(t) + x_i^d(t) \quad (13)$$

$$k_1(t) = \frac{c_1}{1+\exp((t-shift_1) \times scale_1)}$$

$$k_2(t) = \frac{c_2}{1+\exp((t-shift_2) \times scale_2)} \quad (14)$$

در فرمول شماره (۱۲) rand1 و rand2 ضرایب وزنی به صورت تصادفی در بازه [0,1] هستند تا به الگوریتم خاصیت تصادفی داده شود و در فرمول‌های (۱۳) و (۱۴) مقادیر $c_1, c_2, shift_1, shift_2, scale_1$ و $scale_2$ ثوابتی هستند که برای هر تابع به صورت تجربی به دست می‌آیند. مقدار $v_i^d(t)$ سرعت توپ نام در بُعد d و در زمان t است و به صورت زیر تعریف می‌شود:

$$v_i^d(t) = \frac{x_{best}^d(t) - x_i^d(t)}{\Delta t} \quad (15)$$

x_{best} توپی است که بهترین برازندگی را در کل تکرارها دارد و برای این که میل رسیدن به بهترین مقدار را دارند، در صورت کسر قرار گرفته است.

شبه کد الگوریتم IPO:

الف) تولید جمعیت اولیه به صورت تصادفی، مقادیر $K1, K2$ و دیگر پارامترها

ب) تکرار اجرای الگوریتم

پ) ارزیابی برازندگی (ارتفاع) هر توپ

ت) محاسبه زاویه، شتاب و سرعت هر توپ

ث) به روزرسانی موقعیت هر توپ

ج) محاسبه و تعیین مقادیر $k1, K2$

چ) بازگرداندن توپ‌هایی که از بازه فضای جستجو خارج

شده‌اند، به داخل فضای جستجو

ح) پایان، در صورت مشاهده شرط توقف

۳- معرفی الگوریتم بهینه‌ساز صفحات شیب‌دار با طول متغیر (VLIPO) و نحوه استفاده از آن در انتخاب نوع و مکان‌یابی توابع عضویت و آموزش یک طبقه‌بند (ANFIS)

در این بخش در ابتدا نحوه بیان یک پروب در روش پیشنهادی بیان و سپس نسخه جدید الگوریتم بهینه‌ساز صفحات شیب‌دار با طول متغیر (VLIPO) معرفی و روش پیشنهادی با VLIPO توصیف و در ادامه نحوه آموزش یک طبقه ساده ANFIS با روش‌های ابتکاری بیان شده است.

موقعیت، ارتفاع و زاویه‌ای که با دیگر توپ‌ها می‌سازد. موقعیت هر توپ یک جواب در فضای جستجو و ارتفاع آن به وسیله تابع برازندگی به دست می‌آید. برای داشتن تخمینی از صفحه شیب‌دار که توپ‌ها بر روی آن قرار دارند از خطوطی مستقیم استفاده می‌شوند که مراکز توپ‌ها را به هم وصل می‌کنند؛ این خطوط با خط راست افقی عبوری از مرکز توپ، زاویه‌ای را تشکیل می‌دهند که به وسیله آن و میزان شتاب اختصاص یافته به هر توپ تعیین شود. سامانه‌ای با N توپ را در نظر بگیرید، موقعیت توپ نام به وسیله فرمول زیر تعریف می‌شود:

$$x_i^{\rightarrow} = (x_i^1, \dots, x_i^d, \dots, x_i^n) \quad i = 1, 2, \dots, N \quad (7)$$

$$x_j^{\min} < x_j < x_j^{\max}, \quad 1 < j < n$$

به طوری که، x_i^d موقعیت توپ نام در بُعد d در فضای n بعدی است. هدف پیدا کردن موقعیت $f(x_i^{\rightarrow})$ کمینه تابع هدف است که بر روی فضای جستجو تعریف شده است. در یک زمان مشخص مانند t ، زاویه بین توپ نام و توپ نام در بُعد d یعنی ϕ_{ij}^d به صورت زیر حساب می‌شود:

$$\phi_{ij}^d = \tan^{-1} \left(\frac{f_i(t) - f_j(t)}{x_i^d - x_j^d} \right), \quad d = 1, 2, \dots, n \quad (8)$$

$$i, j = 1, 2, \dots, N \quad i \neq j$$

به گونه‌ای که $f_i(t)$ مقدار تابع هدف (ارتفاع) برای توپ نام در زمان t است. بنابر تجربه و آزمایش و برای کاهش حجم محاسباتی، جهت رسیدن به جواب‌های بهتر، شتاب هر توپ در هر بعد به صورت جداگانه از دیگر ابعاد محاسبه می‌شود. برای اینکه توپ‌ها به سمت پایین سرازیر شوند، در محاسبه شتاب آن‌ها، توپ‌هایی که در ارتفاع پایین‌تر قرار دارند در نظر گرفته می‌شوند. طبق قانون دوم نیوتن داریم:

$$\Sigma \vec{f} = m \cdot \vec{a} \quad (9)$$

برای شتاب هم داریم:

$$a = g \cdot \sin(\emptyset) \quad (10)$$

که در آن g ثابت گرانش زمین است. در الگوریتم IPO با اعمال یک سری تغییرات، شتاب توپ نام در زمان t نام در بُعد d به صورت زیر محاسبه می‌شود:

$$a_i^d(t) = \sum_{j=1}^N U(f_j(t) - f_i(t)) \cdot \sin(\phi_{ij}^d(t)) \quad (11)$$

به طوری که U تابع پله واحد است. در هر تکرار الگوریتم برای به روز شدن و تعیین موقعیت جدید هر توپ پس از محاسبه شتاب آن از فرمول (۱۱) و این نکته که حرکت از نوع حرکت با شتاب ثابت است، می‌توان از فرمول موقعیت به صورت زیر استفاده کرد که در آن ضرایب $k1, k2$ ضرایب متغیر با زمان برای کنترل بهتر عملکرد IPO است.

۲-۳- نحوه بیان پروب

در طبقه‌بند پیشنهادی هدف پیدا کردن بهترین نوع توابع عضویت و آموزش هم‌زمان آن است، برای رسید به این اهداف قبل از اینکه وارد مرحله اصلی فرآیند بهینه‌سازی توسط روش‌های ابتکاری با طول متغیر شویم باید پروب توابع عضویت به همراه پارامترهای سامانه فازی پایه شکل بگیرد. در روش پیشنهادی، با توجه به ویژگی‌های پایگاه داده مورد نظر و سامانه ANFIS، به‌طور کلی می‌توان یک حالت را در نظر گرفت؛ برای مثال برای مجموعه داده Iris که دارای چهار ویژگی با تعداد سه رده است، سامانه ANFIS بر اساس ویژگی‌های مجموعه داده Iris دارای چهار تا ورودی خواهد بود که هر کدام از این ورودی‌ها بر اساس تعداد رده پایگاه داده Iris دارای سه تابع عضویت است، پس برای همه ورودی‌ها از $X1$ تا $X4$ یک نوع تابع عضویت توسط روش ابتکاری با طول متغیر مشخص و به‌طور هم‌زمان آموزش داده می‌شود که در این صورت تعداد متغیرهای پروب توسط فرمول زیر بیان می‌شود:

$$NOF + Output Paramter \quad (21)$$

NOF: Number of feature (تعداد ویژگی‌های پایگاه داده مورد نظر است).

Output Paramter: پارامترهای خروجی سامانه فازی ما هستند که بر اساس:

$$z_i = p_i x + q_i y + r_i \quad (22)$$

(p_i, q_i, r_i) مرتبط با چندجمله‌ای مرتبه نخست Sugeno مشخص است و در شکل (۴)، پروب برای مجموعه داده Iris به‌صورت کلی توصیف شده است که در آن $X1$ تا $X4$ تعداد ویژگی‌های داده Iris است، پارامترهای توابع عضویت ویژگی داده Iris و پارامترهای خروجی سامانه فازی پایه برای مجموعه داده Iris نشان داده شده و شکل (۵) برای درک بهتر یک پروب برای ویژگی‌های $X1$ تا $X4$ نشان داده شده است که در این شکل هر کدام از توابع عضویت با یک شماره شاخص مشخص شده‌اند، برای مثال شماره شاخص یک معرف تابع Gauss MF است و به همین ترتیب برای دیگر توابع عضویت به کار گرفته شده هر کدام دارای یک شماره شاخص هستند و در قسمت بعدی برای مشخص کردن پارامترهای هر کدام از این توابع عضویت، این پارامترها به ترتیب شماره شاخص انتخاب شده قرار می‌گیرند و در قسمت بعدی مقادیر پارامترهای سامانه فازی خروجی که در قسمت نحوه بیان پروب توصیف شده‌اند، قرار می‌گیرند و به‌صورت کلی برای پایگاه داده‌ای با n ویژگی نحوه بیان پروب به‌صورت شکل (۶) خواهد بود.

در استفاده از روش‌های بهینه‌سازی با طول متغیر، برای انتخاب نوع و مکان توابع عضویت و روش آموزش هم‌زمان آن موضوع قابل توجه تعریف تابع ارزیابی است که روش بهینه‌سازی مورد استفاده، مقدار بهینه آن (بیشینه یا کمینه) را می‌یابد. درواقع، اهمیت تابع ارزیابی از این جهت است که مسیر جستجو را هدایت می‌کند.

۱-۳- تعریف تابع ارزیابی

در طبقه‌بند مورد نظر هدف رسیدن به کمترین خطای طبقه‌بندی و بیشترین قابلیت تفسیرپذیری است. این اهداف در این مقاله، با تشخیص نرخ صحیح داده آموزشی به جهت انتخاب بهترین نوع توابع عضویت و تنظیم پارامترهای سامانه فازی پایه برای آموزش هم‌زمان آن با توجه به تابع خطای مدل‌سازی، توسط الگوریتم‌های بهینه‌سازی صورت می‌گیرد که به‌صورت ریاضی مدل می‌شود:

$$\min_{\theta} Error = \frac{1}{N} \sum_{i=1}^n e_i^2 \quad (16)$$

$$e_i = t_i - f(x_i | \theta) \quad (17)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (t_i - y_i)^2} \quad (18)$$

N : تعداد نمونه‌های ورودی سامانه و جهت نرمالیزه کردن

e_i : مقدار خطاهای سامانه

x_i : مقدار داده‌های ورودی

θ : پارامترهای قابل تنظیم سامانه استنتاج عصبی-فازی

تطبیقی به‌ازای ورودی‌های مختلف x_i

m : تعداد نمونه‌های آموزشی

t_i : مقدار داده هدف

y_i : مقدار خروجی واقعی سامانه به‌ازای داده‌های آموزشی

و به‌طور کلی تابع ارزیابی به‌صورت معادله زیر بیان می‌شود:

$$Fitness = \min Error(\theta) \text{ and } RMSE \quad (19)$$

$$\theta = (\theta_1, \theta_2, \dots, \theta_n) \quad (20)$$

از آنجایی که، الگوریتم‌های DE، GA، PSO، IPO و ACOR توانایی یافتن کمینه تابع هدف را دارند تابع ارزیابی رابطه (۱۹) خواهد بود.

قبل از توضیح روش VLIPPO و نحوه پیاده‌سازی آن برای آموزش، انتخاب و مکان‌یابی توابع عضویت در طبقه‌بند ANFIS، در ابتدا باید به نحوه شکل‌گیری یک پروب شامل توابع عضویت از روی پایگاه داده مورد نظر به همراه پارامترهای قابل تنظیم سامانه فازی پایه برای فرآیند آموزش بپردازیم.

X1	X2	X3	X4	پارامترهای توابع عضویت	پارامترهای خروجی سیستم فازی
----	----	----	----	------------------------	-----------------------------

(شکل-۴): شکل کلی پروب در برای مجموعه داده Iris

(Figure-4): Overall probe shape for Iris dataset

1,...,7	1,...,7	1,...,7	...	1,...,7	σ	c	...	a	b	c	d	p_i	q_i	...	r_i
شماره شاخص توابع عضویت				پارامترهای توابع به ترتیب شماره شاخص آنها				پارامترهای خروجی سیستم فازی							

(شکل-۵): شکل کلی یک پروب از X1 تا Xn

(Figure-5): Overall shape of a probe from X1 to Xn

X1	X2	X3	X4	...	Xn	پارامترهای توابع عضویت به ترتیب شماره شاخص آنها	پارامترهای خروجی سیستم فازی
----	----	----	----	-----	----	---	-----------------------------

(شکل-۶): شکل کلی پروب برای پایگاه داده‌ای با n ویژگی

(Figure-6): Overall shape of a probe for those databases with n specifications

چ) بازگرداندن توپ‌هایی که از بازه فضای جستجو خارج شده‌اند، به داخل فضای جستجو

ح) پایان، در صورت مشاهده شرط توقف

در قسمت توضیحات ساختار کلی یک توپ با توجه به ویژگی‌های پایگاه داد موردنظر به صورت شکل (۷) خواهد بود؛ که در قسمت اولیه با توجه به توضیحات قبلی شماره شاخص توابع عضویت قرار می‌گیرند و در قسمت بعدی با توجه به ترتیب قرارگیری شماره شاخص نوع توابع عضویت، پارامترهای توابع عضویت قرار می‌گیرند و در انتها هم پارامترهای خروجی سامانه فازی جهت آموزش همزمان قرار می‌گیرند.

در الگوریتم IPO پس از تولید جمعیت اولیه به صورت تصادفی، تکرار اجرای الگوریتم و ارزیابی برازندگی (ارتفاع) یک توپ به عنوان مثال با توجه به روند الگوریتم ساختار کلی دو تا توپ ۱ ام و ۲ ام به صورت شکل (۸) و (۹) خواهد بود (البته به طور مثال برای ویژگی‌های مجموعه داده Iris از X1 تا Xn). همان طور که از شکل (۸) و (۹) مشخص است در قسمت شماره شاخص توابع عضویت از X1 تا X4 برای هر توپ یک نوع تابع عضویت در نظر گرفته شده است و به دلیل متفاوت بودن تعداد اعضای پارامترهای توابع عضویت، پس طول متغیر توپ ۱ ام با ۲ ام به حتم برابر نخواهد بود و باید از نسخه VLIPO استفاده شود که روند اجرای آن در زیر آمده است:

الف) تولید جمعیت اولیه به صورت تصادفی، مقادیر K1, K2 و

دیگر پارامترها

ب) تکرار اجرای الگوریتم

در جدول (۱) توابع عضویت به کار گرفته شده با شماره شاخص آن‌ها بیان شده است.

(جدول-۱): توابع عضویت و شماره شاخص آن‌ها

(Table-1): Membership functions and their index number

نوع تابع عضویت	Gauss MF	Tri MF	Trap MF	Gbell MF	Pi MF	Dsig MF	Psig MF
شماره شاخص	1	2	3	4	5	6	7

۳-۳- معرفی الگوریتم بهینه‌ساز صفحات

شیب‌دار با طول متغیر (VLIPO^۱)

توضیحات کامل این الگوریتم در بخش ۳ به طور کامل شرح داده شده است در این قسمت توضیحات تکمیلی جهت طول متغیر بودن عوامل جستجو با توجه به نوع کاربرد در روش پیشنهادی شرح داده می‌شود.

روند کلی الگوریتم بهینه‌ساز صفحات شیب‌دار به صورت زیر است:

الف) تولید جمعیت اولیه به صورت تصادفی، مقادیر K1, K2 و دیگر پارامترها

ب) تکرار اجرای الگوریتم

پ) ارزیابی برازندگی (ارتفاع) هر توپ

ت) محاسبه زاویه، شتاب و سرعت هر توپ

ث) به روزرسانی موقعیت هر توپ

ج) محاسبه و تعیین مقادیر k1, K2


¹Variable Length Inclined Planes System Optimization algorithm

(پ) ارزیابی برازندگی (ارتفاع) هر توپ


• چک کردن شرط (اگر طول متغیر توپ i ام با j ام برابر نبود)

• توپ با طول متغیر بزرگتر و کوچکتر بین توپهای i ام و j ام مشخص می شود


• به اندازه مقدار (طول متغیر توپ کوچکتر - طول متغیر توپ بزرگتر) با عنوان یکسان سازی طول متغیر به توپ دارای طول متغیر کوچکتر یعنی در انتهای قسمت پارامترهای توابع عضویت اضافه می شود.



(شکل-۷): شکل کلی یک توپ در VLIPO
(Figure-7): Overall shape of a ball in VLIPO



(شکل-۸): ساختار توپ i ام
(Figure-8): Structure of i^{th} ball



(شکل-۹): ساختار توپ j ام
(Figure-9): Structure of j^{th} ball

انتخاب تصادفی مقادیر اولیه پارامترهای مجموعه سامانه فازی است.

گام دوم: شکل گیری پروب با توجه به ویژگی های پایگاه داده انتخابی و سامانه فازی پایه، کلیه قسمت ها که عبارت انداز: تعداد تکرار و $shift1, shift2, scale1, scale2$ مقداردهی می شوند.

گام سوم: ارزیابی اولیه توابع هدف است که بر اساس قسمت (۴-۱) مقاله (تعریف تابع ارزیابی) برابر است با:

$$\min_{\theta} Error = \frac{1}{N} \sum_{i=1}^N e_i^2 \quad (23)$$

$$MSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (t_i - y_i)^2} \quad (24)$$

۴-۳- روش پیشنهادی با الگوریتم ابتکاری VLIPO

در شکل (۱۰) روندنمای کلی فرآیند روش پیشنهادی توسط الگوریتم VLIPO نمایش داده شده است. همان طور که از روندنما مشخص است، وظیفه روش VLIPO، انتخاب توابع عضویت و آموزش هم زمان رده بند کننده داده مبتنی بر سامانه استنتاج عصبی-فازی تطبیقی است. روند کلی به صورت زیر است:

گام نخست: مقداردهی اولیه توسط مجموعه داده انتخابی به ورودی طبقه بند پیشنهادی و گرفتن تعداد ویژگی های پایگاه داده مورد نظر برای شکل گیری پروب، تعیین تعداد توپ ها و

فصل ۳




- بر اساس روابط یادشده در قسمت توضیحات روش VLIPO محاسبه زاویه و سرعت هر توپ
 - محاسبه و تعیین مقادیر $K1, K2$
 - خروجی نتایج به‌دست‌آمده
- گام چهارم: ارزیابی دوباره مقدار تابع هدف که اگر، به معیار شرط توقف یعنی انتخاب بهترین توابع عضویت برای هر ویژگی پایگاه داده انتخابی و آموزش هم‌زمان آن در ازای کمترین مقدار Fitness رسیده باشد، شرایط خاتمه لحاظ می‌شود.

حال اگر به معیار شرط توقف یعنی رسیدن به:

$$Fitness = \min Error(\theta) \text{ and } RMSE \quad (25)$$

یعنی انتخاب بهترین توابع عضویت برای هر ویژگی پایگاه داده انتخابی و آموزش هم‌زمان آن درازای کمترین مقدار Fitness رسیده باشد، شرایط خاتمه لحاظ و در غیر این صورت وارد مرحله اصلی فرایند روش VLIPO می‌شود:

- تنظیم همه پارامترهای قسمت VLIPO
- ارزیابی برازندگی (ارتفاع) هر توپ است
- یکسان‌سازی طول متغیر



(شکل-۱۰): روندنمای کلی فرآیند روش پیشنهادی توسط روش VLIPO
(Figure-10): Overall flowchart of proposed method's process via VLIPO method

ساختار کلی عامل در فضای جستجو به‌صورت شکل (۱۱) خواهد بود.

شکل (۱۱) ساختار کلی یک عامل در فضای جستجو را نشان خواهد داد. که در قسمت نخست آن پارامترهای نوع تابع عضویت انتخاب‌شده برای ویژگی‌های پایگاه داده موردنظر قرار خواهد گرفت و قسمت دوم آن پارامترهای خروجی سامانه فازی موردنظر خواهد بود.

گام سوم: جستجوی محلی برای پیدا کردن تابع ارزیابی، که شاخص MSE است، حال اگر به معیار شرط توقف، یعنی رسیدن به بهترین فرآیند آموزش به ازای کمترین مقدار MSE رسیده باشد، شرط خاتمه لحاظ می‌شود؛ در غیر این صورت مراحل زیر تکرار می‌شود:

- تنظیم همه پارامترهای مربوط به هر روش ابتکاری
- ارزیابی برازندگی در روش ابتکاری
- انجام محاسبات و مراحل اصلی مربوط به هر روش ابتکاری

۳-۵- روش آموزش طبقه‌بند ANFIS ساده توسط روش‌های ابتکاری


مراحل آموزش یک طبقه‌بند ANFIS ساده به شرح زیر است: گام نخست: مقداردهی اولیه (تعداد جمعیت، تعداد تکرار و...) مربوط به هر روش ابتکاری

گام دوم: شکل‌گرفتن عامل‌ها در فضای جستجو است که شامل پارامترهای سامانه فازی پایه و پارامترهای تابع عضویت آن است به‌طور پیش‌فرض نوع تابع استفاده‌شده گوسی است:

$$Gaussian(x; c, \sigma) = e^{-\frac{1}{2}(\frac{x-c}{\sigma})^2} \quad (26)$$

که c معین مرکز تابع عضویت است و σ عرض آن را نشان می‌دهد. پارامترهای $\{c, \sigma\}$ ساختار کلی یک عامل را نشان می‌دهند. اگر به‌طور کلی مجموعه داده‌های انتخاب‌شده دارای n ویژگی ورودی باشند، یعنی $(x_1, x_2, \dots, x_n)$ و برای مجموعه فازی مقدار n تا تابع عضویت را در نظر بگیریم

• خروجی نتایج
تا شرط خاتمه لحاظ شود.



(شکل-۱۱): ساختار کلی یک عامل در فضای جستجو در روش های ابتکاری به جهت آموزش طبقه‌بند ANFIS
(Figure-11): Overall structure of a factor in search space in Heuristic methods for ANFIS classifier training

داده‌های سرطان سینه (Breast Cancer): این پایگاه داده از بیماران دانشگاه Wisconsin به‌دست آمده است و شامل ۶۹۹ نمونه سرطان سینه مربوط به دو رده خوش‌خیم (Benign) و بدخیم (Malignant) با ۹ بعد فضای ویژگی است. داده‌های شراب (Wine): این مجموعه متشکل از آنالیز شیمیایی عناصر رشد داده‌شده شراب‌های یکسان در شرایط مساوی است که دارای ۱۷۸ نمونه با سیزده ویژگی و تعداد سه رده است.

داده‌های Bupa Liver: این مجموعه داده‌ها توسط نویسندگان متعددی نظیر Breiman (2001) مورد مطالعه واقع شده‌اند. این مجموعه داده دارای ۳۴۵ نمونه در شش ویژگی و تعداد دو رده است.

داده‌های Pima Indians: این مجموعه داده دارای ۷۶۸ نمونه در ۸ ویژگی و تعداد ۲ کلاس می‌باشد.

۴-۲- ارزیابی نتایج

جهت به‌دست‌آوردن دقت روش پیشنهادی در طبقه‌بندی داده‌های گل زنبق به سه رده (زنبق خاردار، زنبق رنگارنگ و زنبق ورجینیکا)، داده‌های سرطان سینه به دو رده (خوش‌خیم و بدخیم)، داده‌های شراب در سه رده، داده‌های Bupa liver در دو رده و داده‌های Pima در دو رده، قسمتی از داده‌ها را طبق جدول (۴) به‌عنوان داده‌های آموزشی جهت آموزش طبقه‌بند مبتنی بر سامانه استنتاج عصبی-فازی تطبیقی اعمال و مابقی به‌عنوان داده آزمایش به‌کار گرفته شده است.

(جدول-۴): تعداد داده‌های آموزش و آزمایش

(Table-4): Number of training and testing data

داده	تعداد داده‌های آموزش	تعداد داده‌های آزمایش
Iris	135	15
BreastCancer	629	70
Wine	159	19
BupaLiver	310	35
Wine	159	19

در روش پیشنهادی، کران بالا و پایین متغیر X (موقعیت هر توپ) به‌ترتیب ۱۰ و ۱۰- است و در جدول (۲)، مقادیر پارامترهای انتخابی برای الگوریتم بهینه‌سازی VLPO که برای محاسبه مقادیر k_1 و k_2 به‌کار می‌رود بیان شده است.

(جدول-۲): پارامترهای به‌کار گرفته‌شده

(Table-2): Parameters setting

C	C	Shift	Shift	Scale	Scale	NPO	Max It
1	2	1	2	1	2	P	
1	2	100	1000	0.01	2	20	50

۴- نتایج تجربی

برای ارزیابی و مقایسه عملکرد روش پیشنهادی مبتنی بر الگوریتم‌های ابتکاری با طول متغیر در بهبود عملکرد یک طبقه‌بند ANFIS، پنج پایگاه داده در جدول (۳) با ابعاد ویژگی متفاوت به‌کار گرفته شده است و نتایج به‌دست‌آمده از روش‌های DE، GA، PSO، ACOR و به‌صورت مقایسه‌ای با یکدیگر گزارش شده است.

(جدول-۳): توصیف مجموعه داده‌های مورد آزمایش [32]

(Table-3): Description of the test datasets [32]

تعداد رده‌ها	تعداد ویژگی	تعداد داده	مجموعه داده
2	9	699	BreastCancer
3	4	150	Iris
2	6	345	Bupa Liver
2	8	768	Pima indians
3	13	178	Wine

۴-۱- مجموعه داده‌ها

داده‌های گل زنبق (Iris) [33]: شامل ۱۵۰ نمونه با چهار ویژگی طول کاسبرگ (Sepal Length)، عرض کاسبرگ (Sepal Width)، طول گلبرگ (Petal Length) و عرض گلبرگ (Petal Width) و از سه نوع گونه زنبق خاردار (Iris Setosa)، زنبق رنگارنگ (Iris Versicolor) و زنبق ورجینیکا (Iris Iris) است.

W=0.9	-	PCR=0.2	Zeta=5
Varmin=-10	Var Max=10	Npop=20	MaxIt=50

در جدول‌های (۶) تا (۱۵) نتایج حاصل از روش پیشنهادی برای انتخاب بهینه نوع و مکان توابع عضویت و آموزش هم‌زمان توسط روش‌های ابتکاری با طول متغیر در سامانه طبقه‌بند ANFIS به صورت مقایسه‌ای با طبقه‌بند ANFIS ساده برای پنج پایگاه داده انتخاب شده و میزان دقت طبقه‌بندی داده‌های موردنظر برای ۱۰ بار تکرار گزارش شده است.

(جدول-۶): مقایسه دقت طبقه‌بندی داده‌های آزمایش برای

مجموعه داده Iris در یک طبقه‌بند ساده ANFIS

(Table-6): Comparing accuracy of test data classification for Iris dataset in a simple ANFIS classifier

روش ترکیب طبقه‌بند ANFIS	میزان دقت طبقه‌بندی کننده داده آزمایش (%)
PSO	95.97
GA	95.33
ACOR	96
DE	96
IPO	96.67

در جدول (۱۶) نمونه‌ای از بهترین توابع عضویت یافت شده برای مجموعه داده Iris توسط روش ابتکاری VLIPSO گزارش شده است، که برای درک بهتر آن در روش پیشنهادی توابع عضویت یافت شده برای هر ویژگی X1 تا X4 در شکل (۱۲) تا (۱۵) نشان داده شده است.

در شکل‌های (۱۶) تا (۲۵) نتایج هم‌گرایی مقدار MSE برای هر مجموعه داده انتخابی که از طریق ترکیب طبقه‌بند ساده ANFIS با روش‌های ابتکاری و طبقه‌بند ANFIS که با روش‌های ابتکاری با طول متغیر ترکیب شده، نشان داده شده و برای مقایسه بهتر عملکرد هر کدام از این روش‌های هوشمند با یکدیگر مقدار تکرار برابر با پانصد در نظر گرفته شده است.

(جدول-۷): میزان دقت طبقه‌بندی مجموعه داده iris در روش‌های مختلف برای تعیین بهترین نوع توابع عضویت و آموزش هم‌زمان
(Table-7): Level of Iris dataset classification accuracy in various methods to specify best types of membership functions and train simultaneously

ویژگی پایگاه داده iris	بهترین توابع عضویت یافت شده توسط روش ابتکاری با طول متغیر				
	VLPSO	VLGA	VLACOR	VLDE	VLIPSO
X1	psigmf	psigmf	gaussmf	gaussmf	psigmf
X2	psigmf	gaussmf	gaussmf	psigmf	psigmf
X3	psigmf	gaussmf	psigmf	psigmf	gbellmf
X4	gaussmf	psigmf	gbellmf	psigmf	gaussmf
میزان دقت طبقه‌بندی (%)	98	98	98	98	98.67

جهت محاسبه دقت، طبقه‌بند پیشنهادی، ۱۰ مرتبه اجرا شده و میانگین جواب‌های به دست آمده به عنوان دقت طبقه‌بند لحاظ شده و روش پیشنهادی در نرم‌افزار Matlab (R2015b) و سیستمی با مشخصات Cori5 4210U و 4GB حافظه رم پیاده‌سازی شده است.

۳-۴- مقایسه با روش‌های موجود

کارایی روش پیشنهادی برای انتخاب و مکان‌یابی توابع عضویت و آموزش هم‌زمان آن در طبقه‌بند ANFIS نشان از بهبود دقت طبقه‌بندی درست در مقایسه با طبقه‌بند ساده ANFIS است. در جدول (۵) مقادیر انتخاب شده برای الگوریتم‌های یاد شده آمده است، که در الگوریتم PSO پارامترهای C1 و C2 ضرایب یادگیری جمعی و شخصی است و ۰.۷، وزن اینرسی برای به تعادل آوردن جستجوی سراسری و محلی است. در الگوریتم GA، پارامترهای مقدار احتمال جهش (Mutation Probability) و احتمال بازترکیب (Crossover Probability) است. در الگوریتم DE، پارامتر Beta ضریب مقدار مقیاس (Scaling Factor) در عمل‌گر جهش است و PCR احتمال بازترکیب (Crossover Probability) است. در الگوریتم ACOR، nSample تعداد نمونه‌ها در هر تکرار الگوریتم و Q پارامتر (Intensification Factor) و zeta پارامتر (Deviation-Distance Ratio) است و مقادیر کران بالا و کران پایین، مقدار جمعیت و تعداد تکرار الگوریتم مشخص شده است.

(جدول-۵): پارامترهای به کار گرفته شده برای الگوریتم‌ها

(Table-5): Values of selected parameters for algorithms

PSO	GA	DE	ACOR
C1=2	Mutation=0.1	Beta min=0.1	nSample=2*nPop
C2=2	CrossOver=0.8	Beta max=0.8	Q=0.5

(جدول-۸): مقایسه دقت طبقه‌بندی داده‌های آزمایش برای مجموعه داده Cancer در یک طبقه‌بند ساده ANFIS
(Table-8): Comparing accuracy of test data classification for Cancer dataset in a simple ANFIS classifier

میزان دقت طبقه‌بندی کننده داده آزمایش (%)	روش ترکیب طبقه بند ANFIS
95.42	PSO
95.85	GA
95.71	ACOR
95.99	DE
96.28	IPO

(جدول-۹): میزان دقت طبقه‌بندی مجموعه داد Cancer در روش‌های مختلف برای تعیین بهترین نوع توابع عضویت و آموزش همزمان
(Table-9): Level of Cancer dataset classification accuracy in various methods to specify best types of membership functions and train simultaneously

ویژگی پایگاه داده Cancer	بهترین توابع عضویت یافت شده توسط روش ابتکاری با طول متغیر				
	VLPSO	VLGA	VLACOR	VLDE	VLIPO
X1	gaussmf	gaussmf	psigmf	gaussmf	psigmf
X2	gbellmf	gbellmf	gbellmf	gaussmf	gaussmf
X3	gaussmf	gaussmf	gbellmf	psigmf	gbellmf
X4	psigmf	gaussmf	gaussmf	psigmf	psigmf
X5	psigmf	gbellmf	gaussmf	psigmf	psigmf
X6	gbellmf	gbellmf	gbellmf	psigmf	gaussmf
X7	gbellmf	gaussmf	gbellmf	gaussmf	psigmf
X8	gbellmf	psigmf	gaussmf	gaussmf	gbellmf
X9	psigmf	gaussmf	gbellmf	psigmf	psigmf
میزان دقت طبقه‌بندی (%)	96.71	96.57	96.42	96.57	96.85

(جدول-۱۰): مقایسه دقت طبقه‌بندی داده‌های آزمایش برای مجموعه‌داده Bupa Liver در یک طبقه‌بند ساده ANFIS
(Table-10): Comparing accuracy of test data classification for Bupa dataset in a simple ANFIS classifier

میزان دقت طبقه‌بندی کننده داده آزمایش (%)	روش ترکیب طبقه‌بند ANFIS
71.35	PSO
68.24	GA
69.28	ACOR
68.99	DE
71.43	IPO

(جدول-۱۱): میزان دقت طبقه‌بندی مجموعه‌داده Bupa Liver در روش‌های مختلف برای تعیین بهترین نوع توابع عضویت و آموزش همزمان

(Table-11): Level of Bupa dataset classification accuracy in various methods to specify best types of membership functions and train simultaneously

ویژگی پایگاه داده Bupa	بهترین توابع عضویت یافت شده توسط روش ابتکاری با طول متغیر				
	VLPSO	VLGA	VLACOR	VLDE	VLIPO
X1	psigmf	gbellmf	gbellmf	psigmf	psigmf
X2	psigmf	gaussmf	psigmf	psigmf	gaussmf
X3	gbellmf	gbellmf	psigmf	psigmf	gbellmf
X4	gbellmf	gbellmf	gbellmf	gaussmf	gbellmf
X5	psigmf	gbellmf	gbellmf	gaussmf	gaussmf
X6	psigmf	gbellmf	gaussmf	gaussmf	gaussmf
میزان دقت طبقه‌بندی (%)	74.12	73.55	74.05	73.68	74.41

(جدول-۱۲): مقایسه دقت طبقه‌بندی داده‌های آزمایش برای مجموعه داده Pima در یک طبقه‌بند ساده ANFIS

(Table-12): Comparing accuracy of test data classification for Pima dataset in a simple ANFIS classifier

روش ترکیب طبقه‌بند ANFIS	میزان دقت طبقه‌بندی کننده داده آزمایش (%)
PSO	76.56
GA	77.05
ACOR	77.47
DE	76.30
IPO	77.68

(جدول-۱۳): میزان دقت طبقه‌بندی مجموعه داده Pima در روش‌های مختلف برای تعیین بهترین نوع توابع عضویت و آموزش همزمان

(Table-13): Level of Pima dataset classification accuracy in various methods to specify best types of membership functions and train simultaneously

ویژگی پایگاه داده Pima	بهترین توابع عضویت یافت شده توسط روش ابتکاری با طول متغیر				
	VLPSO	VLGA	VLACOR	VLDE	VLIPO
X1	gbellmf	psigmf	gbellmf	psigmf	psigmf
X2	gaussmf	gaussmf	psigmf	gbellmf	gbellmf
X3	psigmf	gbellmf	gbellmf	psigmf	gaussmf
X4	gaussmf	psigmf	gaussmf	psigmf	psigmf
X5	psigmf	gbellmf	gbellmf	psigmf	gbellmf
X6	psigmf	gbellmf	gaussmf	psigmf	psigmf
X7	gbellmf	psigmf	gbellmf	gbellmf	gbellmf
X8	gaussmf	psigmf	gaussmf	psigmf	psigmf
میزان دقت طبقه‌بندی (%)	78.23	78.07	78.26	78.13	78.26

(جدول-۱۴): مقایسه دقت طبقه‌بندی داده‌های آزمایش برای مجموعه داده Wine در یک طبقه‌بند ساده ANFIS

(Table-14): Comparing accuracy of test data classification for Wine dataset in a simple ANFIS classifier


روش ترکیب طبقه‌بند ANFIS	میزان دقت طبقه‌بندی کننده داده آزمایش (%)
PSO	96.07
GA	94.92
ACOR	96.63
DE	95.51
IPO	97.14

(جدول-۱۵): میزان دقت طبقه‌بندی مجموعه داده Wine در روش‌های مختلف برای تعیین بهترین نوع توابع عضویت و آموزش همزمان

(Table-15): Level of Wine dataset classification accuracy in various methods to specify best types of membership functions and train simultaneously

ویژگی پایگاه داده Wine	بهترین توابع عضویت یافت شده توسط روش ابتکاری با طول متغیر				
	VLPSO	VLGA	VLACOR	VLDE	VLIPO
X1	gbellmf	gbellmf	psigmf	gaussmf	psigmf
X2	gbellmf	gbellmf	psigmf	psigmf	gbellmf
X3	gbellmf	gbellmf	gbellmf	psigmf	psigmf
X4	psigmf	gbellmf	gbellmf	psigmf	gaussmf
X5	psigmf	gbellmf	gbellmf	gaussmf	gaussmf
X6	psigmf	gbellmf	gaussmf	psigmf	gbellmf
X7	gaussmf	psigmf	gbellmf	psigmf	gbellmf
X8	psigmf	gbellmf	psigmf	psigmf	gbellmf
X9	gbellmf	gaussmf	psigmf	gaussmf	psigmf


X10	psigmf	gbellmf	gbellmf	gbellmf	psigmf
X11	gaussmf	psigmf	gbellmf	psigmf	gbellmf
X12	gbellmf	psigmf	gaussmf	gbellmf	gbellmf
X13	gaussmf	gbellmf	gbellmf	psigmf	gaussmf
میزان دقت طبقه‌بندی (%)	98.30	98.29	98.31	97.73	98.31



(شکل-۱۴): بهترین توابع عضویت یافت‌شده توسط روش

VLIPO برای ویژگی X(c) مجموعه‌داده Iris

(Figure-14): Best found membership functions via VLIPO for X(c) specification of Iris dataset



(شکل-۱۵): بهترین توابع عضویت یافت‌شده توسط روش

VLIPO برای ویژگی X(d) مجموعه‌داده Iris

(Figure-15): Best found membership functions via VLIPO for X(d) specification of Iris dataset

در شکل‌های (۱۶) تا (۲۵) که دربردارنده نحوه هم‌گرایی روش‌های ابتکاری به کار گرفته شده است، متضمن آن است که روش IPO به‌عنوان یک روش ابتکاری جدید نه تنها با تعداد تکرار کمتر هم‌گرا شده است، بلکه با همان تعداد تکرار کمتر توانسته است، پاسخ بهتری نیز به دست آورد. این مطلب نشان‌دهنده این است که این روش در مسأله به کار گرفته شده توانسته است، به‌طور مؤثر به جستجوی پاسخ بهینه در فضای مربوطه پرداخته و از نقاط بهینه محلی که بقیه روش‌ها در آن‌ها گرفتار شده‌اند، خود را برهاند.

نمونه‌ای از توابع عضویت یافت شده توسط روش VLIPO برای


مجموعه‌داده Iris:

(جدول-۱۶): نمونه‌ای از توابع عضویت توسط روش VLIPO برای

مجموعه‌داده Iris

(Table-16): A sample of membership functions via IPO for Iris dataset


X1	X2	X3	X4
gbellmf	gaussmf	psigmf	gbellmf



(شکل-۱۲): بهترین توابع عضویت یافت‌شده توسط روش

VLIPO برای ویژگی X(a) مجموعه‌داده Iris

(Figure-12): Best found membership functions via VLIPO for X(a) specification of Iris dataset




(شکل-۱۳): بهترین توابع عضویت یافت‌شده توسط روش

VLIPO برای ویژگی X(b) مجموعه‌داده Iris


(Figure-13): Best found membership functions via VLIPO for X(b) specification of Iris dataset

فصل ۱۲








(شکل-۱۹): هم‌گرایی مقدار MSE برای مجموعه‌داده Cancer برای طبقه‌بند ANFIS با روش‌های ابتکاری با طول متغیر
(Figure-19): Convergence of MSE value for Cancer dataset for ANFIS classifier through Heuristic methods with variable lengths




(شکل-۲۰): هم‌گرایی مقدار MSE برای مجموعه‌داده Wine برای طبقه‌بند ساده ANFIS
(Figure-20): Convergence of MSE value for Wine data set for simple ANFIS classifier



(شکل-۲۱): هم‌گرایی مقدار MSE برای مجموعه‌داده Wine برای طبقه‌بند ANFIS با روش‌های ابتکاری با طول متغیر
(Figure-21): Convergence of MSE value for Wine dataset for ANFIS classifier through Heuristic methods with variable lengths




(شکل-۱۶): هم‌گرایی مقدار MSE برای مجموعه‌داده Iris برای طبقه‌بند ساده ANFIS




(شکل-۱۷): هم‌گرایی مقدار MSE برای مجموعه‌داده Iris برای طبقه‌بند ANFIS با روش‌های ابتکاری با طول متغیر
(Figure-17): Convergence of MSE value for Iris dataset for ANFIS classifier through Heuristic methods with variable lengths

با مشاهده شکل‌های (۱۲) تا (۱۵) می‌توان دید که توابع عضویت پیشنهادشده به‌وسیله روش ارائه‌شده، توابع عضویتی معقول و همخوان با کمینه‌های فازی مربوط به تک‌تک عناصر بردار ویژگی است. این مسأله در تمام یافته‌های شبیه‌سازی‌شده تکرار شده که به‌دلیل ازدیاد تعداد اشکال، این شکل فقط به‌صورت نمونه گزارش شده است.




(شکل-۱۸): هم‌گرایی مقدار MSE برای مجموعه‌داده Cancer برای طبقه‌بند ساده ANFIS
(Figure-18): Convergence of MSE value for Cancer data set for simple ANFIS classifier

شده و به صورت مقایسه‌ای با یکدیگر نمایش داده شده است. در طبقه‌بند ساده ANFIS نوع تابع عضویت گوسی است. از نمودار (۱) به طور واضح مشخص است که روش ابتکاری IPO برای آموزش طبقه‌بند ساده ANFIS نسبت به سایر روش‌های دیگر بهتر عمل کرده است.




(نمودار-۱): مقایسه دقت طبقه‌بندی داده‌های آزمایش برای مجموعه داده Iris در طبقه‌بند ساده ANFIS
(Diagram-1): Comparing accuracy of test data classification for Iris dataset in a simple ANFIS classifier




(نمودار-۲): مقایسه دقت طبقه‌بندی داده آزمایش برای مجموعه داده Iris در طبقه ANFIS از طریق روش‌های ابتکاری با طول متغیر
(Diagram-2): Comparing accuracy of test data classification for Iris dataset in ANFIS class through innovative methods with various lengths

در نمودار (۲) نتایج جدول (۷) یعنی مقایسه دقت طبقه‌بندی داده‌های آزمایش برای مجموعه داده Iris در طبقه‌بند ساده ANFIS که از طریق روش‌های ابتکاری با طول متغیر برای انتخاب و مکان‌یابی توابع عضویت و آموزش آن صورت


(شکل-۲۲): هم‌گرایی مقدار MSE برای مجموعه داده Bupa Liver برای طبقه‌بند ساده ANFIS



(شکل-۲۳): هم‌گرایی مقدار MSE برای مجموعه داده Bupa Liver برای طبقه‌بند ANFIS با روش‌های ابتکاری با طول متغیر
(Figure-23): Convergence of MSE value for Bupa dataset for ANFIS classifier through Heuristic methods with variable lengths




(شکل-۲۴): هم‌گرایی مقدار MSE برای مجموعه داده Pima Liver برای طبقه‌بند ساده ANFIS
(Figure-24): Convergence of MSE value for Pima data set for simple ANFIS classifier



(شکل-۲۵): هم‌گرایی مقدار MSE برای مجموعه داده Pima برای طبقه‌بند ANFIS با روش‌های ابتکاری با طول متغیر
(Figure-25): Convergence of MSE value for Pima dataset for ANFIS classifier through Heuristic methods with variable lengths

در نمودار (۱) نتایج جدول (۶) یعنی میزان دقت طبقه‌بندی داده‌های آزمایش برای مجموعه داده Iris که توسط یک طبقه‌بند ساده ANFIS که به جهت آموزش با روش‌های ابتکاری یادشده ترکیب شده است، برای ده بار تکرار گزارش


ابتکاری ساده به جهت آموزش آن ترکیب شده از میزان دقت و کارایی بالاتری برخوردار است و به‌طور کلی از جدول (۷) مشخص است که روش VLIPSO نسبت به سایر روش‌های دیگر هم در این مجموعه داده بهتر عمل کرده است.



(نمودار-۴): مقایسه دقت طبقه‌بندی داده‌های آزمایش برای

مجموعه داده Cancer در طبقه‌بند ساده ANFIS
(Diagram-4): Comparing accuracy of test data classification for Cancer dataset in a simple ANFIS classifier


در نمودار (۴) نتایج جدول (۸) به‌طور مقایسه‌ای نشان داده شده و همان‌طور که مشخص است، روش IPO برای آموزش طبقه‌بند ساده ANFIS با دقت ۹۶/۲۸ درصد نسبت به سایر روش‌های دیگر بهتر عمل کرده است.



(نمودار-۵): مقایسه دقت طبقه‌بندی داده آزمایش برای

مجموعه داده Cancer در طبقه‌بند ANFIS از طریق روش‌های ابتکاری با طول متغیر
(Diagram-5): Comparing accuracy of test data classification for Cancer dataset in ANFIS class through innovative methods with various lengths

گرفته، به‌صورت مقایسه با یکدیگر نمایش داده شده است. این نتایج بیان‌گر این مسأله است که روش VLIPSO نسبت به سایر روش‌های ابتکاری با طول متغیر دیگر بهتر عمل کرده و نکته قابل‌توجه دیگر این است که در تمامی روش‌های ابتکاری با طول متغیر یک پایداری به‌نسبه خوب در طبقه‌بندی صحیح داده‌های آزمایشی و میزان دقت خروجی پدیدار شده است.




(نمودار-۳): مقایسه دقت طبقه‌بندی داده‌های آزمایش برای

مجموعه داده Iris در یک طبقه‌بند ساده ANFIS با طبقه طراحی‌شده توسط روش ابتکاری با طول متغیر
(Diagram-3): Comparing accuracy of test data classification for Iris dataset in a simple ANFIS with through innovative methods with various lengths

در نمودار (۳) نتایج جدول (۶) و (۷) به‌صورت مقایسه‌ای با یکدیگر نمایش داده شده است. همان‌طور که از نتایج جدول (۶) مشخص است، نوع تابع عضویت در طبقه‌بند ساده ANFIS برای همه‌ی ورودی‌ها فقط گوسی و به‌طور واضح از نتایج مشخص است که نوع تابع عضویت و روش آموزش تأثیر چشم‌گیری در میزان دقت و کارایی طبقه‌بند ANFIS دارد؛ بنابراین بر طبق روش پیشنهادی توسط روش‌های ابتکاری با طول متغیر در طبقه‌بند پیشنهادی با توجه به ویژگی‌های پایگاه داده موردنظر از X_1 تا X_n توسط این روش هم نوع بهترین تابع عضویت مشخص و به‌طور هم‌زمان آموزش داده می‌شود؛ که بر طبق نتایج جدول (۷) به‌طور کامل مشخص است که طبقه‌بند طراحی‌شده با روش‌های ابتکاری با طول متغیر از میزان دقت بالا نسبت به یک طبقه‌بند ساده ANFIS دارد. برای مثال همان‌طور که از نمودار (۳) مشخص است، در یک طبقه‌بند ساده ANFIS که با روش PSO آموزش داده شده برای ده بار تکرار به بیشینه دقت ۹۵/۹۷ درصد رسیده ولی درحالی‌که طبقه که با روش VLPSO بهترین نوع توابع عضویت تعیین و به‌طور هم‌زمان آموزش داده شده به دقت برای ده بار تکرار ۹۸ درصد رسیده است و همان‌طور که از نتایج مشخص است، برای تمامی موارد روش پیشنهادی نسبت به یک طبقه‌بند ساده که با روش‌های

در نمودار (۵) نتایج جدول (۹) به صورت مقایسه‌ای نشان داده شده و روش VLIPSO با دقت ۹۶/۸۵ برای ۱۰ بار تکرار از سایر روش‌های دیگر بهتر عمل کرده است.




(نمودار-۶): مقایسه دقت طبقه‌بندی داده‌های آزمایش برای مجموعه داده Cancer در یک طبقه‌بند ساده ANFIS با طبقه

طراحی شده توسط روش ابتکاری با طول متغیر

(Diagram-6): Comparing accuracy of test data classification for Cancer dataset in a simple ANFIS with through innovative methods with various lengths

در نمودار (۷) نتایج جدول (۱۰) به صورت مقایسه‌ای نشان داده شده است و همان‌طور که از نتایج مشخص است روش IPO با دقت ۷۱/۴۳ درصد برای ده بار تکرار نسبت به سایر روش‌ها بهتر عمل کرده است.




(نمودار-۸): مقایسه دقت طبقه‌بندی داده آزمایش برای

مجموعه داده Bupa در طبقه ANFIS از طریق روش‌های ابتکاری با طول متغیر

(Diagram-8): Comparing accuracy of test data classification for Bupa dataset in ANFIS class through innovative methods with various lengths

در نمودار (۸) نتایج جدول (۱۱) به صورت مقایسه‌ای نشان داده شده است.




(نمودار-۹): مقایسه دقت طبقه‌بندی داده‌های آزمایش برای

مجموعه داده Bupa Liver در یک طبقه‌بند ساده ANFIS با طبقه

طراحی شده توسط روش ابتکاری با طول متغیر

(Diagram-9): Comparing accuracy of test data classification for Bupa Liver dataset in a simple ANFIS with through innovative methods with various lengths



(نمودار-۷): مقایسه دقت طبقه‌بندی داده‌های آزمایش برای

مجموعه داده Bupa Liver در یک طبقه‌بند ساده ANFIS


(Diagram-7): Comparing accuracy of test data classification for Bupa dataset in a simple ANFIS classifier

(نمودار-۱۲): مقایسه دقت طبقه‌بندی داده‌های آزمایش برای مجموعه داده Pima در یک طبقه‌بند ساده ANFIS با طبقه

طراحی شده توسط روش ابتکاری با طول متغیر

(Diagram-12): Comparing accuracy of test data classification for Pima dataset in a simple ANFIS with through innovative methods with various lengths

در نمودار (۱۲) نتایج جدول (۱۲) و (۱۳) به صورت مقایسه‌ای نشان داده شده است.




(نمودار-۱۳): مقایسه دقت طبقه‌بندی داده‌های آزمایش برای

مجموعه داده wine در طبقه‌بند ساده ANFIS

(Diagram-13): Comparing accuracy of test data classification for Wine dataset in a simple ANFIS classifier

در نمودار (۱۳) نتایج جدول (۱۴) به صورت مقایسه‌ای نشان داده شده است.




(نمودار-۱۴): مقایسه دقت طبقه‌بندی داده آزمایش برای

مجموعه داده Wine در طبقه ANFIS از طریق روش‌های ابتکاری

با طول متغیر

(Diagram-14): Comparing accuracy of test data classification for Wine dataset in ANFIS class through innovative methods with various lengths

در نمودار (۹) نتایج جدول (۱۰) و (۱۱) به صورت مقایسه‌ای نشان داده شده است.




(نمودار-۱۰): مقایسه دقت طبقه‌بندی داده‌های آزمایش برای

مجموعه داده Pima در طبقه‌بند ساده ANFIS

(Diagram-10): Comparing accuracy of test data classification for Pima dataset in a simple ANFIS classifier

در نمودار (۱۰) نتایج جدول (۱۲) به صورت مقایسه‌ای نشان داده شده است.




(نمودار-۱۱): مقایسه دقت طبقه‌بندی داده آزمایش برای

مجموعه داده Pima در طبقه ANFIS از طریق روش‌های ابتکاری


با طول متغیر

(Diagram-11): Comparing accuracy of test data classification for Pima dataset in ANFIS class through innovative methods with various lengths

در نمودار (۱۱) نتایج جدول (۱۳) به صورت مقایسه‌ای نشان داده شده است.



در نمودار (۱۴) نتایج جدول (۱۵) به صورت مقایسه‌ای نشان داده شده است.



(نمودار-۱۵): مقایسه دقت طبقه‌بندی داده‌های آزمایش برای

مجموعه داده Wine در یک طبقه‌بند ساده ANFIS با طبقه

طراحی شده توسط روش ابتکاری با طول متغیر

(Diagram-15): Comparing accuracy of test data classification for Wine dataset in a simple ANFIS with through innovative methods with various lengths

در نمودار (۱۵) نتایج جدول (۱۴) و (۱۵) به صورت

مقایسه‌ای نشان داده شده است.

مقایسه انجام شده، برای پنج مجموعه داده انتخاب شده، بیانگر عملکرد بهتر و دقت بالاتر، روش پیشنهادی مبتنی بر الگوریتم‌های ابتکاری با طول متغیر در سامانه طبقه‌بند ANFIS در این مقاله، در هر پنج مجموعه داده نسبت به طبقه‌بند ساده ANFIS است و این مؤید این مطلب است که روش پیشنهادی مبتنی بر الگوریتم‌های ابتکاری با طول متغیر در بهبود عملکرد سامانه طبقه‌بند ANFIS، البته در این مسأله خاص، نسبت به روش‌های دیگر بهتر عمل می‌کند. با توجه به نتایج به دست آمده می‌توان گفت که روش پیشنهادی در طبقه بند مورد نظر، کارایی قابل قبولی در مسأله بازشناسی الگو دارد.

۵- نتیجه گیری

در این پژوهش یک روش هوشمند برای طراحی بهینه یک طبقه‌بند ANFIS مبتنی بر الگوریتم‌های ابتکاری با طول متغیر پیشنهاد شده است. نتایج تجربی نشان می‌دهد، که طراحی بهینه و هوشمند طبقه‌بند ANFIS توسط روش‌های ابتکاری با طول متغیر بر پنج مجموعه داده مشهور نتایج خوب و رضایت‌بخشی را حاصل کرد و در هر پنج مسأله جواب‌های

بهتری نسبت به روش‌های طراحی دیگر در سامانه طبقه‌بند ANFIS ارائه کرده است.

یک محدودیت مهم که ممکن است استفاده از روش طراحی بهینه و هوشمند طبقه‌بند ANFIS توسط الگوریتم ابتکاری طول متغیر را محدود کند، وابستگی به پارامترهای اولیه الگوریتم‌ها جهت رسیدن به هم‌گرایی سریع الگوریتم است. استفاده از الگوریتم‌های ابتکاری با کنترل‌کننده‌های کمکی به منظور کنترل پارامترهای آن می‌تواند سبب هم‌گرایی سریع‌تر طبقه‌بند شود. این توانایی در پژوهش‌های آینده می‌تواند مورد بررسی قرار گیرد.

6- References

۶- مراجع

- [1] C. C. C. Lee, "Fuzzy logic in control systems: fuzzy logic controller. II," IEEE Trans. Syst. Man. Cybern., vol. 20, no. 2, pp. 404-418, 1990.
- [2] T. J. Ross, "Fuzzy Logic with Engineering Applications: Third Edition", vol. 222, New Delhi: Tata McGraw-Hill Publishing Company limited, 2010.
- [3] S.-H. Zahiri, "Swarm Intelligence and Fuzzy Systems (Computer Science, Technology and Applications): Seyyed-Hamid Zahiri: March 1, 2011," 2010.
- [4] A. Klose and R. Kruse, "Enabling neuro-fuzzy classification to learn from partially labeled data," in 2002 IEEE World Congress on Computational Intelligence. 2002 IEEE International Conference on Fuzzy Systems. FUZZ-IEEE'02. Proceedings (Cat. No.02CH-37291), vol. 1, pp. 803-808, 2011.
- [5] H. Ishibuchi, T. Nakashima, and T. Murata, "Performance evaluation of fuzzy classifier systems for multi-dimensional pattern classification problems," IEEE Trans. Syst. Man Cybern. Part B, vol. 29, no. 5, pp. 601-618, 1999.
- [6] R. Yuhui Shi, Eberhart, and Ch. Yaobin, "Implementation of evolutionary fuzzy systems," IEEE Trans. Fuzzy Syst., vol. 7, no. 2, pp. 109-119, Apr. 1999.
- [7] M. Setnes and H. Roubos, "GA-fuzzy modeling and classification: complexity and performance," IEEE Trans. Fuzzy Syst., vol. 8, no. 5, pp. 509-522, 2000.
- [8] Ching-Hung Wang, Tzung-Pei Hong, and Shian-Shyong Tseng, "Integrating fuzzy knowledge by genetic algorithms," IEEE Trans. Evol. Comput., vol. 2, no. 4, pp. 138-149, 1998.
- [9] Z. Xing, Y. Hou, Z. Tong, and L. Jia, "Construction of Fuzzy Classification System Based on Multi-objective Genetic Algorithm," in Sixth International Conference on Intelligent Systems

- Autom. Soft Comput., vol. 23, no. 2, pp. 227–234, 2017.
- [24] D. Karaboga and E. Kaya, "Adaptive network based fuzzy inference system (ANFIS) training approaches: a comprehensive survey," *Artif. Intell. Rev.*, pp. 1–31, Jan. 2018.
- [25] M. H. Mozaffari, H. Abdy, and S. H. Zahiri, "IPO: An inclined planes system optimization algorithm," *Comput. Informatics*, vol. 35, no. 1, pp. 222–240, 2016.
- [26] J. Kennedy and R. Eberhart, "Particle swarm optimization," *Neural Networks*, 1995. *Proceedings*, IEEE Int. Conf., vol. 4, pp. 1942–1948, 1995.
- [27] T. Bäck, *Evolutionary algorithms in theory and practice: evolution strategies, evolutionary programming, genetic algorithms*. Oxford University Press, 1996.
- [28] R. Chelouah and P. Siarry, "A Continuous Genetic Algorithm Designed for the Global Optimization of Multimodal Functions," *J. Heuristics*, vol. 6, no. 2, pp. 191–213, 2000.
- [29] K. Storn, R.; Price, "Differential evolution - a simple and efficient heuristic for global optimization over continuous spaces," *J. Glob. Optim.* 11 - 1223 731–752.
- [30] K. Socha and M. Dorigo, "Ant colony optimization for continuous domains," *Eur. J. Oper. Res.*, vol. 185, no. 3, pp. 1155–1173, 2008.
- [31] K. Sugun. S. Esvari, P. N. Raghunath, "Ductility performance of HyFRC," *Am. J. Appl. Sci.*, vol. 5, no. 9, pp. 1257–1262, 2008.
- [32] K. Bache and M. Lichman, "UCI Machine Learning Repository," University of California Irvine School of Information, vol. 2008, no. 14/8. 2013.
- [33] R. A. FISHER, "THE USE OF MULTIPLE MEASUREMENTS IN TAXONOMIC PROBLEMS," *Ann. Eugen.*, vol. 7, no. 2, pp. 179–188, 1936.
- [۳۴] گل‌گونه علیرضا، تارویردی‌زاده بهرام. توسعه سامانه مکترونیکي بلادرنج سنجش استرس، مبتنی بر سیگنال‌های حیاتی. پردازش علائم و داده‌ها. ۱۳۹۷؛ ۷۴-۵۹: (۳) ۱۵
- [34] A. Golgouneh and B. Tarvirdizadeh, "Development of a Mechatronics System to Real-Time Stress Detection Based on Physiological Signals," *Signal Data Process.*, vol. 15, no. 3, 2018.
- [۳۵] محبی نجم‌آباد جواد، مرادی مرتضی، سلامی باقر. انتخاب ویژگی پیشنهادی برای مدیریت دمای پویا در Design and Applications, , vol. 2, 2006, pp. 1029–1034.
- [10] C. Rania and S. N. Deepa, "PSO with mutation for fuzzy classifier design," in *Procedia Computer Science*, 2010, vol. 2, pp. 307–313.
- [11] C. C. Chen, "Design of PSO-based fuzzy classification systems," *Tamkang J. Sci. Eng.*, vol. 9, no. 1, pp. 63–70, 2006.
- [12] H. Alipour, F. K. Asl, M. Esmaili, and M. Nourhosseini, "ACO-FCR: Applying ACO-Based Algorithms to Induct FCR," vol. I, 2008.
- [13] S.-H. Zahiri and S.-A. Seyedin, "Using Multi-Objective Particle Swarm Optimization for Designing Novel Classifiers." Springer, Berlin, Heidelberg, pp. 65–92, 2009.
- [14] J. S. R. Jang, "ANFIS: Adaptive-Network-Based Fuzzy Inference System," *IEEE Trans. Syst. Man Cybern.*, vol. 23, no. 3, pp. 665–685, 1993.
- [15] S. Kar, S. Das, and P. K. Ghosh, "Applications of neuro fuzzy systems: A brief review and future outline," *Appl. Soft Comput. J.*, vol. 15, pp. 243–259, 2014.
- [16] A. Z. Zangeneh, M. Mansouri, M. Teshnehlab, and A. K. Sedigh, "Training ANFIS system with DE algorithm," in *The Fourth International Workshop on Advanced Computational Intelligence*, 2011, pp. 308–314.
- [17] M. Nasiri and K. Facz, "Extracting fetal electrocardiogram signal using ANFIS trained by genetic algorithm," in *2012 International Conference on Bio-medical Engineering, ICoBE 2012*, 2012, pp. 197–202.
- [18] A. Sarkheyli, A. M. Zain, and S. Sharif, "Robust optimization of ANFIS based on a new modified GA," *Neurocomputing*, vol. 166, no. October, pp. 357–366, 2015.
- [19] D. P. Rini, S. M. Shamsuddin, and S. S. Yuhaziz, "Particle swarm optimization for ANFIS interpretability and accuracy," *Soft Comput.*, vol. 20, no. 1, pp. 251–262, Jan. 2016.
- [20] D. Karaboga and E. Kaya, "An adaptive and hybrid artificial bee colony algorithm (aABC) for ANFIS training," *Appl. Soft Comput.*, vol. 49, pp. 423–436, 2016.
- [21] K. Thangavel and A. Kaja Mohideen, "Mammogram Classification Using ANFIS with Ant Colony Optimization Based Learning," Springer Singapore, 2016, pp. 141–152.
- [22] E. Ghasemi, H. Kalhori, and R. Bagherpour, "A new hybrid ANFIS-PSO model for prediction of peak particle velocity due to bench blasting," *Eng. Comput.*, vol. 32, no. 4, pp. 607–614, 2016.
- [23] H. Marzi, A. Haj Darwish, and H. Helfawi, "Training ANFIS Using the Enhanced Bees Algorithm and Least Squares Estimation," *Intell.*

سیستم‌های چند هسته‌ای. پردازش علائم و داده‌ها.

۱۳۹۸؛ ۱۶ (۱): ۱۲۵-۱۴۲

[35] J. Mohebbi, M. Moradi, and B. Salami, "Proposed Feature Selection for Dynamic Thermal Management in Multicore Systems," Signal Data Process., vol. 16, no. 1, 2019.



امیر سلطانی محبوب فارغ التحصیل

کارشناسی ارشد در رشته الکترونیک از

دانشگاه بیرجند در سال ۱۳۹۶ است.

زمینه‌های مورد علاقه ایشان، تشخیص الگو،

روش‌های بهینه‌سازی تکاملی، روش‌های

بهینه‌سازی هوش جمعی، محاسبات نرم، الگوریتم‌های

بهینه‌ساز ابتکاری و طراحی بهینه مدارات مجتمع است.

نشانی رایانامه ایشان عبارت است از:

Soltany.Mahboob@gmail.com



سید حمید ظهیری ممقانی مدارک

کارشناسی و کارشناسی ارشد خود را به ترتیب

در رشته مهندسی برق الکترونیک از دانشگاه

صنعتی شریف و تربیت مدرس دریافت کردند.

ایشان در سال ۱۳۸۴ مدرک دکترای خود را

در رشته مهندسی برق الکترونیک در دانشگاه فردوسی مشهد

به اتمام رساندند. وی در حال حاضر استاد تمام گروه برق

الکترونیک دانشکده مهندسی برق و کامپیوتر دانشگاه بیرجند

هستند. زمینه‌های مورد علاقه ایشان، روش‌های بهینه‌سازی

تکاملی، روش‌های بهینه‌سازی هوش جمعی، محاسبات نرم،

تشخیص الگو، پردازش تصویر و پردازش سیگنال است.

نشانی رایانامه ایشان عبارت است از:

shzahiri@yahoo.com