



شناسایی دستگاه‌های فوق آشوب با استفاده از مدل شبکه عصبی ELM و بهبود تخمین پارامترهای آن با استفاده از الگوریتم فرااکتشافی جستجوی فرکتال تصادفی بهبودیافته

محدثه شکراللهی*^(۱) دکتر مهدی یعقوبی^(۲)

(۱) گروه مهندسی کامپیوتر، واحد مشهد، دانشگاه آزاد اسلامی، مشهد، ایران.*

(۲) گروه مهندسی برق، واحد مشهد، دانشگاه آزاد اسلامی، مشهد، ایران.

(تاریخ دریافت: ۱۳۹۷/۱/۱۲ تاریخ پذیرش: ۱۳۹۷/۷/۱۲)

چکیده

در این مقاله، جهت مدل‌سازی دستگاه‌های آشوب و فوق آشوب از مدل ماشین یادگیری افراطی (ELM) استفاده شده است. جهت بهبود عملکرد مدل ELM، از الگوریتم بهینه‌سازی تکاملی جستجوی فرکتال تصادفی (SFS) برای تنظیم پارامترهای شبکه عصبی ELM استفاده شده است. این روش مبتنی بر اشتقاق یک‌ذره به چندین ذره دیگر است و به دلیل پوشش فضا به صورت یکنواخت و عدم به وجود آمدن نقاط بهینه محلی و همچنین به دلیل رشد نرمی که دارد می‌تواند اکتشاف همه فضا را انجام دهد. دستگاه‌های آشوب حساس به شرایط اولیه بوده و دارای رفتار غیرخطی شدید هستند. در این مقاله از پنج سیستم فوق آشوب لورنز، چن، لو، راسلر و چوا جهت مدل‌سازی استفاده شده است. دستگاه‌های فوق آشوب به دلیل دارا بودن بیش از دو متغیر دارای پیچیدگی بیشتری نسبت به دستگاه‌های آشوب هستند. همچنین حداقل دو نمای لیاپانوف مثبت در آن‌ها وجود داشته و فضای کلید آن‌ها نسبت به توابع آشوب معمولی بزرگ‌تر است. روش پیشنهادی مؤثرتر از روش‌های پیشین از لحاظ دقت و کاهش خطا است. نتایج شبیه‌سازی توسط معیارهای $RMSE$, KSE , LLE اندازه‌گیری شده است.

واژه‌های کلیدی: دستگاه‌های فوق آشوب، مدل ماشین یادگیری افراطی (ELM)، الگوریتم بهینه‌سازی جستجوی فرکتال تصادفی (SFS)

* عهده‌دار مکاتبات:

نشانی: گروه مهندسی کامپیوتر، واحد مشهد، دانشگاه آزاد اسلامی، مشهد، ایران.

پست الکترونیکی: Mohadese_shokrollahi@yahoo.com

آشوب یک پدیده غیرخطی پیچیده است که توسط یک معادله معین به وجود می‌آید و کاربردهای گوناگونی در بسیاری از زمینه‌های علمی و مهندسی پیدا می‌کند. ارتباطات ایمن، سیستم‌های زیستی، واکنش‌های شیمیایی، تحلیل و بهینه‌سازی اطلاعات و غیره، تنها نمونه‌های اندکی از آن هستند [۱،۲،۳]. شناسایی سیستم آشوب اصولاً شامل دو بخش تخمین پارامتر و مدل‌سازی پویا است. در این مقاله مدل‌سازی دستگاه‌های فوق آشوب با استفاده از مدل ماشین یادگیری افراطی (ELM) بهبود یافته انجام شده است. این مدل از یک تابع غیرخطی ثابت که به وسیله یک بخش پویای خطی دنبال می‌گردد، تشکیل شده است. تابع غیرخطی ثابت به وسیله یک شبکه عصبی ELM نشان داده شده است. جهت بهینه‌سازی توابع معیار که دارای ابعاد بالایی می‌باشند به علت بزرگ بودن فضای جستجو روش‌های گرادیانی کارایی ندارند. بنابراین جهت بهینه‌سازی این‌گونه توابع معمولاً از روش‌های تکاملی استفاده می‌شود که علت آن رویکرد این روش‌ها در جستجوی تصادفی فضای جستجو می‌باشد. الگوریتم بهینه‌سازی تکاملی جستجوی فرکتال تصادفی پارامترهای w و η ورودی شبکه عصبی ELM را تخمین می‌زند. جهت بهبود عملکرد این مدل از الگوریتم SFS برای تنظیم پارامترها استفاده شده است. روش تکاملی جدید SFS مبتنی بر اشتقاق یک ذره به چندین ذره دیگر است. به عبارت دیگر ذره‌های هر نسل از اشتقاق ذره‌های نسل قبلی تولید می‌شود، به طوری که انرژی هر ذره بین چندین ذره مشتق شده تقسیم می‌شود [۴]. بنابراین به دلیل پوشش فضا به صورت یکنواخت توسط الگوریتم SFS و عدم وجود مشکل به وجود آمدن نقاط بهینه محلی و همچنین به دلیل رشد نرمی که دارد می‌تواند اکتشاف


همه فضا را انجام دهد بنابراین نتایج مدل‌سازی دستگاه‌های فوق آشوب توسط مدل شبکه عصبی ELM و بهبود پارامترهای آن توسط الگوریتم مذکور، بهبود قابل توجهی داشته است. همچنین به دلیل عدم وجود مقالات در زمینه مدل‌سازی دستگاه‌های فوق آشوب به وسیله مدل ELM در تحقیق‌های انجام شده تاکنون، از پنج سیستم فوق آشوب لورنز، چن، لو، راسلر و چوا جهت مدل‌سازی استفاده شده است. دستگاه‌های فوق آشوب به دلیل دارا بودن بیش از دو متغیر دارای پیچیدگی بیشتری نسبت به دستگاه‌های آشوب هستند و فضای کلید آن‌ها نسبت به توابع آشوب معمولی بزرگ‌تر است. بزرگ‌ترین شاخص تمایزدهنده میان سیستم‌های فوق آشوب با آشوب معمولی، وجود حداقل دو نمای لیاپانوف مثبت در این سیستم‌هاست. در قسمت دوم و سوم به تشریح مباحث پایه شامل شبکه عصبی ELM، دستگاه‌های فوق آشوب و چگونگی مدل‌سازی آن‌ها پرداخته شده است و در قسمت چهارم نتایج مدل‌سازی پنج سیستم فوق آشوب چن، چوا، لورنز، لو و راسلر توسط شبکه عصبی ELM بهبود یافته و مقایسه نتایج قبل و بعد از پیاده‌سازی روش پیشنهادی که باعث به دست آوردن نتایج بهتر نسبت به قبل شده بیان شده است را مورد بحث و بررسی قرار می‌دهیم. در قسمت پنجم نتیجه‌گیری و پیشنهاد کار آینده آورده شده است.

۲- ماشین یادگیری افراطی (ELM)

شبکه‌های عصبی پیش‌خور تک لایه پنهان (SLFN)، یکی از معروف‌ترین شبکه‌های عصبی هستند. آن‌ها کاربردهای گسترده‌ای در زمینه‌های مختلف به دلیل توانایی تقریب جهانی برای توابع غیرخطی پیچیده دارند. معماری SLFN در شکل ۲ نشان داده شده است که در آن گره‌های ورودی m ، گره‌های خروجی n و گره‌های پنهان L وجود دارند. اگر

$$D = \{(u_j, y_j) | u_j \in R^n, y_j \in R^m\} \quad (1)$$

مدلسازی دستگاه‌های آشوبناک با استفاده از شبکه عصبی ELM نشان داده شده است. در این فلوچارت x های ۱ تا $n-1$ را به عنوان ورودی الگوریتم استفاده می‌کنیم تا وزن‌های elm را به دست آوریم. x_2 تا x_n خروجی الگوریتم است و به عنوان پارامترهایی که الگوریتم تخمین می‌زند در نظر گرفته شده است. Z ماتریس انتقال است. به مقادیر وزن و بایاس (w و η) در شبکه عصبی مقادیر تصادفی داده می‌شود و ماتریس ϕ به دست می‌آید و سپس با استفاده از این ماتریس مقادیر ماتریس θ را به دست می‌آوریم. با ضرب این دو ماتریس در هم مقدار تخمین زده شده X به دست می‌آید. تفاضل مقادیر X واقعی و X تخمین زده شده همان خطای مدلسازی است. این فرآیند تا زمانی ادامه پیدا می‌کند که خطای به دست آمده از مقدار آستانه در نظر گرفته شده کمتر شود، در غیر این صورت مجدداً مقادیر وزن و بایاس با استفاده از الگوریتم بهینه‌سازی SFS مقداردهی می‌شود.



شکل ۲: شبکه عصبی پیش‌خور

۴- الگوریتم بهینه‌سازی جستجوی فرکتال تصادفی (SFS)
الگوریتم بهینه‌سازی تکاملی جستجوی فرکتال تصادفی پارامترهای w و η ورودی شبکه عصبی ELM را کلمبومی ایجاد شده بین دو الکترون، دو ارزش منطقی

نمونه مجزا باشد. یک SLFN با گره‌های پنهان L به صورت ذیل مدل شده است:

$$\sum_{\ell=1}^L \beta_{\ell} g(w_{\ell} \cdot u_j + \eta_{\ell}) = O_j, \quad (2)$$

$$j=1,2,3,\dots,N$$

که $w_{\ell} = [w_{\ell 1}, w_{\ell 2}, \dots, w_{\ell n}]$ بردار وزنی است که گره پنهان l ام، گره‌های ورودی را متصل می‌کند.

پنهان l ام را به گره خروجی متصل می‌کند.

که نورون پنهان l ام را به گره خروجی متصل می‌کند. $\eta_{\ell} \in \mathbb{R}$ تمایل نورون مخفی l ام است. $w_{\ell} \cdot u_j$ نشان می‌دهد تولید $u_j, g(0)$ درون تابع فعال‌ساز گره‌های لایه پنهان است. O_z خروجی واقعی SLFN است.

۳- مسئله تحقیق

مدلسازی سیستم آشوب توسط شبکه عصبی ELM به صورت جعبه سیاه انجام می‌شود، در این مدلسازی تابع آشوب را نداریم و این تابع از رابطه بین ورودی و خروجی به دست می‌آید.

در شکل ۱ دیاگرام نحوه مدلسازی دستگاه‌های فوق آشوب نشان داده شده است. هدف تخمین تابع f است به طوری که رفتارش شبیه f باشد. تعداد لایه‌های مخفی (L)، 10 در نظر گرفته شده است.



شکل ۱: دیاگرام نحوه مدلسازی دستگاه‌های فوق آشوب

$$f(x) \cong \hat{f}(x) \quad (3)$$

اختلاف $f(x)$ با $\hat{f}(x)$ خطای مدلسازی است. هر چه این اختلاف کمتر شود مدلسازی سیستم آشوب بهینه‌تر شده است که این اختلاف را با اعمال الگوریتم بهینه‌سازی SFS به جای انتخاب تصادفی وزن‌های شبکه عصبی کاهش می‌دهیم. در شکل ۲ فلوچارت چگونگی

تخمین می‌زند. جهت بهبود عملکرد این مدل از الگوریتم SFS برای تنظیم پارامترها استفاده شده است. روش تکاملی جدید SFS مبتنی بر اشتقاق یک ذره به چندین ذره دیگر است. به عبارت دیگر ذره‌های هر نسل از اشتقاق ذره‌های نسل قبلی تولید می‌شود، به طوری که انرژی هر ذره بین چندین ذره مشتق شده تقسیم می‌شود [۴]. بنابراین به دلیل پوشش فضا به صورت یکنواخت توسط الگوریتم SFS و عدم وجود مشکل به وجود آمدن نقاط بهینه محلی و همچنین به دلیل رشد نرمی که دارد می‌تواند اکتشاف همه فضا را انجام دهد. در این الگوریتم ابتدا جمعیت اولیه تولید می‌شود و برای هر کدام انرژی در نظر گرفته می‌شود و E اولیه را به P مقدار تقسیم می‌کند و هر بار جواب آن توسط یک تابع بهینه‌سازی به نام تابع هزینه ارزیابی می‌شود. هر بار که جواب به جواب‌های جدید تقسیم می‌شود، انرژی آن‌هم تقسیم می‌شود که این تقسیم انرژی بستگی به میزان بهتر بودن جواب دارد. الگوریتم تا وقتی تکرار می‌شود که جوابی با بهترین تابع هزینه به دست آید یا اینکه پس از چند دوره تغییر نکند. ارزیابی با استفاده از این تابع به دست می‌آید.

فاصله بین خروجی اصلی (y) و مقدار تخمین زده شده خروجی (\hat{y}) را به عنوان خطای Rmse در نظر می‌گیریم.

$$E = \sqrt{(y - \hat{y})^2} - 5 \quad (4)$$

در هر مرحله جواب‌ها با استفاده از روابط گوسی (5) و (6) به‌روزرسانی می‌شوند و پس از آن مقایسه و محاسبه خطا صورت می‌گیرد.

$$GW_1 = \text{Gaussian}(\mu_{BP}, \sigma) + (\varepsilon \times BP - \varepsilon' \times P_i) \quad (5)$$

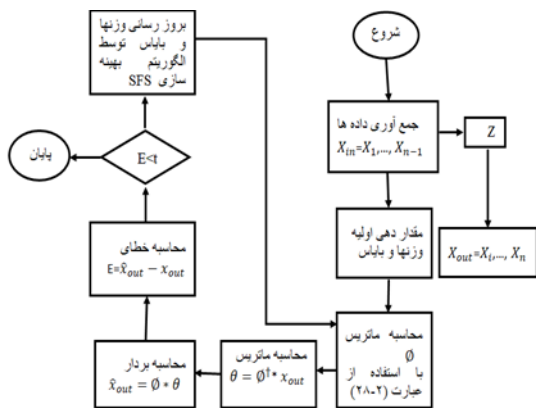
$$GW_2 = \text{Gaussian}(\mu_p, \sigma) \quad (6)$$

هدف استفاده از الگوریتم بهینه‌سازی SFS عدم به وجود آمدن نقاط بهینه محلی است. همچنین به دلیل

پوشش فضا به صورت یکنواخت در این الگوریتم و به دلیل رشد نرمی که دارد می‌تواند Exploration همه فضا را انجام دهد. نتایج نشان می‌دهد مدل‌سازی دستگاه‌های فوق آشوب توسط شبکه عصبی ELM بهبود یافته به وسیله الگوریتم مذکور، کاهش میزان خطای قابل توجهی داشته است. فلوجارت چگونگی عملکرد الگوریتم بهینه‌سازی SFS جهت تنظیم پارامترهای شبکه عصبی ELM در شکل ۴ نشان داده شده است.

۵- معیارهای سنجش مقادیر

سه معیار جهت ارزیابی چگونگی پیاده‌سازی ایده کاربردی دستگاه‌های فوق آشوب و ایده تنظیم پارامترهای شبکه عصبی ELM با استفاده از الگوریتم بهینه‌سازی جستجوی فرکتال تصادفی (SFS) در نظر گرفته شده است. یکی از این معیارها محاسبه بزرگ‌ترین توان لیاپانوف (LLE) است.



شکل ۳: فلوجارت چگونگی مدل‌سازی دستگاه‌های

آشوبناک با استفاده از شبکه عصبی ELM

آزمون نمای لیاپانوف بر اساس این ویژگی سری‌های آشوبی است که نقاط مجاور در این سری‌ها به‌مرور زمان از هم جدا شده و نسبت به هم واگرا می‌شوند. نمای لیاپانوف این واگرایی را به وسیله یک تابع‌نمایی اندازه‌گیری می‌کند. محاسبه نمای لیاپانوف از طریق سیستم رخ می‌دهد، انجام می‌شود. در واقع در این روش، سرعت متوسطی که مسیرهای انتقالی دونقطه‌ای که در

X_i به مقادیر شبیه سازی شده و \hat{X}_i به مقادیر واقعی اشاره می کند. این شاخص، ابتدا اختلاف تک تک مقادیر مشاهده شده را با مقادیر پیش بینی شده به وسیله مدل (مثلاً در تحلیل رگرسیون) محاسبه نموده و به توان دو می رساند. از این اختلافات میانگین گرفته و در نهایت جذر عدد میانگین را ارائه می دهد که همان $RMSE$ است. این شاخص معیاری برای دقت نتایج است و معمولاً هرچه مدل بهتر بر داده ها منطبق باشد مقدار آن کمتر می شود. سومین معیار سنجش در این پایان نامه محاسبه آنتروپی سینای - کولموگروف (KSE) می باشد. آزمون آنتروپی کولموگروف در واقع ویژگی حساسیت یک سری آشوبی به شرایط اولیه را کم می کند. اگر دو سری زمانی بسیار نزدیک به هم را در نظر بگیریم به طوری که به ظاهر قابل تشخیص از یکدیگر باشند در صورت تبعیت از یک فرایند آشوبی انتظار می رود که روند دو سری با گذشت زمان کاملاً متمایز و قابل تشخیص از یکدیگر باشند. آزمون آنتروپی کولموگروف سرعتی را که طبق آن دو سری از یکدیگر متمایز می شوند و یا به عبارتی دیگر میانگین نرخ انحراف دو سری از یکدیگر را محاسبه می کند. سرعت صفر به معنای عدم تمایز پذیری دو سری با گذشت زمان و در نتیجه تصادفی بودن فرایند ایجادکننده آنها است. سرعت مثبت به معنای جدا شدن دو سری از یکدیگر به مرور زمان و در نتیجه آشوبی بودن فرایند ایجادکننده سری است.

۵- مدل سازی پنج سیستم فوق آشوب

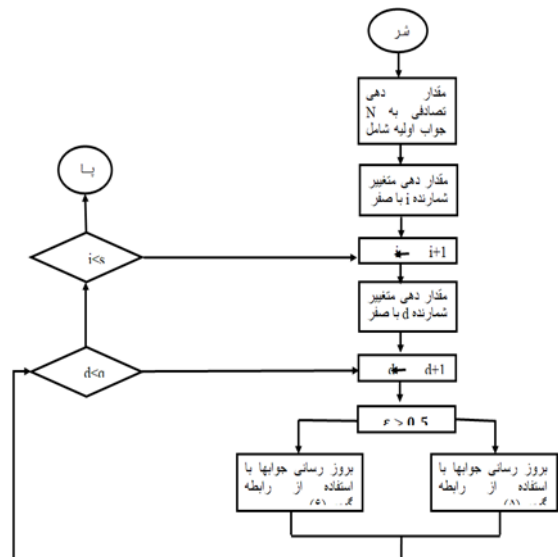
دستگاه های فوق آشوب به دلیل دارا بودن بیش از دو متغیر دارای پیچیدگی بیشتری نسبت به دستگاه های آشوب هستند. همچنین دستگاه های فوق آشوب غیرخطی شدید و حساس به شرایط اولیه هستند و حداقل دو نمای لیاپانوف مثبت در آنها وجود داشته و

ابتدا به هم نزدیک بوده اند، به طور نمایی از یکدیگر منحرف می شوند، محاسبه می شود. اگر بزرگ ترین نمای محاسبه شده لیاپونوف مقدار مثبتی داشته باشد، سیستم دارای رفتار آشوبی است و برعکس. می توان نشان داد که نمای لیاپونوف به صورت زیر نیز قابل ارائه است:

$$\lambda(x_0) = \lim_{n \rightarrow \infty} \frac{1}{n} \log \left| \frac{df^n(x_0)}{dx_0} \right| \quad (7)$$


λ به نمای لیاپونوف معروف بوده که در آن، عبارت داخل $\|$ مشتق تابع f است. برای سری های آشوبناک مقدار توان لیاپونوف مثبت و در غیر این صورت منفی است.

معیار دیگر سنجش ریشه میانگین مربعات خطا ($RMSE$) است. $RMSE$ که از آن به عنوان خطای $RMSE$ نیز یاد می کنند، مخفف کلمه Root Mean Square Error و به معنی میانگین مربع خطاها می باشد. خطای جذر میانگین مربعات ($RMSE$)، یک معیار خطای بسیار پر کاربرد برای اندازه گیری دقت است که در زمان پیوسته به صورت زیر تعریف شده است:



شکل ۴: فلوجارت چگونگی عملکرد الگوریتم بهینه سازی SFS جهت تنظیم پارامترهای شبکه عصبی ELM

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (X_i - \hat{X}_i)^2} \quad (8)$$




شکل ۵: سیستم فوق آشوب چن

۲-۶- سیستم فوق آشوب چوا

مدار چوا تغییر یافته به وسیله معادلات زیر توصیف می شود:

$$(10) \begin{cases} \dot{X} = p(y - f(x)) \\ \dot{Y} = x - y + z \\ \dot{Z} = -qy \end{cases} \quad f(x) = 2x^3 - x/7$$

جاذب آشوب گونه آن هنگامی که $p=10, q=100/7$ در شکل زیر نشان داده شده است.



شکل ۶: سیستم فوق آشوب چوا

۳-۶- سیستم فوق آشوب لورنز

سیستم لورنز یکی از نمونه های آشوب است. سیستم لورنز برای مدل کردن حرکت دینامیکی یک سیال جوی استفاده شده است و معادلات دینامیک آن به صورت زیر نوشته می شود:

$$(11) \begin{cases} \dot{X} = \sigma(y - x) \\ \dot{Y} = \rho x - y - xz \\ \dot{Z} = -\beta z + xy \end{cases}$$

که در آن $\sigma=10, \rho=28, \beta=8.3$ است. این سیستم یک جاذب کران دار دارد که در شکل زیر دیده می شود.

فضای کلید آن ها نسبت به توابع آشوب معمولی بزرگ تر است.

جهت بهینه سازی توابع معیار که دارای ابعاد بالایی می باشند به علت بزرگ بودن فضای جستجو روش های گرادینانی کارایی ندارند. بنابراین جهت بهینه سازی این گونه توابع معمولاً از روش های تکاملی استفاده می شود که علت آن رویکرد این روش ها در جستجوی تصادفی فضای جستجو می باشد. الگوریتم *SFS* پارامترهای η و W ورودی شبکه عصبی *ELM* را تخمین میزند. هر چه مقادیر مناسب تری برای این دو پیدا کنیم جهت محاسبه $h^* \beta^*$ مقادیر خروجی Y به Y' نزدیک تر است و در نتیجه خطا کم شود.


در این مقاله به دلیل عدم وجود مقالات در زمینه مدل سازی دستگاه های فوق آشوب به وسیله مدل *ELM* در تحقیق های انجام شده تاکنون، از ۵ سیستم فوق آشوب لورنز، چن، لو، راسلر و چوا جهت مدل سازی به وسیله *ELM* استفاده شده است. بزرگ ترین شاخص تمایز دهنده میان سیستم های فوق آشوب با آشوب معمولی، وجود حداقل دو نمای لیاپانوف مثبت در این سیستم هاست. توابع فوق آشوب بیش از دو متغیر دارند بنابراین پیچیدگی بیشتری دارند و همچنین فضای کلید آن ها نسبت به توابع آشوب معمولی بزرگ تر است.

۱-۶- سیستم فوق آشوب چن

این سیستم بر اساس معادلات سیستم لورنز استخراج شده است. معادلات دیفرانسیل غیر خطی که جاذب چن را توصیف می کند، به شرح زیر می باشد:

$$(9) \begin{cases} \dot{X} = a(y-x) \\ \dot{Y} = (c-a)x - xz + cy \\ \dot{Z} = xy - bz \end{cases}$$

جاذب آشوب گونه آن هنگامی که $a=35, b=3, c=28$ در شکل زیر نشان داده شده است.




شکل ۷: سیستم فوق آشوب لورنز

۶-۴- سیستم فوق آشوب لو

در سال ۲۰۰۲، لو وچن یک سیستم آشوب گونه جدید پیدا کردند که به نام سیستم لو شناخته شده است و پلی بین سیستم آشوب گونه لورنز و سیستم آشوب گونه چن می باشد. سیستم لو به وسیله معادلات زیر توصیف می شود:

$$(12) \begin{cases} \dot{X} = a(y-x) \\ \dot{Y} = -xz + cy \\ \dot{Z} = xy - bz \end{cases}$$

هنگامی که $a=36$, $b=3$, $c=20$ است، دارای جاذب آشوب گونه نشان داده شده در شکل زیر می باشد.




شکل ۸: سیستم فوق آشوب لو

۶-۵- سیستم فوق آشوب راسلر

بر پایه سیستم آشوب گونه لورنز، راسلر یک سیستم آشوب گونه ساده تر ساخت که البته جاذب آن با جاذب سیستم لورنز متفاوت است. معادلات سیستم راسلر به شرح زیر است: ورودی را نشان می دهند.

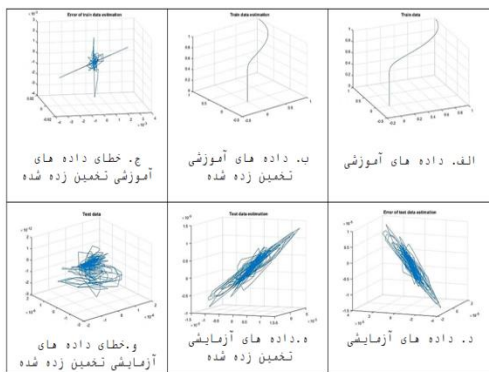
$$\begin{cases} \dot{X} = -y - z \\ \dot{Y} = x + ay \\ \dot{Z} = \underline{xz} - \underline{bz} + c \end{cases}$$

ساده ترین دستگاه های زمان پیوسته است که از خود رفتار آشوب گونه نشان می دهد. در شکل زیر جاذب آشوب گونه عجیب آن نشان داده شده است.



شکل ۹: سیستم فوق آشوب راسلر

پارامترهای شبکه عصبی ELM با استفاده از الگوریتم تکاملی SFS بهبود بخشیده شده است، در اینجا نتایج خطای RMSE و KSE و LLE حاصل از مدل سازی پنج سیستم فوق آشوب شامل داده های آموزشی، داده های آموزشی تخمین زده شده، خطای داده های آموزشی تخمین زده شده، داده های آزمایشی، داده های آزمایشی تخمین زده شده و خطای داده های آزمایشی تخمین زده شده در شکل های زیر نشان داده شده است.



شکل ۱۰: پیاده سازی سیستم فوق آشوب چن با استفاده

از شبکه عصبی ELM

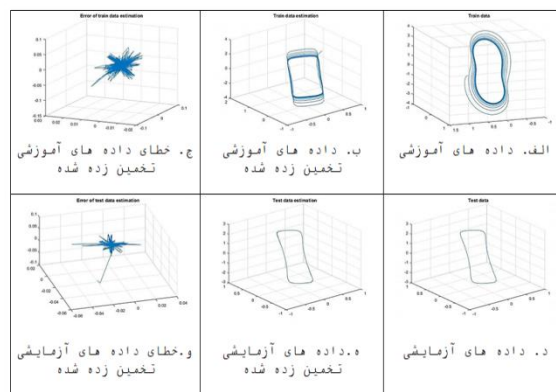
جدید تکاملی SFS استفاده شده است. این روش مبتنی بر اشتقاق یک ذره به چندین ذره دیگر است. به عبارت دیگر ذره های هر نسل از اشتقاق ذره های نسل قبلی تولید می شود به طوری که انرژی هر ذره بین چندین ذره مشتق شده تقسیم می شود. بنابراین به دلیل پوشش فضا به صورت یکنواخت توسط الگوریتم SFS و عدم وجود مشکل به وجود آمدن نقاط بهینه محلی و همچنین به دلیل رشد نرمی که دارد می تواند Exploration همه فضا را انجام دهد بنابراین نتایج مدل سازی دستگاه های فوق آشوب توسط مدل شبکه عصبی ELM و بهبود پارامترهای آن توسط الگوریتم مذکور، بهبود قابل توجهی داشته است. میانگین نتایج پنج بار خطای RMSE, LLE, KSE داده های Train و Test در جداول ۱ تا ۳ نشان داده شده است.

جدول ۱: نتایج ریشه میانگین مربعات خطا (RMSE) داده های آموزشی و آزمایشی حاصل از پیاده سازی پنج سیستم فوق آشوب به وسیله شبکه عصبی ELM و بهبود پارامترهای آن به وسیله الگوریتم بهینه سازی SFS

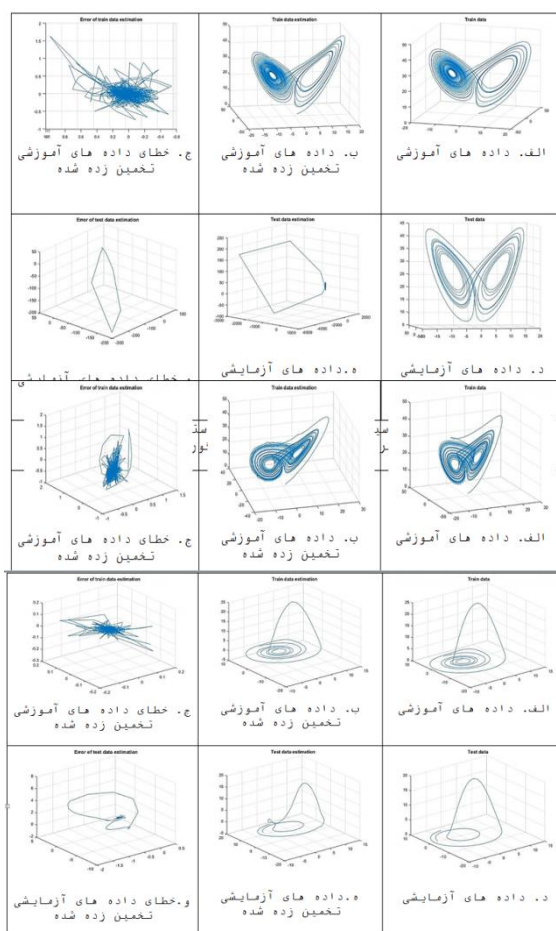
RMSE	RMSETrain	RMSETest
Lorenz	0.0846	0.0012
Chowa	0.0100	0.0093
Rasler	0.0180	0.0136
Chen	0.0001	0.0000
Lu	0.2958	0.1997

جدول ۲: نتایج خطای LLE داده های آموزشی و آزمایشی حاصل از پیاده سازی پنج سیستم فوق آشوب به وسیله شبکه عصبی ELM و بهبود پارامترهای آن به وسیله الگوریتم بهینه سازی SFS

LLE	LLETrain	LLETest
Lorenz	73.6346	57.1164
Chowa	213.4718	153.7621
Rasler	6.0192	4.7682
Chen	11.8865	11.1660



شکل ۱۱: پیاده سازی سیستم فوق آشوب چوا با استفاده از شبکه عصبی ELM و بهبود پارامترهای آن با استفاده از الگوریتم تکاملی SFS



شکل ۱۲: پیاده سازی سیستم فوق آشوب راسلر با استفاده از شبکه عصبی ELM و بهبود پارامترهای آن با استفاده از الگوریتم تکاملی SFS

۷- نتایج مدل سازی پنج سیستم فوق آشوب با شبکه عصبی ELM بهبود یافته

جهت بهبود پارامترهای شبکه عصبی ELM از روش

ELM قبل و بعد از بهبود پارامترهای آن به وسیله

الگوریتم بهینه سازی SFS

RMSE	Train (-SFS)	Test (-SFS)	Train (+SFS)	Test (+SFS)
Lorenz	0.1335	0.0864	0.0846	0.0012
Chowa	0.0104	0.0094	0.0100	0.0093
Rasler	0.7255	0.6075	0.0180	0.0136
Chen	0.0004	0.0001	0.0001	0.0000
Lu	0.2725	0.2393	0.2958	0.1997

جدول ۵: مقایسه نتایج خطای LLE داده‌های آموزشی و آزمایشی حاصل از پیاده‌سازی پنج سیستم فوق آشوب به وسیله شبکه عصبی ELM قبل و بعد از بهبود پارامترهای آن به وسیله الگوریتم بهینه سازی SFS

LL E	Train (-SFS)	Test (-SFS)	Train (+SFS)	Test (+SFS)
Lorenz	78.4965	58.9880	73.6346	57.1164
Chowa	215.3756	143.7621	213.4718	140.0336
Rasler	9.0770	9.1857	6.0192	4.7682
Chen	65.8770	42.7925	11.8865	11.1660
Lu	114.3032	67.9057	111.6680	66.4758

جدول ۶: مقایسه نتایج خطای KSE داده‌های آموزشی و آزمایشی حاصل از پیاده‌سازی پنج سیستم فوق آشوب به وسیله شبکه عصبی ELM قبل و بعد از بهبود پارامترهای آن به وسیله الگوریتم بهینه سازی SFS

KSE	Train (-SFS)	Test (-SFS)	Train (+SFS)	Test (+SFS)
Lorenz	1.6911	1.5622	1.5397	1.4916
Chowa	4.2687	3.9531	4.2666	3.9429
Rasler	3.6852	3.0704	3.6636	3.3384
Chen	0.5510	0.0000	0.5515	0.0000
Lu	1.3526	1.3241	1.4975	1.3670

در جدول ۷ تمایز بین خطاهای به دست آمده در جداول بالا را نشان داده‌ایم. همان‌طور که مشاهده می‌کنید تفاضل خطا در اکثر نتایج مدل‌سازی پنج سیستم فوق

Lu	111.6680	66.4758
----	----------	---------

جدول ۳: نتایج خطای KSE داده‌های آموزشی و آزمایشی حاصل از پیاده‌سازی پنج سیستم فوق آشوب به وسیله شبکه عصبی ELM و بهبود پارامترهای آن به وسیله الگوریتم بهینه سازی SFS

KSE	KSETrain	KSETest
Lorenz	1.5397	1.4916
Chowa	4.2666	3.9429
Rasler	3.6636	3.3384
Chen	0.5515	0.0000
Lu	1.4975	1.3670

۷-۱- مقایسه نتایج قبل و بعد از اعمال الگوریتم بهینه سازی SFS

در این قسمت نتایج مدل‌سازی دستگاه‌های فوق آشوب به وسیله شبکه عصبی ELM، قبل و بعد از بهبود پارامترهای آن به وسیله الگوریتم بهینه سازی SFS مقایسه شده است. در محاسبه خطا به وسیله معیارهای RMSE و LLE کاهش قابل توجهی مشاهده می‌شود و در معیار KSE خطا میزان کمی تغییرات داشته است. ابتدا نتایج پیاده‌سازی با استفاده از سه معیار RMSE و LLE و KSE قبل و بعد از بهبود پارامترهای شبکه عصبی ELM در جداول زیر نشان داده شده است.

جداول نشان‌دهنده تفاضل بین خطای موجود در مدل‌سازی پنج سیستم فوق آشوب قبل و بعد از بهبود پارامترهای شبکه عصبی ELM با استفاده از الگوریتم SFS می‌باشد و در این جداول برای نمایش صحیح کاهش میزان خطا، از خطای داده‌های آموزشی و آزمایشی در هر سیستم فوق آشوب میانگین گرفته شده است.

جدول ۴: مقایسه نتایج ریشه میانگین مربعات خطا (RMSE) داده‌های آموزشی و آزمایشی حاصل از پیاده‌سازی پنج سیستم فوق آشوب به وسیله شبکه عصبی

$$E = \|X - \phi\theta\|^2 \quad (14)$$

با در نظر گرفتن مشتقات جزئی E نسبت به θ ، پارامتر θ به روزرسانی می گردد به صورت:

$$\theta(i+1) = \theta(i) - \rho \frac{\partial E}{\partial \theta} \quad (15)$$

در شبیه سازی ρ به ۰.۱ و مقدار اولیه $\theta(0)$ به صورت تصادفی انتخاب می گردد. برای یک مقایسه عادلانه، تمامی شرایط شبیه سازی مانند مقادیر اولیه سیستم آشوب، تعداد جفت های اطلاعات استفاده شده برای شناسایی دو الگوریتم یکسان در نظر گرفته می شود و در نتیجه عملکرد ELM بهتر از الگوریتم GD است.

۹- نتیجه گیری

در این مقاله، ابتدا مدل سازی دستگاه های آشوبناک توسط شبکه عصبی ELM صورت گرفته است، سپس مدل سازی پنج سیستم فوق آشوب به وسیله شبکه عصبی ELM و بهبود پارامترهای آن به وسیله الگوریتم بهینه سازی SFS انجام شده است. با توجه به اینکه دستگاه های فوق آشوب دارای بیش از دو متغیر است و پیچیدگی بیشتری نسبت به دستگاه های آشوب دارند و همچنین غیرخطی بودن شدید این توابع و اینکه حساس به شرایط اولیه هستند و حداقل دو نمای لیاپانوف مثبت در آن ها وجود داشته و فضای کلید آن ها نسبت به توابع آشوب معمولی بزرگ تر است، روش پیشنهادی مؤثرتر از روش های پیشین از لحاظ دقت، توانایی تعمیم و کاهش خطا است. این موضوع به دلیل این است که الگوریتم ELM تعمیم یافته راه حل را از طریق شبه معکوس ماتریس به جای گرادیان نزولی پیدا می کند. نمونه های شبیه سازی، تأثیر روش پیشنهادی را اعتبارسنجی می نماید. همچنین به دلیل پوشش فضا به صورت یکنواخت توسط الگوریتم SFS و عدم وجود مشکل به وجود آمدن نقاط بهینه محلی و همچنین به دلیل رشد نرمی که دارد می تواند Exploration همه

آشوب با استفاده از شبکه عصبی ELM و بهبود پارامترهای آن با استفاده از الگوریتم فرکتال تصادفی با استفاده سه معیار مختلف کاهش داشته است.

جدول ۷: نمایش میزان کاهش خطای RMSE و LLE و KSE حاصل از مدل سازی پنج سیستم فوق آشوب به وسیله شبکه عصبی ELM قبل و بعد از بهبود پارامترهای آن به وسیله الگوریتم بهینه سازی

	LLE	RMSE	KSE
Lorenz	-3.36675	-0.06705	-0.111
Chowa	-2.81615	-0.00025	-0.00615
Rasler	-3.73765	-0.6507	0.1232
Chen	-42.8085	-0.00016	0.00025
Lu	-2.03255	-0.00815	0.0939

۷-۲- بازده محاسبات

در این بخش بازده محاسبات الگوریتم سریع برای محاسبات شبه معکوس M-P مورد توجه قرار گرفته است. برای نمایش این بازده، زمان محاسبات الگوریتم محاسبات سریع پیشنهادی با روش محاسبات مبتنی بر SVD مقایسه می گردد. نتایج محاسبات در روش مقاله پایه [۵] در جدول شماره ۱ آمده است. می توان دید که الگوریتم سریع پیشنهادی، بهتر از الگوریتم مبتنی بر SVD است. رتبه بالاتر ماتریس، بازده الگوریتم سریع را افزایش می دهد. همچنین نتایج محاسبات روش مقاله پایه و پیاده سازی الگوریتم پیشنهادی SFS در جداول ۴، ۵ و ۶ نشان داده شده است. در این جداول بهبود نتایج از لحاظ دقت را می توان مشاهده نمود.

۸- تجزیه و تحلیل همگرایی

در این بخش، تحلیل همگرایی و اجرای فراگیری الگوریتم ELM تعمیم یافته مورد مطالعه قرار گرفته است. بدین منظور الگوریتم ELM تعمیم یافته و الگوریتم گرادیان نزولی کلاسیک GD نشان شده است.

محدوده مناسبی به صورت آشوب گونه نوسان می کنند و وزن های پایه، شبکه عصبی آشوب گونه ای طراحی گردد که وزن های آن در هر لحظه به صورت آشوب گونه تغییر کند. با این روش وزن های آشوبی طوری با یکدیگر هم زمان می شوند که احتمال می رود خطای خروجی حداقل گردد. همچنین می توان با استفاده از الگوریتم های بهینه سازی، زمان مدل سازی را کاهش داد.

فضا را انجام دهد. نتایج خطای RMSE و KSE و LLE حاصل از مدل سازی پنج سیستم فوق آشوب لورنز، چن، لو، راسلر و چوا توسط شبکه عصبی ELM و بهبود پارامترهای آن توسط الگوریتم بهینه سازی فرکتال تصادفی، نشان داده که راه حل پیشنهادی نسبت به موارد مشابه پیاده سازی شده بهبود قابل توجهی داشته است.

پیشنهاد می شود در تحقیقات آینده وزن های شبکه عصبی ELM آشوبی شود. در این روش وزن های شبکه عصبی ELM پس از آموزش به عنوان پایه در نظر گرفته می شوند. با استفاده از توابع لاجستیک که در

مراجع

- [1] Chai, Y., Chen, L.Q.: Projective lag synchronization of spatio temporal chaos via active sliding mode control. *Commun. Nonlinear Sci. Numer. Simul.* 17(8), 3390–3398 (2012)
- [2] de Córdoba, M.P.F., Liz, E.: Prediction-based control of chaos and a dynamic Parrondo's paradox. *Phys. Lett. A* 377(10–11), 778–782 (2013)
- [3] Sadegh pour, M., Khodabakhsh, M., Salarieh, H.: Intelligent control of chaos using linear feedback controller and neural network identifier. *Commun. Nonlinear Sci. Numer. Simul.* 17(12), 4731–4739 (2012)
- [4] Hamid Salimi.: Stochastic Fractal Search: A powerful metaheuristic algorithm. *Knowledge-Based Systems. Elsevier journal. Knowledge-Based Systems* 75 1–18 (2015)
- [5] Shuen Wang, Weiwei Wang, Fucui Liu, Yinggan Tang, Xiping Guan.: Identification of chaotic system using Hammerstein-ELM model. *Nonlinear Dyn* 81:1081–1095 (2015)
- [6] Yang, D., Zhou, J.: Connections among several chaos feedback control approaches and chaotic vibration control of mechanical systems. *Commun. Nonlinear Sci. Numer. Simul.* 19(11), 3954–3968 (2014)
- [7] Wu, Z.G., Shi, P., Su, H., Chu, J.: Sampled-data fuzzy control of chaotic systems based on aT-S fuzzy model. *IEEE Trans. Fuzzy Syst.* 22(1), 153–163 (2014)
- [8] Lee, C.H., Chang, F.Y., Lin, C.M.: An efficient interval type-2 fuzzy CMAC for chaos time-series prediction and synchronization. *IEEE Trans. Cybern.* 44(3), 329–341 (2014)
- [9] Courieu, P.: Fast computation of Moore–Penrose inverse matrices. *Neural Inf. Process. Lett. Rev.* 8(2), 25–29 (2005)
- [10] Avci, E., Coteli, R.: A new automatic target recognition system based on wavelet extreme learning machine. *Expert Syst. Appl.* 39, 12340–12348 (2012)
- [11] Deng, J., Li, K., Irwin, G.W.: Fast automatic two-stage nonlinear model identification based on the extreme learning machine. *Neurocomputing* 74(16), 2422–2429 (2011)
- [12] dos Santos Coelho, L., Araujo, E.: Identification of the Hénon chaotic map by fuzzy modeling and Nelder-Mead simplex method. *Chaos Solitons Fractals* 41(5), 2762–2772 (2009)
- [13] Huang, G.B., Zhu, Q.Y., Siew, C.K.: Extreme learning machine: a new learning scheme of feedforward neural networks. *IEEE Int. Jt. Conf. Neural Netw.* 2, 985–990 (2004)
- [14] Khooban, M., Alfi, A., Abadi, D.: Control of a class of online uncertain chaotic systems via an optimal type-2 fuzzy proportional integral derivative controller. *IET Sci. Meas. Technol.* 7(1), 50–58 (2013)
- [15] Konnur, R.: Synchronization-based approach for estimating all model parameters of chaotic systems. *Phys. Rev. E* 67(2), 027,204 (2003)
- [16] Yeh, J.P.: Identifying chaotic systems using a fuzzy model coupled with a linear plant. *Chaos Solitons Fractals* 32(3), 1178–1187 (2007)
- [17] Li, C., Zhou, J., Xiao, J., Xiao, H.: Parameters identification of chaotic system by chaotic gravitational search algorithm. *Chaos Solitons Fractals* 45(4), 539–547 (2012)

- [18] Li, H., Liao, X., Li, C., Li, C.: Chaos control and synchronization via a novel chatter free sliding mode control strategy. *Neuro computing* 74(17), 3212–3222 (2011)
- [19] Liberzon, D.: *Switching in Systems and Control*. Birkh äuser, Boston (2003)
- [20] Moreno-Valenzuela, J.: Adaptive anti control of chaos for robot manipulators with experimental evaluations. *Commun. Nonlinear Sci. Numer. Simul.* 18(1), 1–11 (2013)
- [21] Narendra, K.S., Parthasarathy, K.: Identification and control of dynamical systems using neural networks. *IEEE Trans. Neural Netw.* 1(1), 4–27 (1990)
- [22] Niu, B., Zhao, J.: Barrier Lyapunov functions for the output tracking control of constrained nonlinear switched systems. *Syst. Control Lett.* 62, 963–971 (2013)
- [23] Niu, B., Zhao, J.: Output tracking control for a class of switched non-linear systems with partial state constraints. *IET Control Theory Appl.* 4(4), 623–631 (2013)
- [24] Parlitz, U.: Estimating model parameters from time series by auto synchronization. *Phys. Rev. Lett.* 76(8), 1232–1235 (1996)
- [25] Raiesdana, S., Goplayegani, S.M.H.: Study on chaos anticontrol for hippocampal models of epilepsy. *Neuro computing* 111, 54–69 (2013)
- [26] Balasundaram, S., Gupta, D.: Kapil: 1-norm extreme learning machine for regression and multiclass classification using Newton method. *Neuro computing* 128, 4–14 (2013)
- [27] Sari, N., Suhajito, S., Widodo, A.: Trend prediction for computer science research topics using extreme learning machine. *Procedia Eng.* 50, 871–881 (2012)
- [28] Zhao, X., Zhang, L., Shi, P., Liu, M.: Stability and stabilization of switched linear systems with mode-dependent average dwell time. *IEEE Trans Automat Contr* 57(7), 1809–1815 (2012)
- [29] Tien, J.P., Li, T.H.S.: Hybrid Taguchi-chaos of multilevel immune and the artificial bee colony algorithm for parameter identification of chaotic systems. *Comput. Math. Appl.* 64(5), 1108–1119 (2012)
- [30] Wang, Y., Cao, F., Yuan, Y.: A study on effectiveness of extreme learning machine. *Neuro computing* 74, 2483–2490 (2011)
- [31] Wu, Z.G., Shi, P., Su, H., Chu, J.: Sampled-data synchronization of chaotic Lur'e systems with time delays. *IEEE Trans. Neural Netw. Learn. Syst.* 24(3), 410–421 (2013)
- [32] Xu, M., Chen, G., Tian, Y.T.: Identifying chaotic systems using Wiener and Hammerstein cascade models. *Math. Comput. Model.* 33(4), 483–493 (2001) Identification of chaotic system using Hammerstein-ELM model 1095
- [33] Yang, Z.O., Wang, Y., Li, D., Wang, C.: Predict the time series of the parameter-varying chaotic system based on reduced recursive least square support vector machine. In: *International Conference on Artificial Intelligence and Computational Intelligence*. AICI '09, vol. 1, pp. 29–34 (2009)