

سیستم استنتاج عصبی - فازی تطبیقی خودبازخورد آموزش یافته با الگوریتم رقابت استعماری برای پیش‌بینی سری‌های زمانی آشوبناک

میثم بهمنش^۱، مجید محمدی^۲

۱- دانشجوی دکتری هوش مصنوعی، دانشکده مهندسی کامپیوتر - دانشگاه اصفهان - اصفهان - ایران

mbehmanesh@eng.ui.ac.ir

۲- دانشیار بخش مهندسی کامپیوتر، دانشکده مهندسی - دانشگاه شهید باهنر کرمان - کرمان - ایران

mohammadi@mail.uk.ac.ir

چکیده: پیش‌بینی سری‌های زمانی، مخصوصاً سری‌های زمانی آشوبی سیستم‌های پویای غیرخطی، یکی از زمینه‌های مهم تحقیقاتی است و کاربرد زیادی در زمینه‌های گوناگون دارد. از میان روش‌های معرفی‌شده برای پیش‌بینی سری‌های زمانی آشوبناک، به استفاده از شبکه‌های عصبی و سیستم‌های فازی بیشتر توجه شده است. در این مقاله، سیستم استنتاج عصبی - فازی تطبیقی بهبودیافته، برای پیش‌بینی سری‌های زمانی آشوبناک پیشنهاد شده است. با توجه به اینکه ساختار سیستم استنتاج عصبی - فازی تطبیقی براساس یک شبکه پیشرو است، بیشتر به مسائل ایستا محدود بوده است و توانایی مواجهه مؤثر با ویژگی‌های پویا مانند سری‌های زمانی را ندارد. برای غلبه بر این مشکل، در این مقاله برای مدل‌سازی وابستگی‌های زمانی این سیستم، از ارتباط خودبازخورد خروجی مراحل قبلی استفاده شده است. همچنین از ترکیب الگوریتم بهینه‌سازی رقابت استعماری ICA، همراه با تخمین حداقل مربعات LSE، برای آموزش سیستم عصبی - فازی و به‌روزرسانی پارامترهای آن استفاده شده است که این روش، مشکلات آموزش الگوریتم‌های بر پایه گرادینان را ندارد. این روش برای پیش‌بینی و مدل‌سازی چند سری زمانی غیرخطی و آشوبناک جهان واقعی استفاده شده است. تجزیه و تحلیل نتایج و مقایسه آن با کارهای اخیر، نشان‌دهنده عملکرد بهتر روش پیشنهادی نسبت به روش‌های قبلی، از نظر معیار خطای کل پیش‌بینی برای مدل‌سازی و پیش‌بینی سری‌های زمانی هستند.

واژه‌های کلیدی: الگوریتم‌های تکاملی، الگوریتم یادگیری، حداقل مربعات خطا، سیستم‌های آشوبناک

۱- مقدمه

است؛ سپس مدل حاصل به منظور برون‌یابی سری‌های زمانی در آینده استفاده شده است. پیش‌بینی سری‌های زمانی، مبحث مهمی است که کاربردهای گسترده‌ای در زمینه‌های علوم، مهندسی، پزشکی، اقتصاد و ... دارد.

به‌طورکلی، یک سری زمانی، خواصی همچون غیرخطی‌گری^۱، آشوبی^۲، غیرایستاگری^۳ و تناوبی^۴ مانند فصلی‌گری^۵ دارد و حتی ممکن است نویزی نیز باشد. در میان انواع مختلف سری‌های زمانی، سری زمانی آشوبی، به‌طورمعمول در پدیده‌های طبیعی یافت می‌شود [۱، ۲]. پیش‌بینی رفتار سری‌های زمانی آشوبی سیستم‌های پویای غیرخطی موضوع تحقیق جدیدی است که توجه و تلاش بسیاری از دانشمندان را جلب کرده است.

پیش‌بینی سری‌های زمانی یکی از مهم‌ترین زمینه‌های پیش‌بینی است که در آن مشاهدات گذشته یک متغیر، جمع‌آوری و برای به دست آوردن روابط اساسی بین مشاهدات و تعیین یک مدل توصیفی، تجزیه و تحلیل شده

^۱ تاریخ ارسال مقاله: ۱۳۹۴/۴/۱۸

تاریخ پذیرش مقاله: ۱۳۹۶/۲/۱۷

نام نویسنده مسئول: مجید محمدی

نشانی نویسنده مسئول: ایران - کرمان - دانشگاه شهید باهنر کرمان - دانشکده مهندسی - بخش مهندسی کامپیوتر

پیش بینی سری های زمانی در زمینه الگوریتم یادگیری، پیش پردازش ورودی ها و تنظیم قوانین بوده است. در این مقاله یک روش ترکیبی برای یادگیری و روش تکراری از ارتباط های خودبازخورد، برای بهبود عملکرد سیستم استنتاج عصبی - فازی تطبیقی در پیش بینی سری زمانی استفاده شده است و نتایج حاصل از شبیه سازی روش ترکیبی برای پیش بینی بر سری های زمانی آشوبناک Mackey-Glass و Sunspot Number و فرایندهای آشوبناک Lorenz و Rossler با روش های قبلی براساس معیارهای هایکین [۴] مقایسه شده اند تا اثر روش جدید در صحت پیش بینی را اثبات کنند.

در ادامه این مقاله در بخش ۲، کارهای گذشته مرور شده است. در بخش ۳، پیش زمینه ای از الگوریتم رقابت استعماری، سیستم استنتاج عصبی - فازی تطبیقی و همچنین سیستم استنتاج عصبی - فازی تطبیقی بهبود یافته و الگوریتم های آموزش آن در مواجهه با مسائل پویا توصیف شده است. بخش ۴، روش پیشنهادی برای پیش بینی سری های زمانی را شرح می دهد. در بخش ۵، نتایج حاصل از پیاده سازی روش فوق روی سری های زمانی هدف، بررسی و نتایج با کارهای اخیر مقایسه شده اند. بخش آخر نیز خلاصه و نتیجه گیری را بیان می کند.

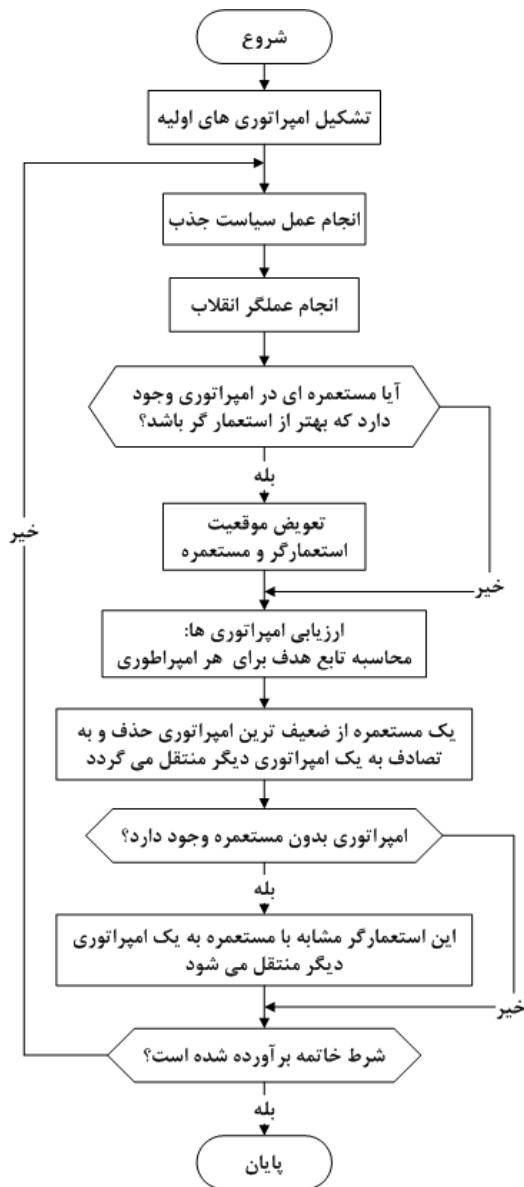
۲- کارهای گذشته

در حوزه سری های زمانی، روش های آماری و کلاسیک بسیاری ارائه شده است؛ ولی این روش ها اغلب پیچیده است و در مواجهه با داده های بسیار زیاد و آشوبی کارایی خوبی از خود نشان نمی دهند [۵، ۶]. محققان در سال های اخیر، روش های پیش بینی زیادی مانند شبکه های موجک [۷، ۸]، شبکه های عصبی [۹، ۱۰]، سیستم های فازی [۱۱، ۱۲]، عصبی - فازی [۱۳-۱۷] و الگوریتم های تکاملی [۱۸-۲۱] پدید آمده اند.

در سال های گذشته مطالعات زیادی مربوط به شبکه های عصبی تکراری [۲۲] (RNN) برای حل این مسائل با پویایی جذب و توانایی ذخیره سازی اطلاعات ارائه شده اند [۲۵-۲۲]؛ اما آموزش RNN، به خاطر ساختار شبکه پیچیده آن، در مقایسه با شبکه های پیشرو سخت تر است و محاسبات

شبکه های عصبی - فازی (FNNs) یکی از ساختارهای پیشنهاد شده برای پیش بینی سری های زمانی است [۳]. از میان این شبکه ها، سیستم استنتاج عصبی - فازی تطبیقی ANFIS^۱ یک شبکه عصبی تطبیقی بر پایه استنتاج فازی است که روال آموزش با بهینه سازی پارامترهای بخش مقدم و تالی آن صورت می گیرد. یک مشکل ذاتی در سیستم استنتاج عصبی - فازی تطبیقی وجود دارد. این مشکل ناشی از طبیعت پیش رونده آن است که باعث محدود شدن توانایی آن به مدل سازی مسائل ایستا می شود. به این دلیل نمی توان از آن با موفقیت در مسائل پویا مانند پیش بینی سری های زمانی استفاده کرد.

در این مقاله تلاش شده است روشی ارائه شود تا بر محدودیت های ذاتی و ساختاری سیستم استنتاج عصبی - فازی تطبیقی در مسائل پویا غلبه کند و علاوه بر این، پارامترهای بخش مقدم را به روشی سریع تر و آسان تر از روش مبتنی بر گرادین به روزرسانی کند؛ به گونه ای که مشکلات ناشی از به روزرسانی پارامترها با روش های مبتنی بر گرادین را نداشته باشد. به منظور دستیابی به این ساختار برای سیستم عصبی - فازی، یک ارتباط خودبازخورد معرفی شده است. طبیعت تکراری سیستم استنتاج عصبی - فازی تطبیقی، اطلاعات حالات قبلی سیستم را ذخیره کرده است و بدین صورت به بازخورد خروجی های مشتق شده از فرایند استنتاج فازی به لایه ورودی شبکه برای ایجاد یک رابطه زمانی بین ورودی های فعلی و خروجی مرحله قبل قادر خواهد بود. این بازخورد در همان مرحله باعث غلبه کردن بر محدودیت های حافظه می شود که یک بخش بسیار مهم برای کاربرد پیش بینی سری های زمانی است. همچنین در فرایند یادگیری و تطابق پارامترهای سیستم استنتاج عصبی - فازی تطبیقی، از الگوریتم ترکیبی رقابت استعماری^۲ ICA و تخمین حداقل مربعات^۳ LSE استفاده شده است. این الگوریتم ضمن شناسایی و ایجاد ساختار بهینه، بهترین روش پیش بینی متغیرهای ورودی سیستم را نیز به منظور پیش بینی مقادیر آتی متغیر هدف، شناسایی و پیشنهاد می کند. علاوه بر این، سایر ویژگی های روش های مستقل از مشتق را نیز دارا است. بیشتر بهبودهای پیشنهاد شده برای سیستم استنتاج عصبی - فازی تطبیقی در



شکل (۱): فلوچارت الگوریتم ICA

مشابه با سایر الگوریتم‌های تکاملی، ICA با جمعیت اولیه تصادفی و تابع هدفی آغاز می‌شود که برای همه آن‌ها محاسبه شده است. قوی‌ترین کشورها، استعمارگر^{۲۱} و کشورهای ضعیف‌تر، مستعمره‌های این استعمارگرها انتخاب می‌شوند. سپس بین استعمارگرها برای گرفتن مستعمره‌های بیشتر، رقابت صورت می‌گیرد. بهترین استعمارگر، شانس بیشتری برای داشتن مستعمره‌های بیشتر دارد. سپس هر استعمارگر با مستعمره‌های خود، امپراتوری تشکیل می‌دهد.

بیشتری نیاز دارد. علاوه بر این، ثابت شده است که در ساختار شبکه‌های پیش‌رونده، کارایی شبکه‌های عصبی - فازی نسبت به شبکه‌های عصبی بهتر است [۲۶، ۲۷]. محققان برای غلبه بر این مشکل ساختاری در شبکه‌های عصبی - فازی پیش‌رو، تلاش کردند تا شبکه عصبی - فازی تکراری را با تشکیل بازخوردهای^{۱۴} داخلی و تأخیر زمانی بسازند و برای کنترل، شناسایی و پیش‌بینی سیستم‌ها استفاده شوند [۲۸-۳۱].

انواع گوناگونی از شبکه‌های عصبی تکراری همراه با الگوریتم‌های یادگیری خود ارائه شده‌اند؛ مانند الگوریتم یادگیری مبتنی بر گرایان^{۱۵} GD [۳۲]، الگوریتم‌های ژنتیک^{۱۶} (GAs) و مبتنی بر تکامل [۳۳]. بسیاری از این روش‌های یادگیری به صورت تکی بوده‌اند و با توجه به ترکیبی نبودن، مشکلاتی در آموزش آن‌ها وجود دارد. آموزش این شبکه در بخش مقدم^{۱۷} بسیار مشکل‌تر از بخش تالی^{۱۸} است؛ زیرا بیشتر روش‌های آموزش پارامترهای بخش مقدم، مبتنی بر گرایان بوده است و محاسبات گرایان در هر مرحله بسیار مشکل هستند و همچنین ممکن است باعث فرارگرفتن در بهینه محلی^{۱۹} شود.


پیش از این، کارها و تحقیقات مشابهی برای پیش‌بینی و شناسایی با استفاده از شبکه عصبی تکراری مبتنی بر موجک (WRFNN) انجام شده است [۳۴]، همچنین سیستم استنتاج عصبی - فازی تطبیقی خودبازخورد با یک الگوریتم جست‌وجوی دسته‌ای محلی^{۲۰} [۳۵] صورت گرفته است.

۳- پیش‌زمینه

۳-۱- الگوریتم بهینه‌سازی رقابت استعماری

الگوریتم رقابت استعماری ICA [۳۶] یک الگوریتم جست‌وجوی تکاملی جدید، مبتنی بر تکامل سیاسی اجتماعی است که با در نظر گرفتن پدیده استعمار به‌عنوان جزئی جدانشدنی از سیر تکامل تاریخی انسان و بررسی چگونگی اثرگذاری آن بر کشورهای استعمارگر و مستعمره و نیز کل تاریخ، از منبعی الهام‌بخش برای ایجاد یک الگوریتم کارا و نو در زمینه محاسبات تکاملی استفاده می‌شود. شکل (۱) فلوچارت الگوریتم ICA را نشان می‌دهد.

زاویه تصادفی نیز به جهت حرکت مستعمره، اضافه می شود. شکل (۴) این حالت را نشان می دهد.



شکل (۴): اصلاح حرکت مستعمره ها به سمت امپراتوری خود


این بار به جای حرکت به اندازه a به سمت کشور استعمارگر و در جهت بردار واصل مستعمره به استعمارگر، به همان میزان، ولی با انحراف θ در مسیر، به حرکت خود ادامه می دهیم. θ به صورت تصادفی و با توزیع یکنواخت در نظر گرفته شده است.

$$\theta \sim U(-\gamma, \gamma) \quad (2)$$

افزایش γ باعث افزایش جست و جوی اطراف امپریالیست شده است و کاهش آن نیز باعث می شود تا مستعمره ها تا حد ممکن، نزدیک به بردار واصل مستعمره به استعمارگر حرکت کنند.

در شرایط مختلفی ممکن است همگرایی زودرس رخ دهد: جمعیت به یک بهینه محلی همگرا شود یا الگوریتم جست و جو به آرامی پیش رود. در الگوریتم ICA، از عملگر انقلاب برای ایجاد تنوع در جمعیت، جلوگیری از گیرکردن در بهینه محلی و همگرایی زودرس استفاده شده است. برای پیاده سازی عملگر انقلاب و بهادادن بیشتر به کاوش^{۲۰}، محوریت حرکت در راستای استعمارگر حذف می شود و به طور تصادفی به بعضی از کشورهای مستعمره اجازه داده می شود در برخی از ویژگی های خود تغییرات کاملاً تصادفی انجام دهند. این تغییرات باعث می شود کشورهای مستعمره موقعیت های جدیدی را تجربه کنند که باعث افزایش قدرت کاوش فضای جست و جو می شود. در این مقاله عملگر انقلاب، سپس عملگر جذب روی برخی از مستعمره ها به صورت تصادفی اعمال می شود. در این مقاله، عملگر انقلاب علاوه بر مستعمره ها، روی استعمارگر هر امپراتوری نیز اعمال می شود.

شکل (۲) جمعیت اولیه هر امپراتوری را نشان می دهد. در این شکل امپراتوری ۱، قوی ترین است و مستعمره^{۲۲} بیشتری دارد.




شکل (۲): تشکیل امپراتوری های اولیه

بعد از تقسیم بندی مستعمره ها بین استعمارگرها، این مستعمره ها به کشور استعمارگر خود نزدیک می شوند (سیاست جذب^{۲۳})؛ که این در شکل (۳) نشان داده شده است. بر اساس این، هر مستعمره به سمت استعمارگر خود به اندازه a واحد حرکت می کند و موقعیت جدیدی به دست می آورد که در آن a یک متغیر تصادفی با توزیع نرمال است و β عددی بزرگ تر از یک و نزدیک به ۲ است.

یک انتخاب مناسب می تواند $\beta = 2$ باشد. وجود ضریب $\beta > 1$ باعث می شود تا مستعمره در حین حرکت به سمت استعمارگر، از جهت های مختلف به آن نزدیک شود.

$$\alpha \sim U(0, \beta \times d) \quad (1)$$



شکل (۳): حرکت مستعمره ها به سمت امپراتوری خود


برای افزایش سرعت همگرایی^{۲۴} و صحت ICA، در این مقاله از الگوریتم اصلاح شده ICA استفاده شده است. برای اصلاح الگوریتم ICA معرفی شده و افزایش تنوع در جمعیت، در حرکت مستعمره ها به سمت استعمارگر، کمی

هزینه یکسانی با استعمارگری دارند که آن‌ها را کنترل می‌کند؛ این بدان معنی است که الگوریتم به بهترین جواب همگرا شده است. در روش ارائه شده، شرط خاتمه الگوریتم، پایان یافتن تعداد تکرار از پیش تعیین شده است.

۳-۲- سیستم استنتاج عصبی - فازی تطبیقی

در این قسمت، توپولوژی و ساختار سیستم استنتاج عصبی - فازی تطبیقی توضیح داده می‌شود. هر دوی شبکه‌های عصبی و سیستم‌های فازی [۳۷]، توانایی‌های مشترک خود را برای مقابله با عدم قطعیت و نویز به اشتراک می‌گذارند. شبکه‌های عصبی - فازی تطبیقی، مانند سیستم‌های فازی، دو قسمت را ساماندهی می‌کند. قسمت نخست، بخش مقدم و قسمت دوم، بخش تالی است که با قوانین به صورت شبکه به یکدیگر متصل می‌شوند. شکل (۵) ساختار سیستم استنتاج عصبی - فازی تطبیقی نوع ۳ با دو ورودی را نشان می‌دهد. ساختار این سیستم از ۵ لایه تشکیل شده است [۳۸].

لایه اول، فرایند فازی‌سازی را انجام می‌دهد. در این لایه هر گره یک تابع عضویت را نشان می‌دهد که پارامترهای آموزش‌پذیر بخش مقدم هستند. در لایه دوم، میزان قدرت آتش^{۳۷} هر قانون محاسبه می‌شود. در لایه سوم، قدرت آتش هر قانون با توجه به قدرت آتش قوانین دیگر نرمال می‌شود. در لایه چهارم، خروجی هر یک از قوانین به دست می‌آید و در نهایت، لایه آخر، خروجی سیستم فازی را با جمع کردن خروجی‌های لایه چهارم محاسبه می‌کند.



شکل (۵): ساختار سیستم استنتاج عصبی - فازی تطبیقی نوع ۳ با دو ورودی و یک خروجی

در این شکل دو برجسب برای هر ورودی نشان داده شده است. مطابق با نوع ۳، قوانین به صورت زیر هستند:

$$w_i = \mu_{A_i}(x) \times \mu_{B_i}(y), i = 1, 2 \quad (4)$$

بعد از اعمال عملگرهای جذب و انقلاب، ممکن است بعضی از مستعمره‌ها به موقعیتی بهتر از استعمارگر خود برسند (نقاطی که هزینه کمتری را نسبت به مقدار تابع هزینه در موقعیت استعمارگر داشته باشد). در این حالت، کشورهای استعمارگر و مستعمره، جای خود را با همدیگر عوض می‌کنند و الگوریتم با کشور استعمارگر در موقعیت جدید ادامه پیدا می‌کند (رقابت درون‌گروهی).

پس از این مرحله، قدرت کل یک امپراتوری محاسبه می‌شود. قدرت هر امپراتوری، وابسته به قدرت کشور استعمارگر و درصدی از قدرت کلیه کشورهای مستعمره آن امپراتوری است. قدرت کل امپراتوری n به صورت فرمول (۳) تعریف می‌شود.

$$Cost(Emp_n) = Cost(Imperialist_n) + \xi \cdot \text{mean}\{Cost(Colony_of_empire_n)\} \quad (3)$$

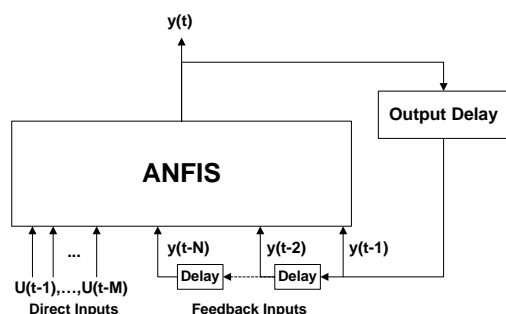
که ξ عددی مثبت است که معمولاً بین صفر و یک و نزدیک به صفر در نظر گرفته می‌شود.

در ادامه، تمام امپراتوری‌ها براساس معیار قدرت کل امپراتوری، با یکدیگر رقابت می‌کنند. بدین صورت که هر امپراتوری سعی می‌کند مستعمرات دیگر امپراتوری‌ها را در اختیار بگیرد و آن را کنترل کند. اساس رقابت استعماری در این مرحله انجام می‌شود که براساس آن، قدرت امپراتوری‌های ضعیف کم می‌شود و قدرت امپراتوری‌های قوی افزایش می‌یابد. در این مقاله، رقابت استعماری بدین صورت پیاده‌سازی می‌شود که یک مستعمره از ضعیف‌ترین امپراتوری جدا می‌شود و یک رقابت بین سایر امپراتوری‌ها برای در اختیار قرار گرفتن آن مستعمره تشکیل می‌شود. در روش ارائه شده، برای انتخاب امپراتوری برنده، برای گرفتن مستعمره از روش چرخ گردان^{۳۶} استفاده شده است. زمانی که یک امپراتوری کلیه مستعمره‌هایش را از دست داد، سقوط می‌کند. در روش ارائه شده، با استعمارگر امپراتوری سقوط کرده نیز مانند یک مستعمره آزاد رفتار می‌شود و آن نیز بین سایر امپراتوری‌ها به رقابت گذاشته می‌شود.

پس از مدتی، کلیه امپراتوری‌ها به جز قوی‌ترین سقوط می‌کند و تمام مستعمره‌ها در کنترل یک امپراتوری یکتا خواهند بود. در حالت ایدئال، کلیه مستعمره‌ها موقعیت و

که $U(t-1), \dots, U(t-M)$ ورودی‌های مستقیم و $y(t-1), \dots, y(t-N)$ ورودی‌های بازخورد داده شده

از خروجی در زمان‌های مختلف هستند.



شکل (۶): ساختار سیستم استنتاج عصبی - فازی تطبیقی با بازخورد خروجی [۳۹]

۳-۲-۲- یادگیری سیستم استنتاج عصبی - فازی

پس از توسعه سیستم استنتاج عصبی - فازی تطبیقی، روش‌هایی برای آموزش پارامترهای آن پیشنهاد شد. به‌طور مثال در [۴۰]، روش ادغام *Min-Max* و مدل *ANFIS* برای تعیین شبکه عصبی - فازی و تعیین مجموعه قوانین بهینه سیستم فازی پیشنهاد شده است. *Jang* و *Mizutani* [۴۱]، کاربرد *Lavenbrg-Marquardt* را پیشنهاد دادند که اساساً یک روش حداقل مربعات غیرخطی است. برای یادگیری سیستم استنتاج عصبی - فازی تطبیقی، در مقاله‌ای دیگر *Jang* [۴۲]، طرحی را برای انتخاب ورودی ارائه داد. *Jang* در مقاله معروف خود [۳۸]، چهار روش برای به‌روزرسانی پارامترهای سیستم ارائه کرد: (۱) گرادیان نزولی: همه پارامترها با کمک گرادیان نزولی آموزش ببینند؛ (۲) گرادیان نزولی و یک مرحله تخمین حداقل مربعات *LSE* در گام اول برای مقداردهی اولیه به پارامترهای بخش تالی استفاده می‌شود؛ سپس گرادیان نزولی، تمام پارامترها را به‌روزرسانی می‌کند؛ (۳) گرادیان نزولی و *LSE*: بخش مقدم با گرادیان نزولی و بخش تالی با *LSE* آموزش می‌بینند؛ (۴) *LSE* ترتیبی: این روش تمام پارامترها را خطی می‌کند و از الگوریتم فیلتر - کالمن توسعه یافته برای به‌روزرسانی پارامترها استفاده می‌کند.

روش‌هایی که تا کنون مطرح شد، وابسته به گرادیان هستند و به دلیل عملکرد مناسب هنوز هم به‌کاربرده

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

$$\left. \begin{aligned} f_1 &= a_1x + b_1y + c_1 \\ f_2 &= a_2x + b_2y + c_2 \end{aligned} \right\} \Rightarrow f = \frac{w_1f_1 + w_2f_2}{w_1 + w_2} \quad (6)$$

$$= \bar{w}_1f_1 + \bar{w}_2f_2$$

سیستم استنتاج عصبی - فازی تطبیقی توانایی زیادی در تقریب‌سازی دارد که به توانایی آن در تقسیم‌بندی فضای ورودی با تعیین توابع عضویت در بخش مقدم برای هر ورودی وابسته است.

اینجا از تابع عضویت گوسی استفاده می‌کنیم.

$$\mu_{A_i}(x) = e^{-\frac{1}{2} \left(\frac{x - m_i}{\sigma_i} \right)^2} \quad (7)$$

مجموعه پارامترهای بخش مقدم $\{m_i, \sigma_i\}$ و مجموعه پارامترهای بخش تالی هستند. $\{a_i, b_i, c_i\}$

۳-۲-۱- سیستم استنتاج عصبی - فازی تطبیقی خودبازخورد

در این مدل، ویژگی پویایی با حلقه خودبازخورد خروجی مراحل قبل به دست می‌آید. این بازخورد، سیستم را قادر می‌سازد تا حالت‌های قبلی خود را یادآوری و از هر دوی حالات قبلی و فعلی برای محاسبه مقادیر جدید استفاده کند. از نظر علمی، تأخیر زمانی تعبیه شده با بازخورد به خود هم نوع است و به رفتار متفاوت دینامیکی منجر می‌شود. چنین رفتاری در بهبود توانایی برای ارائه قابلیت پیش‌بینی بهتر و دقیق‌تر حیاتی است.

برای غلبه مؤثر بر مشکلات سیستم استنتاج عصبی - فازی تطبیقی در مسائل پویا، خروجی شبکه پیش‌رونده مانند شکل (۶) به ورودی‌های سیستم بازخورد داده می‌شود. با بازخورد خروجی مراحل قبل، خروجی در لحظه t ، به‌صورت تابعی از ورودی‌های مستقیم و ورودی و خروجی‌های قبلی تعریف شده است و به‌صورت رابطه (۸) داده می‌شود.

$$y(t) = f[U(t-1), \dots, U(t-M), y(t-1), y(t-2), \dots, y(t-N)] \quad (8)$$

اندازه‌گیری‌های انجام‌شده از متغیرهای دینامیکی سیستم دارند. از طرفی، این نقاط اطلاعات کامل در مورد حالت فعلی سیستم دارند؛ بنابراین، وجود رابطه یک‌به‌یک بدین معناست که با اندازه‌گیری‌های انجام‌شده، حالات فضای فاز شناسایی می‌شوند؛ از این رو، باید به دنبال نگاهی از جاذب سیستم به فضای بازسازی‌شده بود؛ به طوری که این نگاهت یک‌به‌یک است و اطلاعات سیستم را حفظ می‌کند. این در واقع، تعریف مفهومی محاط است. با استفاده از تئوری تاکنر در بازسازی فضای حالت از روی سری‌های زمانی آشوبی [۴۶]، فضای حالت سیستم به کمک دو پارامتر بعد محاط D و زمان تأخیر τ بازسازی می‌شوند. در صورتی که سری زمانی به صورت $\{x(1), x(2), \dots, x(N)\}$ باشد، یک بردار فاز تعبیه‌شده $u(i)$ به صورت زیر است:

$$u(i) = [x(i) \quad x(i - \tau) \quad \dots \quad x(i - (D-1)\tau)] \quad (9)$$

که $\forall i \in [1 + (D-1)\tau, N]$ بعد محاط، τ تأخیر زمانی و $u(i)$ فضای فاز D بعدی است. بر اساس این، ماتریس ورودی به صورت فرمول (۱۰) تعریف می‌شود.

$$U = \begin{bmatrix} x(i) & x(i+1) & \dots & x(i+m) \\ x(i-\tau) & x(i+1-\tau) & \dots & x(i+m-\tau) \\ \vdots & \vdots & \ddots & \vdots \\ x(i-(D-1)\tau) & x(i+1-(D-1)\tau) & \dots & x(i+m-(D-1)\tau) \end{bmatrix} \quad (10)$$

که $i \in [1 + (D-1)\tau, N - m - k]$ یک عدد صحیح، و k تعداد مراحل پیش‌بینی‌شده است. برای استخراج رفتار سری زمانی به یک روش کارآمد، مقادیر بهینه D و τ باید تعیین شوند. برای سری‌های زمانی آزمایش‌شده در این مقاله، این مقادیر به ترتیب با کاربرد روش‌های میانگین اطلاعات متقابل [۴۷] و شمارش نزدیک‌ترین همسایه‌های کاذب [۱] تعیین شده‌اند.

• **گام دوم:** دریافت ماتریس سری زمانی به عنوان ورودی مستقیم، و خروجی بازخوردشده از مراحل قبلی به عنوان ورودی بازخورد به ساختار سیستم استنتاج عصبی - فازی تطبیقی. ورودی مستقیم به ساختار سیستم استنتاج عصبی - فازی تطبیقی بهبودیافته، ماتریسی با بردار فاز تعبیه‌شده ستون و سری زمانی آشوبناک به عنوان ردیف است. ورودی مستقیم ماتریس به صورت زیر است:

می‌شوند. روش‌هایی که وابسته به حداقل مربعات هم بودند، روش‌هایی مؤثر بر بهینه‌سازی پارامترهای بخش تالی هستند که هنوز به کار برده می‌شوند. پارامترهای بخش مقدم اهمیت زیادی در آموزش دارند و روش‌های موجود به دلیل پیچیدگی بالا در محاسبات گرادیانی و با توجه به حضور غیرخطی پارامترهای مقدم در خروجی، مناسب به نظر نمی‌رسند. برای رفع این مشکل، روش‌های مبتنی بر جمعیت مطرح می‌شود؛ به طور مثال، روش‌های الگوریتم‌های ژنتیک، بهینه‌سازی گروهی ذرات، کلونی‌های مورچگان و دیگر روش‌های وابسته [۴۳، ۲۸]. کارهای زیادی برای آموزش شبکه‌های عصبی - فازی با ترکیب الگوریتم‌های تکاملی و روش‌های گرادیان نزولی، حداقل مربعات و فیلتر کاملن مطرح شده است. به عنوان نمونه در [۴۴] الگوریتم PSO در آموزش بخش مقدم و گرادیان نزولی در بخش تالی به کارگیری شده است. در [۴۵] آموزش بخش مقدم با PSO و بخش تالی با حداقل مربعات صورت می‌گیرد.

در این مقاله برای آموزش پارامترهای سیستم استنتاج عصبی - فازی تطبیقی روشی ارائه شده است که پیچیدگی کمتر و صحت بیشتری دارد و در آن، آموزش پارامترهای بخش مقدم و تالی به صورت یک‌روال تکراری با الگوریتم تکاملی رقابت استعماری ICA و حداقل مربعات LSE صورت می‌گیرد. در بخش بعدی سیستم استنتاج عصبی - فازی تطبیقی بهبودیافته برای پیش‌بینی ارائه شده است.

۴- روش پیشنهادی

در این بخش، الگوریتم روش پیشنهادی برای پیش‌بینی سری زمان به صورت مرحله‌به‌مرحله شرح داده می‌شود.

• **گام اول:** بازسازی فضای حالت سری زمانی آشوبی. در راستای مطالعه خواص هندسی و دینامیکی یک سیستم معین از توصیف فضای حالت استفاده شده است. یکی از اساسی‌ترین گام‌ها در تحلیل سری‌های زمانی حاصل از یک فرآیند غیرخطی، بازسازی فضای حالت با ابعاد محدود با استفاده از این سری‌ها است؛ به طوری که با فضای حالت فرآیند مولد داده‌ها معادل باشد. با نظریه محاط، مسئله بازسازی فضای حالت از سری زمانی حل می‌شود. در واقع، نقاط روی جاذب سیستم رابطه‌ای یک‌به‌یک با

(۳) انتخاب بهترین کشورهای استعمارگر اولیه و بقیه کشورهای مستعمره (در این مقاله برای انتخاب مستعمره برای هر امپراتوری، از روش نمونه برداری عمومی اتفاقی^{۲۸} SUS استفاده شده است).

• مرحله ۲: (اعمال عملگرها)

اعمال عملگرهای جذب و انقلاب برای مجموعه پارامترهایی که در هر تکرار به روزرسانی می شوند. به طور مثال در تکرار اول، پارامتر m_i و در تکرار دوم، پارامتر σ_i به روزرسانی می شود و در نهایت پس از به روز شدن کلیه پارامترها، مجدد به روزرسانی پارامتر اول از سر گرفته می شود و به همین ترتیب ادامه پیدا می کند. با هر تغییر در پارامترهای بخش مقدم، پارامترهای بخش تالی نیز با LSE تخمین زده می شوند.

• مرحله ۳: (رقابت درون گروهی)

در صورتی که بعد از اعمال عملگرها به پارامترهای اولیه، بعضی از مستعمره ها به موقعیتی بهتر از استعمارگر خود برسند (نقاطی که هزینه کمتری نسبت به استعمارگر داشته باشند)، موقعیت استعمارگر و مستعمره باهم عوض می شود و الگوریتم با استعمارگر در موقعیت جدید ادامه پیدا می کند.

• مرحله ۴: (محاسبه قدرت کل هر امپراتوری)

قدرت کل هر امپراتوری براساس رابطه (۳) محاسبه می شود. در این مسئله، هدف حداقل کردن اختلاف بین خروجی سیستم استنتاج عصبی - فازی تطبیقی و خروجی واقعی است و تابع هدف برای هر امپراتوری، به صورت تابع هزینه و فرمول (۱۳) تعریف می شود.

$$\text{Cost}(\text{colony}_i) = \frac{1}{2.N} \sum_{i=1}^N (y - \hat{y})^2 \quad (13)$$

• مرحله ۵: (رقابت استعماری)

امپراتوری ها براساس معیار قدرت کل امپراتوری با یکدیگر رقابت می کنند. یک مستعمره از ضعیف ترین امپراتوری جدا می شود و یک رقابت بین سایر امپراتوری ها برای در اختیار قرار گرفتن آن شکل می گیرد. امپراتوری که کلیه مستعمره هایش را از دست داد، سقوط می کند. در این مقاله با استعمارگر امپراتوری سقوط کرده نیز مانند یک

$$U = [u^T(i) \ u^T(i+1) \ \dots \ u^T(i+m)]^T \quad (11)$$

ابعاد ماتریس ورودی مستقیم $(m+1) \times D$ است و $i \in [1+(D-1)\tau, N-m-k]$ تعداد مراحل پیش بینی شده است.

ورودی بازخورد در زمان t از مرتبه M به صورت زیر است:

$$Y(t) = [y(t-1) \ y(t-2) \ \dots \ y(t-M)] \quad (12)$$

ابعاد ماتریس ورودی بازخورد $(m+1) \times M$ است.

• گام سوم: آموزش سیستم استنتاج عصبی - فازی تطبیقی بهبود یافته با بازخورد خروجی از مرحله قبل در یکروال تکراری با الگوریتم ترکیبی رقابت استعماری ICA و تخمین حداقل مربعات LSE است. این فرایند آموزش ترکیبی برای تعیین پارامترهای بخش مقدم و تالی سیستم استنتاج عصبی - فازی تطبیقی به منظور افزایش دقت پیش بینی به کار می رود. هرگاه تعداد مراحل مدنظر انجام شده یا خطای آموزش مدنظر حاصل شده باشد، فرایند آموزش متوقف می شود. در این روال در هر مرحله از خروجی های M ، مرحله قبل به عنوان ورودی های بازخورد داده شده به سیستم استنتاج عصبی - فازی تطبیقی استفاده شده است. پس از تعریف داده های آموزش، داده های وارسی، تعداد مراحل آموزش و نوع توابع عضویت سیستم استنتاج فازی، مقادیر بهینه پارامترهای بخش مقدم در هر مرحله با ICA تعیین می شوند و پس از این مرحله، پارامترهای بخش نتیجه سیستم استنتاج عصبی - فازی تطبیقی بهبود یافته با LSE تخمین زده می شوند. این الگوریتم در هفت مرحله انجام می شود:

• مرحله ۱: (تشکیل امپراتوری های اولیه)

(۱) مقداردهی اولیه به پارامترهای تابع عضویت ورودی $\{m_i, \sigma_i\}$ (در صورتی که توابع عضویت از نوع گوسی باشند) به صورت تصادفی و بر اساس آن، تخمین پارامترهای بخش تالی $\{a_i, b_i, c_i\}$ با LSE.

(۲) محاسبه شایستگی کشورها براساس معیار میانگین مربعات خطا (MSE).

به کار می روند. برای ارزیابی عددی صحت پیش بینی معیارهای زیر استفاده می شوند.

$$RMSE = \sqrt{\frac{1}{N} \sum_{n=1}^N (y(n) - \hat{y}(n))^2} \quad (14)$$

$$NMSE = \sum_{n=1}^N \frac{(y(n) - \hat{y}(n))^2}{(y(n) - \bar{y})^2}, \quad (15)$$

$$\bar{y} = \frac{1}{N} \sum_{n=1}^N y(n)$$

که $y(n)$ و $\hat{y}(n)$ به ترتیب مقدار واقعی و مقدار پیش بینی شده و N تعداد کل نمونه ها هستند.

الف) سری زمانی Mackey-Glass

سری زمانی Mackey-Glass با معادله دیفرانسیل تأخیر زمانی (۱۶) و یک مدل برای تولید گلبول های سفید خون ارائه می شود.

$$\frac{dx}{dt} = \frac{0.2 x(t-\lambda)}{1+x^{10}(t-\lambda)} - 0.1 x(t) \quad (16)$$

این سری زمانی بسیار حساس به شرایط اولیه است و رفتار آن برای $\lambda \geq 16.8$ آشوبناک است و هیچ دوره به وضوح مشخص ندارد. این سری زمانی در تحقیقات مدل سازی شبکه های عصبی و فازی متعددی استفاده شده است. در اینجا $\lambda = 17$ و $x(0) = 1.2$ هستند. مقادیر استاندارد برای بازسازی فضای حالت این سری زمانی به ترتیب $\tau = 6$ و $D = 4$ هستند که به ترتیب با روش های میانگین اطلاعات متقابل و شمارش نزدیک ترین همسایه های کاذب به دست می آیند. بنابراین فضای فاز این سری به صورت $x(t), x(t-6), x(t-12), x(t-18)$ برای پیش بینی $x(t+6)$ (پیش بینی ۶ گام جلوتر) بازسازی می شود. ۵۰٪ از داده ها برای آموزش، ۲۰٪ برای بررسی و ۳۰٪ از آن برای آزمون استفاده می شوند.

مدل پیشنهادی برای پیش بینی این سری زمانی با پارامترهای ذکر شده در جدول (۱) آموزش می بیند. نمودار همگرایی و کاهش خطای روش پیشنهادی در شکل (۸) نشان داده شده است. مقادیر واقعی و پیش بینی شده سری زمانی تست در شکل (۹) و نمودار خطای پیش بینی در شکل (۱۰) نشان داده شده اند.

مستعمره آزاد رفتار می شود و آن نیز بین سایر امپراتوری ها به رقابت گذاشته می شود.

- مرحله ۶: در این مرحله، استعمارگر بهترین امپراتوری با جواب در هر تکرار الگوریتم انتخاب شده است و سیستم پیشنهادی با پارامترهای بخش مقدم گذشته در این جواب و پارامترهای بخش نتیجه تخمین زده شده از LSE به روزرسانی می شود. در این مرحله، به منظور جلوگیری از آموزش زیاد دیدن مدل از مجموعه داده های واری استفاده می شود.
- مرحله ۷ (خاتمه): در صورتی که شرط خاتمه برآورده شده باشد یا به نتیجه منتظر رسیده باشد، الگوریتم خاتمه پیدا می کند.

شکل (۷) ساختار الگوریتم آموزش پیشنهادی را نشان می دهد.




شکل (۷): ساختار الگوریتم آموزش پیشنهادی

۵- نتایج عددی

برای ارزیابی روش پیشنهادی، آزمایش ها و شبیه سازی های جامعی با سیستم استنتاج عصبی - فازی تطبیقی خودبازخورد آموزش یافته با الگوریتم آموزش پیشنهادی صورت گرفت. در تمام موارد، ۵۰٪ داده ها برای آموزش، ۲۰٪ برای بررسی و ۳۰٪ بقیه برای آزمون مدل

داده شده است. سطر آخر این جدول، نتایج روش پیشنهادی را نشان می‌دهد. نتایج، نشان‌دهنده برتری و کارایی بهتر روش ارائه شده برای پیش‌بینی این سری زمانی آشوبناک هستند.



شکل (۱۰): نمودار خطای پیش‌بینی برای سری زمانی

Mackey-Glass


جدول (۲): مقایسه کارایی پیش‌بینی سری زمانی

Mackey-Glass

Method	RMSE Train	RMSE Test
Auto-regressive model [37]	-	0.19
Cascade correlation NN [37]	-	0.06
Back propagation NN [37]	-	0.02
Linear prediction method [37]	-	0.55
Product T-norm [26]	-	0.09
Classical RBF (with 23 neurons) [48]	-	0.0114
PG-RBF network [49]	-	0.0028
Genetic algorithm and fuzzy system [50]	-	0.049
Neural tree model [51]	-	0.0069
WNN [37]+gradient	0.0067	0.0071
LLWNN [37]+gradient	0.0038	0.0041
LLWNN [37]+hybrid	0.0033	0.0036
Recurrent ANFIS [52]	-	0.0013
ANFIS [38]	-	0.00156
RBF network [53]	-	0.0015
Ensembles of ANFIS [54]	-	0.0025
Fuzzy prediction based on SVD [10]	-	0.012
LS-SVM based on PSO [55]	-	0.0028
LLNF[56]	0.0013	0.0020
LNF with LSSVMs[57]	0.00070	0.00079
ICA-ANFIS	0.0011	0.0011
Improved ICA-ANFIS	0.00015	0.00016


جدول (۱): پارامترهای روش پیشنهادی

پارامتر	نوع یا مقدار
N تعداد ورودی‌های بازخورد	2
تعداد خوشه‌ها	20
تعداد کشورها	50
تعداد امپراتوری‌ها	10
تعداد مراحل	100
α	2
β	2
احتمال انقلاب	0.2
μ	0.05
ξ	0.01



شکل (۸): نمودار همگرایی برای سری زمانی

Mackey-Glass




شکل (۹): مقادیر هدف و پیش‌بینی شده سری زمانی

Mackey-Glass

به منظور ارزیابی عددی این روش با روش‌های قبلی برای پیش‌بینی، RMSE آموزش و تست روش پیشنهادی و برخی از روش‌های ارائه شده در مقالات در جدول (۲) نشان

به منظور ارزیابی عددی این روش با روش‌های قبلی برای پیش‌بینی، NMSE آموزش و تست روش پیشنهادی و تعدادی از روش‌های ارائه شده در مقالات در جدول (۳) نشان داده شده‌اند. سطر آخر این جدول، نتایج روش پیشنهادی را نشان می‌دهد. نتایج، نشان‌دهنده برتری و کارایی بهتر روش ارائه شده برای پیش‌بینی این سری زمانی آشوبناک هستند.



شکل (۱۳): نمودار خطای پیش‌بینی برای سری زمانی

Lorenz

جدول (۳): مقایسه کارایی پیش‌بینی سری زمانی Lorenz

Method	NMSE Train	NMSE Test
MLP-EKF [58]	0.00023	0.00162
MLP-BLM [58]	0.00033	0.00096
RNN-BPTT [58]	0.00056	0.00185
RNN-RTRL [58]	0.00057	0.00172
RNN-EKF [58]	0.00036	0.00121
RBLM-RNN [58]	0.00036	0.00090
ANFIS[38]	0.0026	0.0021
Fuzzy prediction based on SVD [10]	-	0.0106
LS-SVM based on PSO [55]	-	0.00018
LLNF[56]	0.00013	0.00029
LNF with LSSVMs[57]	0.000017	0.000064
ICA-ANFIS	0.00007	0.00012
Improved ICA-ANFIS	0.0000051	0.000056

ج) سری زمانی Rossler

مدل Rossler سیستمی از سه معادله دیفرانسیل معمولی است که یک سیستم دینامیکی پیوسته را تعریف می‌کند؛ این


ب) سری زمانی Lorenz

سری زمانی Lorenz با سه معادلات دیفرانسیل فرمول (۱۷) تولید می‌شود.

$$\begin{cases} \dot{x} = a(y - x) \\ \dot{y} = \beta x - zx - y \\ \dot{z} = xy - yz \end{cases} \quad (17)$$


در $\alpha = 10, \gamma = 8/3, \beta > 24.74$ خروجی سیستم آشوبناک است. مقادیر استاندارد برای بازسازی فضای حالت این سری زمانی $\tau = 3$ و $D = 3$ هستند. در شبیه‌سازی برای مقایسه سری زمانی با سایر کارهای مشابه، سری زمانی $\alpha = 10, \beta = 28, \gamma = 8/3$ در نظر گرفته می‌شود.

متغیرهای ورودی $x(t-6), x(t-3), x(t)$ برای پیش‌بینی $x(t+3)$ هستند (پیش‌بینی سه‌گام جلوتر). این سری زمانی، با پارامترهای ذکر شده در جدول (۱) آموزش می‌بیند. نمودار همگرایی و کاهش خطای روش پیشنهادی در شکل (۱۱) نشان داده شده‌اند.




شکل (۱۱): نمودار همگرایی برای سری زمانی Lorenz

خروجی پیش‌بینی شده و نمودار خطای پیش‌بینی به ترتیب در شکل‌های (۱۲) و (۱۳) نشان داده شده‌اند.



شکل (۱۲): نمودار خروجی پیش‌بینی برای سری زمانی

Lorenz



شکل (۱۶): نمودار خطای پیش‌بینی برای سری زمانی Rossler

به منظور ارزیابی عددی این روش با روش‌های قبلی برای پیش‌بینی، NMSE آموزش و تست روش پیشنهادی و تعدادی از روش‌های ارائه شده در مقالات در جدول (۴) نشان داده شده‌اند. سطر آخر این جدول، نتایج روش پیشنهادی را نشان می‌دهند. نتایج، نشان‌دهنده برتری و کارایی بهتر روش ارائه شده برای پیش‌بینی این سری زمانی آشوبناک هستند.

جدول (۴): مقایسه کارایی پیش‌بینی سری زمانی Rossler

Method	NMSE Train	NMSE Test
MLP-EKF [58]	0.00025	0.00193
MLP-BLM [58]	0.00047	0.00101
RNN-BPTT [58]	0.00070	0.00311
RNN-RTRL [58]	0.00071	0.00312
RNN-EKF [58]	0.00060	0.00191
RBLM-RNN [58]	0.00057	0.00092
ANFIS[38]	0.0147	0.0118
LLNF[56]	0.000048	0.000071
LNF with LSSVMs[57]	0.0000065	0.000015
ICA-ANFIS	0.000083	0.00010
Improved ICA-ANFIS	0.0000007	0.000004

ج) سری زمانی تعداد لکه‌های خورشیدی Sunspot Number


سری زمانی تعداد لکه‌های خورشیدی، سری زمانی غیرثابت و بسیار پیچیده جهان واقعی است. این سری مربوط به تعداد نسبی متوسط سالانه از لکه‌های خورشیدی

سیستم نشان‌دهنده دینامیک آشوبناک مرتبط با خواص فراکتال از جذب Rossler است. سری زمانی Rossler با معادلات دیفرانسیل زیر تعریف می‌شود:


$$\begin{cases} \dot{x} = -y - z \\ \dot{y} = x - ay \\ \dot{z} = b + z(x - c) \end{cases} \quad (18)$$

برای رفتار سیستم آشوبناک می‌شود. مقادیر استاندارد برای بازسازی فضای حالت این سری زمانی $\tau = 2$ و $D = 3$ هستند.

متغیرهای ورودی $x(t-4), x(t-2), x(t)$ برای پیش‌بینی $x(t+2)$ هستند (پیش‌بینی دو گام جلوتر). این سری زمانی با پارامترهای ذکر شده در جدول (۱) آموزش می‌یابد. نمودار همگرایی و کاهش خطای روش پیشنهادی در شکل (۱۴) نشان داده شده است. خروجی پیش‌بینی شده و نمودار خطای پیش‌بینی به ترتیب در شکل‌های (۱۵) و (۱۶) نشان داده شده‌اند.




شکل (۱۴): نمودار همگرایی برای سری زمانی Rossler



شکل (۱۵): نمودار خروجی پیش‌بینی برای سری زمانی Rossler

پیشنهادی را نشان می‌دهد. نتایج، نشان‌دهنده برتری و کارایی بهتر روش ارائه شده برای پیش‌بینی این سری زمانی هستند.



شکل (۱۹): نمودار خطای پیش‌بینی برای سری زمانی Sunspot Number

جدول (۵): مقایسه کارایی پیش‌بینی سری زمانی Sunspot Number


Method	RMSE Train	RMSE Test
Tong and Lim [59]	0.097	0.097
Weigend [60]	0.082	0.086
Svarer [61]	0.090	0.082
Transversal net [62]	0.0987	0.0971
Recurrent net [62]	0.1006	0.0972
RFNN [63]	-	0.074
ANFIS [38]	0.0550	0.1915
FENN [64]	-	-
FWNN-S [65]	0.0895	0.1093
FWNN-R [65]	0.0796	0.1099
FWNN-M [65]	0.0828	0.0973
LLNF [56]	0.0714	0.087
LNF with LSSVMs [57]	0.050	0.063
Improved ICA-ANFIS	0.0046	0.0030

۶- نتیجه‌گیری

در این مقاله، یک نسخه بهبودیافته از سیستم استنتاج عصبی - فازی تطبیقی با بازخورد خروجی و آموزش یافته با الگوریتم رقابت استعماری ICA، برای پیش‌بینی سری‌های زمانی آشوبناک معرفی شد. بازخورد خروجی مراحل قبل،


مشاهده شده است. سری زمانی متوسط لکه‌های خورشیدی ثبت شده از سال ۱۷۰۰ تا ۱۹۷۹ در [۶۶] ارائه شده است.

مقادیر استاندارد برای بازسازی فضای حالت این سری زمانی $\tau = 1$ و $D = 4$ هستند؛ بنابراین متغیرهای ورودی $x(t-3), x(t-2), x(t-1), x(t)$ — برای پیش‌بینی $x(t+1)$ هستند (پیش‌بینی یک گام جلوتر). نمودار همگرایی و کاهش خطای روش پیشنهادی در شکل (۱۷) نشان داده شده‌اند.



شکل (۱۷): نمودار همگرایی برای سری زمانی Sunspot Number

مقادیر واقعی و پیش‌بینی شده سری زمانی تست در شکل (۱۸) و نمودار خطای پیش‌بینی در شکل (۱۹) نشان داده شده‌اند.



شکل (۱۸): نمودار خروجی پیش‌بینی برای سری زمانی Sunspot Number

به منظور ارزیابی عددی این روش با روش‌های قبلی برای پیش‌بینی، RMSE آموزش و تست روش پیشنهادی و تعدادی از روش‌های ارائه شده در مقالات در جدول (۵) نشان داده شده‌اند. سطر آخر این جدول، نتایج روش

- [6] Gooijer JGD., Hyndman RJ., "25 years of time series forecasting". International Journal of Forecasting, Vol. 22, No.3, pp. 443-473, 2006.
- [7] Bodyanskiy Y., Vynokurova O., "Hybrid adaptive wavelet-neuro-fuzzy system for chaotic time series identification", Information Sciences, Vol. 220, No. 0, pp.170-179, 2013.
- [8] Hsu CF., "Adaptive fuzzy wavelet neural controller design for chaos synchronization", Expert Systems with Applications, Vol. 38, No. 8, pp. 10475-83, 2011.
- [9] Leung H., Lo T., Wang S., "Prediction of noisy chaotic time series using an optimal radial basis function neural network", IEEE Transactions on Neural Networks, Vol. 12, No. 5, pp. 1163-1172, 2001.
- [10] Han M., Xi J., Xu S., Yin FL., "Prediction of chaotic time series based on the recurrent predictor neural network", IEEE Transactions on Signal Processing, Vol. 52, No. 12, pp. 3409-3416, 2004.
- [11] Lee CHL, Liu A., Chen WS., "Pattern discovery of fuzzy time series for financial prediction", IEEE Transactions on Knowledge and Data Engineering, Vol. 18, No. 5, pp. 613-625, 2006.
- [12] Gu H., Wang H., "Fuzzy prediction of chaotic time series based on singular value decomposition", Applied Mathematics and Computation, Vol.185, No. 2, pp. 1171-1185, 2007.
- [13] Ang K., Quek C., "Stock trading using rspop: A novel rough set-based neuro-fuzzy approach", IEEE Transactions on Neural Networks, Vol.17, No.5, pp.1301-1315, 2006.
- [14] Zaheeruddin, Garima, "A neuro-fuzzy approach for prediction of human work efficiency in noisy environment", Applied Soft Computing, Vol. 6, No. 3, pp. 283-294, 2006.
- [15] M. JLA., Snchez JMB., Lugilde DN., de Linares Fernndez C., de la Guardia CD., Snchez FA., "Forecasting airborne pollen concentration time series with neural and neuro-fuzzy models", Expert Systems with Applications, Vol. 32, No. 4, pp. 1218 – 1225, 2007.
- [16] Zhang J., Chung HH., Lo WL., "Chaotic time series prediction using a neuro-fuzzy system with time-delay coordinates", IEEE Transactions on Knowledge and Data Engineering, Vol. 20, No. 7, pp. 956-964, 2008.
- [17] Samanta B., "Prediction of chaotic time series using computational intelligence", Expert Systems with Applications, Vol. 38, No. 9, pp. 11406-11411, 2011.
- [18] Gromov VA., Shulga AN., "Chaotic time series prediction with employment of ant colony optimization", Expert Systems with Applications, Vol. 39, No. 9, pp. 8474-8478, 2012.
- [19] Niu D., Wang Y., Wu DD., "Power load forecasting using support vector machine and ant colony optimization", Expert Systems with Applications, Vol. 37, No. 3, pp. 2531-2539, 2010.

سیستم استنتاج عصبی - فازی تطبیقی را قادر می سازد تا با در نظر گرفتن یک حافظه بر محدودیت های ماهیت ایستای خود غلبه کند و توانایی آن در مقابله با مسائل پویا و تغییرات زمانی رخ داده در داده ها افزایش یابد. علاوه بر این، در روش پیشنهادی و فرایند آموزش سیستم استنتاج عصبی - فازی تطبیقی بهبود یافته، از الگوریتم ترکیبی رقابت استعماری ICA و تخمین حداقل مربعات LSE برای آموزش پارامترهای آن به کار گرفته شد که استفاده از این الگوریتم یادگیری باعث می شود ضمن حذف شدن مشکلات ناشی از به روزرسانی پارامترها با روش های مبتنی بر گرادیان، ساختار بهینه سیستم استنتاج عصبی - فازی تطبیقی، به بهترین نحو، شناسایی و تنظیم شود. علاوه بر این، پیچیدگی این الگوریتم یادگیری نسبت به روش های مبتنی بر گرادیان کمتر است. نتایج استفاده از این روش برای پیش بینی سری های زمانی آشوبناک، نشان دهنده بهبود درخور توجه عملکرد سیستم استنتاج عصبی - فازی تطبیقی بهبود یافته، نسبت به روش های قبلی است؛ این نشان دهنده عملکرد مناسب سیستم استنتاج عصبی - فازی تطبیقی بهبود یافته در مقابله با مسائل پویا و همچنین توانایی زیاد آن در فرایند یادگیری پارامترها است.

مراجع

- [1] Abarbanel H. Analysis of Observed Chaotic Data: Springer Study Edition. Institute for Nonlinear Science Series; Springer Verlag, 1996. ISBN: 9780387983721. URL: <http://books.google.de/books?id=OiT9yfEou6MC>.
- [2] Kantz H, Schreiber T. Nonlinear Time Series Analysis. New York, NY, USA: Cambridge University Press; 2003. ISBN 0521529026.
- [3] Zhou Y., Li S., Jin R., "A new fuzzy neural network with fast learning algorithm and guaranteed stability for manufacturing process control", Fuzzy Sets and Systems, Vol. 132, No. 2, pp. 201-216, 2002.
- [4] Haykin S., Neural Networks: A Comprehensive Foundation (3rd Edition). Upper Saddle River, NJ, USA: Prentice-Hall, Inc.; 2007. ISBN 0131471392.
- [5] Box GEP, Jenkins GM. Time Series Analysis: Forecasting and Control. 3rd ed.; Upper Saddle River, NJ, USA: Prentice Hall PTR; 1994. ISBN 0130607746.

- Longman Publishing Co., Inc., 1989, ISBN 0201157675.
- [34] Lin CJ., Chin CC., "Prediction and identification using wavelet-based recurrent fuzzy neural networks", IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics, Vol. 34, No. 5, pp. 2144-2154, 2004.
- [35] Vairappan C., Tamura H., Gao S., Tang Z., "Batch type local search-based adaptive neuro-fuzzy inference system (anfis) with self-feedbacks for time series prediction", Neurocomputing, Vol. 72, No. 79, pp. 1870-1877, 2009.
- [36] Atashpaz-Gargari E., Lucas C., Imperialist competitive algorithm: An algorithm for optimization inspired by imperialistic competition. In: Evolutionary Computation, IEEE Congress on CEC 2007, pp. 4661-4667, 2007
- [37] Chen Y., Yang B., Dong J., "Time-series prediction using a local linear wavelet neural network", Neurocomputing, Vol. 69, No. 46, pp. 449-465, 2006.
- [38] Jang JS., "Anfis: adaptive-network-based fuzzy inference system", IEEE Transactions on Systems, Man and Cybernetics, Vol. 23, No. 3, pp. 665-685, 1993.
- [39] Jassar S., Liao Z., Zhao L., "A recurrent neuro-fuzzy system and its application in inferential sensing", Applied Soft Computing, Vol. 11, No. 3, pp. 2935-2945, 2011.
- [40] Mascioli F., Varazi GM., Martinelli G., "Constructive algorithm for neuro-fuzzy networks", Proceedings of the Sixth IEEE International Conference on Fuzzy Systems, Vol. 1, pp. 459-464, 1997.
- [41] Jang JS., Mizutani E., "Levenberg-marquardt method for anfis learning", Fuzzy Information Processing Society, 1996. NAFIPS. 1996 Biennial Conference of the North American, pp. 87-91, 1996.
- [42] Jang JS., "Input selection for anfis learning", IEEE International Conference on Fuzzy Systems, 1996. Proceedings of the Fifth, Vol. 2, pp. 1493-1499, 1996.
- [43] Juang CF., Liou YC., "Tsk-type recurrent fuzzy network design by the hybrid of genetic algorithm and particle swarm optimization", IEEE International Conference on Systems, Man and Cybernetics, 2004, Vol. 3, pp. 2314-2318, 2004.
- [44] Shoorehdeli MA., Teshnehlab M., Sedigh AK., Khanesar MA., "Identification using anfis with intelligent hybrid stable learning algorithm approaches and stability analysis of training methods", Applied Soft Computing, Vol. 9, No. 2, pp. 833-850, 2009.
- [45] Shoorehdeli MA., Teshnehlab M., Sedigh A., "Novel hybrid learning algorithms for tuning anfis parameters using adaptive weighted pso", IEEE International Fuzzy Systems Conference, 2007. FUZZ-IEEE, pp. 1-6, 2007.
- [20] Wang J., Chi D., Wu J., Yan Lu. H., "Chaotic time series method combined with particle swarm optimization and trend adjustment for electricity demand forecasting", Expert Systems with Applications, Vol. 38, No. 7, pp. 8419-8429, 2011.
- [21] Zhao L., Yang Y., "Pso-based single multiplicative neuron model for time series prediction", Expert Systems with Applications, Vol. 36, No. 2 (part 2), pp. 2805-2812, 2009.
- [22] Li X., Yu W., "Dynamic system identification via recurrent multilayer perceptrons", Information Sciences, Vol. 147, No. 14, pp. 45-63, 2002.
- [23] Lin FJ., Shieh HJ., Shieh PH., Shen PH., "An adaptive recurrent-neural network motion controller for x-y table in cnc machine", IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics, Vol. 36, No.2, pp. 286-299, 2006.
- [24] Lin FJ., Shieh HJ., Teng LT., Shieh PH., "Hybrid controller with recurrent neural network for magnetic levitation system", IEEE Transactions on Magnetics, Vol. 41, No. 7, pp. 2260-2269, 2005.
- [25] Yu W., "Nonlinear system identification using discrete-time recurrent neural networks with stable learning algorithms", Information Sciences, Vol. 158, No. 0, pp. 131-147, 2004.
- [26] Lin CJ., Lin CT., "An art-based fuzzy adaptive learning control network", IEEE Transactions on Fuzzy Systems, Vol. 5, No. 4, pp. 477-496, 1997.
- [27] Wang LX., Mendel J., "Generating fuzzy rules by learning from examples", IEEE Transactions on Systems, Man and Cybernetics, Vol. 22, No. 6, pp. 1414-1427, 1992.
- [28] Lee CH., Teng CC., "Identification and control of dynamic systems using recurrent fuzzy neural networks", IEEE Transactions on Fuzzy Systems, Vol. 8, No. 4, pp. 349-366, 2000.
- [29] Juang CF., "A tsk-type recurrent fuzzy network for dynamic systems processing by neural network and genetic algorithms", IEEE Transactions on Fuzzy Systems, Vol. 10, No. 2, pp. 155-170, 2002.
- [30] Mastorocostas P., Theocharis J., "A recurrent fuzzy-neural model for dynamic system identification", IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics, Vol. 32, No. 2, pp. 176-190, 2002.
- [31] Su SF., Yang FY., "On the dynamical modeling with neural fuzzy networks", IEEE Transactions on Neural Networks, Vol. 13, No. 6, pp. 1548-1553, 2002.
- [32] Mandic DP., Chambers J., Recurrent Neural Networks for Prediction: Learning Algorithms, Architectures and Stability. New York, NY, USA: John Wiley & Sons, Inc., 2001. ISBN 0471495174
- [33] Goldberg DE., Genetic Algorithms in Search, Optimization and Machine Learning. 1st ed.; Boston, MA, USA: Addison-Wesley

- information for neuro fuzzy modeling with the application to time series forecasting", International Joint Conference on Neural Networks, 2007. IJCNN 2007, pp. 1121-1126, 2007.
- [57] Miranian A., Abdollahzade M., "Developing a local least-squares support vector machines-based neuro-fuzzy model for nonlinear and chaotic time series prediction", IEEE Transactions on Neural Networks and Learning Systems, Vol. 24, No. 2, pp. 207-218, 2013.
- [58] Mirikitani D., Nikolaev N., "Recursive bayesian recurrent neural networks for time-series modeling", IEEE Transactions on Neural Networks, Vol. 21, No. 2, pp. 262-274, 2010.
- [59] Lim S., Tong H., "Threshold autoregression, limit cycles and cyclical data", Journal of the Royal Statistical Society. B, Vol. 42, No. 3, pp. 245-292, 1980.
- [60] S. Weigend A., A. Huberman B., E. Rumelhart D., "Predicting the future: A connectionist approach", International Journal of Neural Systems, Vol. 1, No. 3, 1990.
- [61] Svarer C., Hansen L. K., Larsen J., "On design and evaluation of tapped-delay neural network architectures", IEEE International Conference on Neural Networks, San Francisco, 1993.
- [62] McDonnell J.R., Waagen, D., "Evolving recurrent perceptrons for time-series modeling", IEEE Transactions on Neural Network, Vol. 5, No. 1, pp. 24-38, 1994.
- [63] Alieva R. A., Guirimov B. G., Fazlollahi B., Aliev R. R., "Evolutionary algorithm-based learning of fuzzy neural networks. Part 2: Recurrent fuzzy neural networks", Fuzzy Sets System, Vol. 160, No. 17, pp. 2553-2566, 2009.
- [64] Hussain A., "A new neural network structure for temporal signal processing", IEEE International Conference on Acoustics, Speech, and Signal Processing, ICASSP-97 Germany, Vol. 4, pp. 3341-3344, 1997.
- [65] Yılmaz S., Oysal Y., "Fuzzy wavelet neural network models for prediction and identification of dynamical systems", IEEE Transactions on Neural Network, Vol. 21, No. 10, pp.1599-1509, 2010.
- [66] Zhang B.-L., Dong Z.-Y., "An adaptive neural-wavelet model for short term load forecasting" Electric Power Systems Research, Vol. 59, No. 2, pp. 121-129, 2001.
- [46] Takens F., Detecting strange attractors in turbulence, Rand D, Young LS, editors. Dynamical Systems and Turbulence, Warwick 1980; Vol. 898, of Lecture Notes in Mathematics. Springer Berlin Heidelberg, pp. 366-381, 1981.
- [47] Alparslan AK., Sayar M., Atilgan AR., "State-space prediction model for chaotic time series" Physical Review E, Vol. 58, No.2, pp. 2640-2643, 1998.
- [48] Cho KB., Wang BH.. "Radial basis function based adaptive fuzzy systems and their applications to system identification and prediction", Fuzzy Sets and Systems, Vol. 83, No. 3, pp. 325-339, 1996.
- [49] Rojas I., Pomares H., Bernier J., Ortega J., Pino B., Pelayo F., "Time series analysis using normalized pg-rbf network with regression weights", Neurocomputing, Vol. 42, No. 14, pp. 267-285, 2002.
- [50] Kim D., Kim C., "Forecasting time series with genetic fuzzy predictor ensemble", IEEE Transactions on Fuzzy Systems, Vol 5, No. 4, pp. 523-535, 1997.
- [51] Chen Y., Yang B., Dong J., "Nonlinear system modelling via optimal design of neural trees", International Journal of Neural Systems, Vol. 14, No. 2, pp. 125-137, 2004.
- [52] Tamura H., Tanno K., Tanaka H., Vairappan C., Tang Z., "Recurrent type anfis using local search technique for time series prediction", IEEE Asia Pacific Conference on Circuits and Systems., APCCAS 2008, pp. 380-383, 2008.
- [53] Harpham C., Dawson C., "The effect of different basis functions on a radial basis function network for time series prediction: A comparative study", Neurocomputing, Vol. 69, No. 1618, pp. 2161-2170, 2006.
- [54] Melin P., Soto J., Castillo O., Soria J., "A new approach for time series prediction using ensembles of anfis models", Expert Systems with Applications, Vol. 39, No. 3, pp.3494-3506, 2012.
- [55] Liu P., Yao J., "Application of least square support vector machine based on particle swarm optimization to chaotic time series prediction", IEEE International Conference on Intelligent Computing and Intelligent Systems, 2009. ICIS 2009, Vol. 4, pp. 458-462, 2009.
- [56] Yousefi M., Mirmomeni M., Lucas C., "Input variables selection using mutual

¹ Nonlinearity

² Chaotic

³ Non-Stationary

⁴ Periodic

⁵ Seasonality

⁶ Adaptive Fuzzy Inference System (ANFIS)

⁷ Imperialist Competitive Algorithm (ICA)

⁸ Least Squares Estimates (LSE)

- ⁹ Wavelet networks
- ¹⁰ Neural Networks
- ¹¹ Fuzzy Neural Networks (FNNs)
- ¹² Evolutionary Algorithms
- ¹³ Recurrent Neural Networks (RNN)
- ¹⁴ Feedbacks
- ¹⁵ Gradient Based
- ¹⁶ Genetic Algorithms
- ¹⁷ Premise
- ¹⁸ Conclusion
- ¹⁹ Local Optimum
- ²⁰ Batch Type Local Search
- ²¹ Imperialist
- ²² Colony
- ²³ Assimilation Policy
- ²⁴ Converge
- ²⁵ Exploration
- ²⁶ Roulette Wheel
- ²⁷ Firing Strength
- ²⁸ Stochastic Universal Sampling

Archive of SID