



Improved Noise Reduction Method for Chaotic Time Series Using Neural Network and Singular Spectrum Analysis

ARTICLE INFO

Article Type

Original Research

Authors

Bahrami A.R.¹,
Asil Gharebaghi S. ^{1*},

How to cite this article

Bahrami A.R, Asil Gharebaghi S.,
Improved Noise Reduction Method
for Chaotic Time Series Using Neural
Network and Singular Spectrum
Analysis. Modares Mechanical
Engineering; 2024;24(01):53-63.

¹ Civil Engineering Department, K.
N. Toosi University, Tehran, Iran.

*Correspondence

Address: Civil Engineering
Department, K. N. Toosi University,
Tehran, Iran.

asil@kntu.ac.ir

Article History

Received: December 27, 2023

Accepted: April 17, 2024

ePublished: May 1, 2024

ABSTRACT

An improved method for noise reduction from a time series obtained from a chaotic system is presented. This improved method is based on a noise reduction technique presented by Schreiber and Grassberger that has good performance and less complexity compared to other noise reduction methods from chaotic data. Here a global model created using a neural network has been used as a prediction model for chaotic time series. This global prediction model performs better compared to the local prediction model used in the original method. The improved method also takes advantage of the singular spectrum analysis reconstruction technique. Both of these improvements led to a more accurate noise reduction method while preserving the unique properties of the original. The improved method is applied to a time series obtained from the chaotic state of Lorenz equations that is polluted with Gaussian noise. The final results show a 33 percent reduction in mean absolute error values compared to the original method. Also, the error of calculating the correlation dimension from the data has been reduced to 2 percent after applying the improved method.

Keywords Noise Reduction, Chaotic Time Series, Singular Spectrum Analysis, Neural Network, Global Model.

CITATION LINKS

1- Vibration signal denoising for structural health monitoring by 2- On the denoising of structural vibration response records from 3- Noise reduction for improvement of 4- Robust damage detection in the time domain using 5- Investigation of microseismic signal 6- Investigating the effect of noise elimination on 7- Research on the chaotic characteristics and 8- A novel noise reduction technique for underwater acoustic 9- On noise reduction methods for 10- Noise smoothing for nonlinear time series using 11- A method for extracting chaotic signal from 12- H_∞ filtering on nonlinear 13- A smoothing algorithm for nonlinear time series. 14- A simple noise-reduction method for real data. 15- Analysis of observed chaotic data. 16- Exploiting chaos to predict the future and reduce noise. 17- A noise reduction method for 18- Noise reduction schemes for chaotic time series. 19- Noise reduction in chaotic time series using 20- Discrete-time dynamic noise filtering. 21- A comparison of methods for constructing a 22- Noise reduction: Finding the simplest 23- Local-geometric-projection method for 24- A noise reduction method for signals from nonlinear systems. 25- Noise reduction by gradient descent. 26- Topology and intelligent data analysis. 27- Topology-based signal separation. 28- Iterated Function System Models in 29- Denoising of chaotic signal using 30- An adaptive denoising algorithm for chaotic signals based on 31- Chaotic signal denoising based on adaptive smoothing 32- Structural health monitoring through chaotic interrogation. 33- Detecting strange attractors in turbulence. 34- Noise reduction in chaotic time-series data 35- Independent coordinates for strange attractors 36- Extracting qualitative dynamics from experimental data. 37- Singular-spectrum analysis: A toolkit for 38- Chaotic time series prediction with a global model: Artificial neural network. 39- Interval type-2 fuzzy neural networks for 40- Long-term prediction of chaotic 41- Chaotic wind power time series prediction via 42- Point and interval prediction of 43- Bayesian regularization of neural networks. 44- Denoising deep learning network based on 45- Mixed noise removal in hyperspectral image via 46- Deterministic nonperiodic flow. 47- Efficient algorithm for estimating the correlation dimension from 48- Measuring the strangeness of 49- Data assimilation for chaotic dynamics.

روش بهبودیافته کاهش نویز از سری زمانی آشوبناک به کمک شبکه عصبی و تحلیل طیف منفرد

علیرضا بهرامی^۱، سعید اصیل قره‌باغی^۱

^۱ دانشکده مهندسی عمران، دانشگاه خواجه نصیرالدین طوسی، تهران، ایران.

چکیده

در تحقیق حاضر روشی بهبود یافته برای کاهش نویز از سری زمانی حاصل از یک سیستم آشوبناک ارائه شده است. اساس این روش بر مبنای روش کاهش نویز ارائه شده توسط شریبر و گرسپرگر می‌باشد که دارای عملکردی مناسب و پیچیدگی کمتر نسبت به سایر روش‌های کاهش نویز از اطلاعات آشوبناک است. در اینجا از یک مدل کلی که به کمک شبکه عصبی ایجاد شده است به منظور مدل پیش‌بینی سری زمانی آشوبناک استفاده گردیده است. بر خلاف روش اصلی، استفاده از یک مدل پیش‌بینی کلی با نتایج بهتر در مقایسه با مدل‌های محلی و همچنین بهره گرفتن از روش بازسازی تحلیل طیف منفرد سبب ارائه روشی با دقت بالاتر شده است که در عین حال از مزایای منحصر به فرد روش اصلی نیز برخوردار می‌باشد. این روش بهبود یافته به سری زمانی حاصل از حالت آشوبناک معادلات لورنز که با نویز گاوسی آغشته شده، اعمال گردیده است. پس از اعمال روش کاهش نویز بهبود یافته، نتایج نهایی، کاهش حدود ۳۳ درصدی مقدار خطای مطلق میانگین را در مقایسه با روش اولیه نشان می‌دهند. همچنین خطای محاسبه بعد همبستگی پس از اعمال روش بهبود یافته به ۲ درصد کاهش یافته است.

کلیدواژه‌ها: کاهش نویز، سری زمانی آشوبناک، تحلیل طیف منفرد، شبکه عصبی، مدل کلی.

تاریخ دریافت: ۱۴۰۲/۱۰/۰۶

تاریخ پذیرش: ۱۴۰۳/۰۱/۲۹

*نویسنده مسئول: asil@kntu.ac.ir

۱- مقدمه

در سال‌های اخیر تحقیقات زیادی در زمینه کاهش نویز از اطلاعات سری‌های زمانی در زمینه‌های مختلف انجام پذیرفته است. به عنوان نمونه در مهندسی سازه و در بخش پایش سلامت سازه‌ها، در سال‌های اخیر تحقیقات گسترده‌ای در به‌کارگیری روش‌های کاهش نویز برای پایش مطمئن‌تر سازه‌ها و ارائه روش‌های قابل اتکاتر شناسایی آسیب در آن‌ها، انجام پذیرفته است. از میان این تحقیقات می‌توان به [1,2] برای کاهش نویز سیگنال‌های ارتعاشی برگرفته از حسگرها، یا تحقیق [3] برای به‌کارگیری روش‌های کاهش نویز به منظور بهبود پایش فراصوتی، اشاره نمود. رویکردهای جدید شناسایی آسیب در سازه‌ها در سال‌های اخیر، مانند روشی که در [4] ارائه شده است، توجه ویژه‌ای به روش‌های کاهش نویز نشان داده‌اند. همچنین در مهندسی زلزله، در تحقیق [5] با به‌کارگیری

روش‌های نوین کاهش نویز، روشی برای بهبود نسبت سیگنال به نویز در سیگنال‌های میکروزلرزه‌ای ارائه گردید که استفاده از فرآیندهای برخط را برای این سیگنال‌ها مطمئن‌تر می‌نماید. در پیش‌بینی بازارهای مالی نیز، در تحقیق [6] نشان داده شد که به‌کارگیری روش‌های کاهش نویز در یافتن الگوهای مخفی و پیش‌بینی دقیق‌تر این بازارها مؤثر است. یا در صنعت و ساخت قطعات، به‌کارگیری این روش‌ها می‌تواند سبب کاهش میزان خطای نسبی گردد [7]. از طرف دیگر کاربرد روش‌های کاهش نویز در شفاف‌سازی هرچه بهتر سیگنال‌ها و تصاویر، مانند آن‌چه در [8] انجام گرفته است، همواره مورد توجه محققان بوده است.

عبارت کاهش نویز به آن دسته از مسائل اطلاق می‌شود که در آن‌ها الگوریتمی ارائه می‌شود که هدف آن تفکیک سیگنال به دو بخش مطلوب و نامطلوب است. هر روش کاهش نویزی باید با این فرض عمل نماید که می‌توان به وسیله ارائه یک الگوریتم، سیگنال را به دو بخش «سیگنال» و «نویز» تجزیه نمود [9]. از طرفی دیگر الگوریتم ارائه شده باید توانایی تشخیص سیگنال بدون نویز را دارا باشد. روش‌های مرسوم مانند فیلترهای خطی از طیف فرکانسی برای تجزیه و تحلیل سیگنال‌ها استفاده می‌کنند. به عنوان مثال در استفاده از فیلترهای پایین‌گذر و بالاگذر به ترتیب فرض می‌شود که فرکانس‌های کلی سیگنال اصلی در محدوده‌ای پایین‌تر یا بالاتر از یک مقدار مشخص واقع شده‌اند. در صورتی که امکان تفکیک بر اساس مقیاس‌های زمانی مشخصه سیگنال ممکن نباشد، مؤلفه‌های پهن‌بند (Broad-band) طیف، مرتبط با نویز فرض می‌شوند در حالی که خطوط تیز به سیگنال نسبت داده می‌شوند [9]. این روند برای سیگنال‌هایی منظم از منابع معمولی که سیگنال‌های متناوب یا شبه‌متناوب را ارائه می‌دهند، مناسب است، اما اگر سیگنال متناوب یا شبه‌متناوب نباشد، فیلترهای خطی نمی‌توانند نویز را بدون مخدوش کردن سیگنال اصلی حذف نمایند [10,11]. این مورد به ویژه در مورد سیگنال‌هایی که منابعی آشوبناک دارند مصداق می‌یابد چرا که حتی سیگنال‌های خالص از سیستم‌های آشوبناک نیز طیف پهن‌بندی را نشان می‌دهند [12] و هیچ روشی مبتنی بر تبدیل فوری (Fourier-Based) قادر به تشخیص آن از نویز تصادفی نمی‌باشد [13].

از طرفی دیگر بهره گرفتن از خواص سیستم‌های آشوبناک در آزمایشگاه‌ها و یا در آزمایشات میدانی بدون بهره بردن از یک روش کاهش نویز مناسب امری بسیار دشوار و در برخی موارد انجام ناپذیر است، چرا که نمی‌توان تمام آزمایشات را به اندازه‌ای در شرایط کنترل شده به انجام رساند که نویز ایجاد شده سبب مشکل نشود [14]. لذا در طول سالیان گذشته روشی که بتواند به صورتی مناسب به این مهم تحقق بخشد، همواره مورد توجه محققین در رشته‌های مختلف قرار داشته است.

تحقیقات مربوط به مساله کاهش نویز از سیگنال‌های آشوبناک را می‌توان به سه دسته کلی طبقه‌بندی نمود [15]. دسته اول مربوط به

دسته سوم از تحقیقات انجام شده مربوط به زمانی است که هیچ‌گونه اطلاعات قبلی از سیگنال، دینامیک یا نویز در اختیار نباشد. در این حالت فرآیند کاهش نویز باید با بکارگیری یک سری از فرضیات صریح یا ضمنی انجام گیرد. لذا نمی‌توان انتظار داشت که از میان روش‌های ارائه شده در این دسته، بتوان روشی را یافت که کاملاً عمومی باشد و بتوان آن را در تمامی مسائل مورد استفاده قرار داد [15]. از میان تحقیقات شاخص و تاثیرگذار ارائه شده در این دسته، می‌توان به [19-24] اشاره نمود.

با استفاده از مباحث مطرح شده در تحقیقات فوق، در سال‌های بعد تحقیقات بیشتری در زمینه کاهش نویز از سری زمانی آشوبناک ارائه شدند و این تحقیقات تا به امروز نیز ادامه دارند. به عنوان مثال، با تکیه بر ایده کمینه‌سازی مطرح شده در تحقیق [22] توسط کاستلیک و یورک، دیویس و همکاران در [18,25] روش‌هایی را برای کاهش نویز با استفاده الگوریتم‌های بهینه‌یابی نزول گرادیان (Gradient Descent) و لونبرگ-مارکوارت (Levenberg-Marquardt) ارائه نمودند. نمونه دیگر از روش‌هایی که بر این مبنا ارائه شده‌اند، روشی است که در [14] توسط شیربر و گرسبرگر ارائه شده است. این روش علاوه بر آن‌که عملکردی مناسبی را ارائه می‌نماید و به سادگی قابل پیاده‌سازی می‌باشد، دشواری‌های عددی دیگر روش‌های بر مبنای کمینه‌یابی، نظیر کاهش سرعت یا توقف الگوریتم هنگامی که مسیر عملاً غیرهذلولی (Non-hyperbolic) می‌شود، را ندارد [14,18]. در نمونه‌ای دیگر رابینز، الکساندر و همکاران با بهره گرفتن از توپولوژی جاذب و همچنین ایده متصل بودن و پیوستگی نقاط بر روی آن، با فرض کمتر بودن تعداد نقاط آلوده شده نسبت به کل نقاط، در [26-28] روش‌هایی را به منظور شناسایی و حذف نقاط آلوده شده به نویز ارائه نمودند. همچنین ونگ و همکاران نیز در تحقیقاتی نظیر [29-31]، روش‌هایی را برای کاهش نویز از سری زمانی آشوبناک با استفاده از فیلترهای مخصوص، ارائه کرده‌اند.

با توجه به مطالب فوق و مزایایی که برای روش کاهش نویز ارائه شده توسط شیربر و گرسبرگر بیان شد، در تحقیق حاضر تلاش بر ارائه روشی بهبود یافته، بر مبنای این روش، به منظور کاهش نویز از سری زمانی آشوبناک می‌باشد که علاوه بر حفظ خصوصیات منحصر به فرد روش اصلی، عملکرد نهایی آن را نیز به طور قابل ملاحظه‌ای بهبود بخشد. روش ارائه شده توسط شیربر و گرسبرگر و به طور کلی روش‌های کاهش نویز بر مبنای کمینه‌یابی را می‌توان در دو گام خلاصه نمود. بخش اول ارائه مدل پیش‌بینی از سری زمانی آشوبناک و بخش دوم، ارائه الگوریتمی برای کاهش خطای پیش‌بینی [18]. در ادامه هر یک از این بخش‌ها به طور مجزا برای روش شیربر و گرسبرگر بیان و بهبودهای در نظر گرفته شده در هر بخش، ارائه خواهند شد. در تحقیق حاضر بخش سوم تحت عنوان پس‌پردازش نیز به این دو بخش افزوده شده است که توضیحات کامل مربوط به آن در ادامه بیان خواهد شد.

حالتی است که دینامیک سیستم مشخص باشد. از تحقیقات شاخص در این دسته می‌توان به [16,17] اشاره نمود. در این تحقیقات ایده کلی بر مبنای تعیین محدوده‌ای مجاز برای نقاط در فضای حالت با استفاده از تجزیه چندراهه‌های (Manifolds) پایدار و ناپایدار قرار گرفته است. به این صورت که با جلو بردن نقاط در زمان و در راستای چندراهه‌های پایدار (که خاصیت جذب‌کنندگی دارند) و همچنین با عقب بردن نقاط در زمان و در راستای چندراهه‌های ناپایدار (که خاصیت دفع‌کنندگی دارند)، یک محدوده مجاز برای حرکت نقطه مشخص می‌شود که نقاط می‌توانند در زمان مشخص در آن محدوده قرار داشته باشند. نقاطی که در زمان مشخص، خارج از محدوده مجاز قرار گرفته باشند، تحت اثر نویز طبقه‌بندی خواهند شد [16]. بدیهی است که اگر چندراهه‌های پایدار و ناپایدار نسبت به یکدیگر در وضعیت عمود یا نزدیک به عمود باشند، عملکرد این روش‌ها بیشینه و با کاهش این زوایا عملکرد کاهش خواهد یافت. چالش اصلی پیش روی روش‌هایی که در این دسته ارائه می‌شوند، نحوه برخورد و رفع ناپایداری‌های عددی است که در هنگام ساخت ماتریس‌های ژاکوبی (Jacobian Matrices) ظاهر می‌شوند. این‌ها همان ناپایداری‌هایی هستند که باعث ایجاد آشوب در سیستم و نماهای لیاپانوف (Lyapunov Exponents) مثبت شده‌اند [15]. راهکارهایی که اکثر روش‌های این دسته برای مقابله به این ناپایداری‌های عددی ارائه می‌کنند، از لحاظ محاسباتی بسیار هزینه‌بر می‌باشند [18]. علاوه بر این موضوع، در بسیاری از موارد، هیچ‌گونه اطلاعاتی از دینامیک سیستم در دسترس نمی‌باشد و یا کسب هرگونه اطلاعات از دینامیک سیستم، از لحاظ اقتصادی بسیار هزینه‌بر و یا نیازمند به تجهیزات مخصوص است.

دسته دوم روش‌های پاکسازی آماری می‌باشد. روش‌های جداسازی سیگنال در این دسته با این فرض ارائه شده‌اند که از قبل یک سیگنال بدون نویز از سیستم موجود باشد. از این سیگنال مرجع برای بدست آوردن مشخصات آماری حرکت در طول جاذب آشوبناک (Attractor) استفاده می‌شود. در واقع در این دسته از روش‌ها، از سیگنال مرجع به عنوان وسیله‌ای برای تشخیص سیگنال اصلی از نویز استفاده می‌شود. به این صورت که به جای پاسخ به هرگونه پرسش عمومی یا آماری در مورد سیستم، با استفاده از تقریبی از دیتای آلوده شده، از سیگنال مرجع برای پاسخ به این سوالات استفاده می‌شود [15]. از تحقیقات مهم در این زمینه می‌توان به [19] اشاره نمود. روش‌های پاکسازی آماری نسبت به روش‌های دسته اول عملکرد پایین‌تری را ارائه می‌نمایند اما در عین حال نیازمند اطلاعات کمتری از سیستم نیز می‌باشند. از طرفی دیگر بدست آوردن سیگنال مرجع، در اکثر موارد امری بسیار دشوار و نیازمند فراهم آمدن شرایط آزمایشگاهی مناسب و ادوات مخصوص می‌باشد که برای بسیاری از کارهای تحقیقاتی و آزمایشات درمحل، امکان‌پذیر نمی‌باشد.

۲- مدل پیش‌بینی سری زمانی آشوبناک

اولین گام در اکثر روش‌های کاهش نویز از سری زمانی آشوبناک، ارائه مدلی برای پیش‌بینی و یا تقریب سری زمانی می‌باشد. این مدل می‌تواند به صورت کلی (Global) یا محلی (Local) ارائه شود. مدل پیش‌بینی و یا تقریب ارائه شده باید طوری باشد که در نبود نویز دقت بسیار بالایی را نشان دهد و نتایج آن عملاً بر سری زمانی منطبق باشد. در عین حال زمانی که سری زمانی آشوبناک به نویز آلوده شده باشد نتایج این مدل پیش‌بینی یا تقریب باید به نحوی باشند که نه کاملاً بر سری زمانی منطبق شود (نویز را مدل نماید) و نه آنقدر خطای آن زیاد باشد که دینامیک مدل نشود [18]. نخستین گام برای ارائه یک مدل پیش‌بینی و یا تقریب از سری زمانی آشوبناک، بازسازی کیفی فضای حالت دینامیک آن است که در ادامه به توضیح مختصر دو مورد از مورد استفاده‌ترین روش‌ها برای این منظور پرداخته خواهد شد.

۲-۱- بازسازی کیفی فضای حالت با استفاده از اطلاعات سری زمانی آشوبناک

دو روش اصلی به منظور بازسازی کیفی فضای حالت، با استفاده از اطلاعات سری زمانی آشوبناک، روش مختصات تأخیر یافته (Delayed Coordinates) و تحلیل طیف منفرد (Singular Spectrum Analysis) می‌باشند [32]. روش مختصات تأخیر یافته در واقع حالت تعمیم یافته‌ای از نظریه تعبیه‌سازی تاکینز (Takens Embedding Theorem) می‌باشد [33,34]. در این روش اطلاعات سری زمانی در مقابل نسخه تأخیر یافته‌ای از خودش ترسیم می‌گردد. دو متغیر اصلی که باید برای بکارگیری این روش مشخص شوند، بُعد تعبیه‌سازی (m) و گام زمانی تأخیر (T) می‌باشند (معادله ۱). به منظور اینکه فضای حالت بازسازی شده با این روش، دینامیک سیستم را به طور کیفی حفظ نماید، ثبت سری زمانی با گام زمانی یکسان و مشخص کردن مقادیر مناسب برای m و T الزامی می‌باشد. برای یافتن این دو متغیر اسکالر روش‌های زیادی ارائه شده است، اما مورد استفاده‌ترین روش به منظور تخمین مقدار m ، روش همسایه‌های کاذب و برای T روش اطلاعات متقابل میانگین و تابع خودهمبستگی (Autocorrelation Function) می‌باشد [35]. در این تحقیق از این روش به منظور بازسازی فضای حالت برای ارائه مدل پیش‌بینی استفاده شده است.

$$x_{(i)} = (x_{(i)}, x_{(i+T)}, \dots, x_{(i+(m-1)T)}) \quad (1)$$

روش تحلیل طیف منفرد توسط بلومهد و کینگ در سال ۱۹۸۶ ارائه شد [36]. مبانی ریاضی این روش بر مبنای تحلیل مؤلفه اصلی (Principal Component Analysis) در فضای برداری مختصات تأخیر یافته، برای یک سری زمانی می‌باشد [37]. اگر اطلاعات سری زمانی به صورت اسکالر باشد، در این روش، ابتدا بردارهای p بُعدی

($p > m$) با $T = 1$ به روش مختصات تأخیر یافته به صورت زیر تشکیل می‌شود:

$$x_{(i)}^p = (x_{(i)}, x_{(i+1)}, \dots, x_{(i+p-1)}) \quad (2)$$

بردارهای حالت m بُعدی نهایی، تصویری از $x_{(i)}^p$ بر روی m مؤلفه اصلی می‌باشد که توسط اطلاعات در فضای $\mathbb{R}^p$ با استفاده از تجزیه مقدار منفرد (Singular Value Decomposition) تعریف شده است به طوری که:

$$x_{(i)}^m = P x_{(i)}^p \quad (3)$$

که در آن P ماتریسی $m \times p$ است [36]. به دلیل سهولت استفاده و هزینه محاسباتی کمتر، در تحقیق حاضر، در مرحله ارائه مدل پیش‌بینی از روش مختصات تأخیر یافته استفاده شده است و از مزایای روش تحلیل طیف منفرد در مرحله پس‌پردازش بهره گرفته شده است که در ادامه به طور کامل توضیح داده خواهد شد.

۲-۲- استفاده از شبکه عصبی مصنوعی

با توجه به عملکرد عالی شبکه عصبی مصنوعی در تقریب توابع، کاروناسینگ و همکاران در تحقیقی نشان دادند که ارائه یک مدل پیش‌بینی کلی با استفاده از شبکه عصبی، علاوه بر رعایت نمودن موارد ذکر شده در قسمت قبل برای یک مدل پیش‌بینی مناسب، می‌تواند نتایج بهتری را نیز نسبت به مدل‌های محلی ارائه نماید [38]. پس از آن، انواع مختلفی از شبکه‌های عصبی و روش‌های یادگیری ماشین به منظور پیش‌بینی انواع خاصی از سری‌های زمانی آشوبناک، برای اهداف مشخص، توسط محققان توسعه داده شد که برخی از استفاده‌های اخیر از آن شامل [39-42] می‌باشد. بهترین عملکرد روش ارائه شده توسط کاروناسینگ و همکاران نسبت به روش‌های محلی مربوط به حالت بدون نویز است اما برتری آن در حالتی که سری زمانی به نویز آغشته باشد نیز نشان داده شده است [38]. در مدل پیش‌بینی کاروناسینگ و همکاران از یک شبکه عصبی با یک لایه مخفی و ۱۷۵ نرون استفاده شده است که ورودی آن بردارهای فضای حالت بازسازی شده از اطلاعات سری زمانی ($x_{(i)}$) و خروجی آن آخرین مؤلفه بردار فضای حالت در زمان آینده (x_{i+T}) می‌باشد. تابع فعال‌سازی مورد استفاده در آن تابع سیگموئید (Sigmoid) است و از الگوریتم لونیگ-مارکوارت به منظور آموزش شبکه عصبی استفاده شده است [38]. از این رو در تحقیق حاضر نیز از روشی مشابه به منظور ارائه مدل پیش‌بینی بهره گرفته شده است. با این تفاوت که با تغییر در معماری شبکه عصبی و دیگر جزئیات آن و استفاده از الگوریتم متعادل‌سازی بیزی (Bayesian Regularization) (رجوع شود به [43]) نتایج آن به خصوص در حالت نبود نویز تا حد قابل توجهی بهبود داده شده است.

تکرار، با اعمال تغییرات کوچکی به مسیر، سعی بر کاهش میزان نویز یا خطای پیش‌بینی می‌باشد. به این صورت که در هر تکرار:

$$x_{i,new} = x_{i,old} + \alpha \cdot \varepsilon_i \quad (۷)$$

که در آن $x_{i,old}$ و $x_{i,new}$ عضو i ام سری زمانی قبل و بعد از اعمال تغییرات می‌باشند، $0 < \alpha < 1$ ضریب کاهش خطا و ε_i خطای پیش‌بینی برای عضو i ام سری زمانی است که به صورت زیر تعریف می‌شود:

$$\varepsilon_i = x_i - \hat{x}_i \quad (۸)$$

در رابطه فوق $\hat{x}_i$ مقدار پیش‌بینی شده توسط مدل پیش‌بینی برای x_i می‌باشد و با فرض استفاده از یک گام زمانی آینده در مدل پیش‌بینی به صورت زیر محاسبه خواهد شد [18]:

$$\hat{x}_i = F(X_{i-1}) \quad (۹)$$

در تحقیق حاضر مدل پیش‌بینی جامع، که با استفاده از شبکه عصبی ارائه شده است به عنوان F در نظر گرفته شده است. سپس با بهره‌گیری از مبانی ارائه شده از روش شریبر-گرسبرگر، در مرحله اول الگوریتم کاهش نویز، هدف اصلی کاهش هرچه بیشتر خطای پیش‌بینی و رساندن مقادیر نویز به حدودی است که بتوان در مرحله دوم الگوریتم، از روش بازسازی تحلیل طیف منفرد، به منظور کاهش هرچه بیشتر نویز استفاده نمود.

استفاده از مدل پیش‌بینی جامع بر مبنای شبکه عصبی باعث می‌شود که به دلیل دقت بالای این مدل در پیش‌بینی سری‌های زمانی بدون نویز و با نویز بسیار کم، بتوان بدون نگرانی از به هم ریختگی و آسیب به اطلاعات، بدون داشتن اطلاعات قبلی از میزان نویز، آن را به سری‌های زمانی بدست آمده در شرایط آزمایشگاهی اعمال نمود. همچنین استفاده از این مدل در عین کاهش هزینه محاسباتی باعث افزایش دقت پیش‌بینی نیز خواهد شد. از طرفی در مدل‌های جامع به دلیل استفاده از تمامی اطلاعات در ارائه پیش‌بینی، مشکل کاهش نویز تنها در مسیرهای پایدار وجود نخواهد داشت.

۲-۳- پس‌پردازش نتایج

پس از آن‌که خطای پیش‌بینی با کمک قسمت اول الگوریتم کاهش یافت و مقداری از نویز نیز حذف گردید، در مرحله دوم الگوریتم، با استفاده از روش بازسازی تحلیل طیف منفرد، که یک روش مناسب برای کار با سری‌های زمانی آلوده به نویز می‌باشد [37] و از هماهنگی مناسبی با روش‌های شبکه عصبی برخوردار است [44] به کاهش بیشتر نویز پرداخته می‌شود. این روش با وجود آنکه مدت نسبتاً زیادی از پیدایش آن می‌گذرد اما اخیراً بار دیگر در تحقیقاتی مانند [45] مورد توجه محققان، به منظور توسعه روش‌های کاهش نویز، واقع شده است. در این روش بازسازی، سری زمانی به M بُعد ($M > m$) تجزیه می‌گردد به‌طوری‌که بُدهای ابتدایی بخش اعظم اطلاعات را شامل می‌شوند و هر چه

۳- الگوریتم کاهش نویز

پس از ساخته شدن مدل پیش‌بینی سری زمانی آشوبناک به کمک شبکه عصبی، در مرحله بعد نیاز به الگوریتمی برای کاهش نویز است. الگوریتم در نظر گرفته شده در تحقیق حاضر، یک الگوریتم ۲ مرحله‌ای می‌باشد. بخش اول الگوریتم معطوف به کاهش خطای پیش‌بینی و بخش دوم به پس‌پردازش نتایج حاصل از قسمت اول اختصاص دارد. در ادامه در دو بخش مجزا به تشریح این دو بخش پرداخته خواهد شد.

۳-۱- کاهش خطای پیش‌بینی

الگوریتم در نظر گرفته شده به منظور کاهش خطای تقریب یا پیش‌بینی، یک الگوریتم تکرار شونده با الهام از روش ارائه شده توسط شریبر و گرسبرگر در [14] می‌باشد. دلیل انتخاب این روش، سهولت پیاده‌سازی، عملکرد مناسب و عدم توقف و یا کاهش سرعت الگوریتم در مواجهه با مسیرهای غیرهذلولی می‌باشد. همچنین این روش در مسائلی که میزان نویز آن‌ها برای بکارگیری دیگر روش‌ها زیاد است، مناسب می‌باشد [18]. در روش ارائه شده توسط شریبر و گرسبرگر، از مدل تقریب محلی خطی استفاده شده است و برای آن‌که کاهش نویز تنها در جهت پایدار صورت نپذیرد، در مدل تقریب شامل اطلاعات گذشته و آینده می‌باشد. در این روش بردارهای بازسازی شده (x_i) ، اطلاعات l جزء قبل تا k جزء بعد از $x_{(i)}$ را شامل می‌شوند و در واقع دارای بُعدی معادل $(l + k + 1)$ می‌باشند (معادله ۴) [34]. در این روش تقریبی از هر $x_{(i)}$ با استفاده از معادله ۵ بدست می‌آید.

$$x_{(i)} = (x_{(i-l)}, x_{(i-l+1)}, \dots, x_{(i)}, \dots, x_{(i+k-1)}, x_{(i+k)}) \quad (۴)$$

$$x_{(i)} = \sum_{j=-l}^k a_j^{(i)} x_{(i+j)} + b^{(i)} = a^{(i)} x_{(i)} + b^{(i)} \quad (۵)$$

مقادیر $a^{(i)}$ و $b^{(i)}$ با تشکیل یک همسایگی $k + l + 1$ بُعدی از نزدیکترین نقاط نزدیک به $x_{(i)}$ ($\mathfrak{N}^{(i)}$) و کمینه کردن رابطه ۶ در این همسایگی بدست می‌آیند [14].


$$x_i = \sum_{x_{(m)} \in \mathfrak{N}^{(i)}} (a^{(i)} x_{(m)} + b^{(i)} - x_{(m)})^2 \quad (۶)$$

متغیرهای اصلی که باید برای عملکرد مناسب این روش مشخص شوند شامل تعداد همسایگی‌ها (kn) ، l ، k و a_0 می‌باشند. مقدار a_0 مقدار اصلاح را مشخص می‌کند و دارای مقداری $0 < a_0 < 1$ است. این مقدار هر چه قدر به واحد نزدیکتر باشد در هر تکرار، اصلاح کمتری بر روی مقادیر انجام می‌شود. برای محاسبه این مقادیر روش مشخصی وجود ندارد اما از طریق سعی و خطا می‌توان مقدار مناسب برای آن‌ها را در مسائل مختلف تخمین زد [14]. اساس عملکرد روش ارائه شده توسط شریبر و گرسبرگر را می‌توان نوع دیگری نیز تفسیر نمود. در واقع در این روش در هر

ام در هر تکرار نسبت به تکرار قبل از یک مقدار مشخص کمتر باشد. از لحاظ هندسی اطلاعات جای گرفته در بُعد M ام، تنها شامل بخشی از شکستگی‌های نمودار حاصل از اتصال نقاط سری زمانی می‌باشد. از طرفی با فرض وجود تعداد نقاط زیاد در سری زمانی و آشوبناک بودن آن (نقاط بر روی جاذب آشوبناک می‌بایست صاف و بدون شکستگی باشند) این شکستگی‌ها مربوط به اثر نویز در نظر گرفته می‌شوند. فرآیند عملکرد توامان هر دو بخش الگوریتم ارائه شده در این تحقیق در نمودار گردش ارائه شده در شکل ۱ قابل ملاحظه می‌باشد.

شماره بُعد افزایش یابد درصد اطلاعات آن بُعد نیز کاهش خواهد یافت. در مواجهه با سری‌های زمانی آلوده به نویز، از اطلاعات m بُعد اول به منظور دستیابی به یک سری زمانی با نویز کمتر استفاده می‌شود [37].

در این قسمت، سری زمانی که پس از انجام مرحله اول الگوریتم ایجاد شده است در یک فرآیند تکرار شونده، با استفاده از روش بازسازی تحلیل طیف منفرد، در بُعد تجزیه می‌گردد و در هر تکرار شرط انتخاب مناسب M (بزرگتر از بُعد مورد استفاده در مرحله ارائه مدل پیش‌بینی)، بُعد M ام آن قدر درصد کمی از اطلاعات را با خود دارد که تنها می‌تواند بخشی از نویز را در خود جای داده باشد. فرآیند تکرار تا جایی ادامه خواهد یافت که اطلاعات بُعد M



شکل ۱) نمودار گردش الگوریتم دو قسمتی ارائه شده برای کاهش نویز در تحقیق حاضر

۴-۱- اطلاعات مورد استفاده


سری زمانی مورد استفاده در تحقیق حاضر، برگرفته از اطلاعات محور $x(t)$ حاصل از حل حالت آشوبناک معادلات دیفرانسیل ارائه شده توسط لورنز می‌باشد [46]. فرم کلی این معادلات به صورت زیر می‌باشد:

۴- تحلیل و نتایج

در این بخش به ارائه نتایج و تحلیل آن‌ها در سه قسمت اطلاعات مورد استفاده، تحلیل و مقایسه نتایج حاصل از مدل پیش‌بینی و تحلیل و مقایسه نتایج حاصل از بکارگیری روش حذف نویز پرداخته خواهد شد.

به دست آمده است. ۶۰۰۰ مؤلفه از این سری زمانی $(x_{(t)})$ در این تحقیق در نظر گرفته شده است.

به عنوان سری زمانی آلوده به نویز، سری زمانی آشوبناک بدون نویز فوق، به وسیله یک نویز گاوسی (Gaussian) با میانگین صفر و انحراف معیاری معادل ۵ درصد از انحراف معیار سیگنال آلوده نشده (۱۲/۶۹) آلوده گردیده است (شکل ۲). از ۱۰ درصد از اطلاعات سری‌های زمانی، در شبکه‌های عصبی مورد استفاده به منظور صحت‌سنجی (آزمون) استفاده شده است.




(ب)

شکل ۲ (الف) بازسازی سری زمانی بدون نویز در نظر گرفته شده و (ب) سری زمانی نویزدار در نظر گرفته شده با ۵ درصد نویز افزوده به روش مختصات تأخیر یافته در ۲ بُعد و تأخیر ۳ گام زمانی،

$$\begin{aligned} \dot{x} &= \sigma(y - x) \\ \dot{y} &= -xz + \gamma x - y \\ \dot{z} &= xy - bx \end{aligned} \quad (10)$$

که در آن‌ها σ عدد پرنیتل (Prandtl)، γ عدد رایله (Rayleigh) و b متغیری قابل تنظیم می‌باشد. این اعداد مرتبط با مباحث دینامیک سیالات می‌باشند. (برای اطلاعات بیشتر به [46] مراجعه شود). در تحقیق حاضر این متغیرها معادل $\sigma = 16$ ، $\gamma = 45.92$ و $b = 4$ در نظر گرفته شده‌اند. مولفه $x_{(t)}$ از حل معادلات فوق با روش رانگا-کوتا (Runge-Kutta) مرتبه ۴ با گام زمانی $\Delta t = 0.01$



(الف)

۴-۲- تحلیل و مقایسه نتایج حاصل از مدل پیش‌بینی سری زمانی آشوبناک

بهبودهای اعمال شده بر روی مدل پیش‌بینی جامع ارائه شده توسط کاروناسینگ و همکاران که با استفاده از شبکه عصبی ارائه شده است، سبب بهبود دقت این مدل و کاهش هزینه محاسباتی آن شده است. این بهبودها شامل افزایش تعداد لایه‌های مخفی از ۱ به ۲ لایه و استفاده از تابع فعالساز $\tanh(x)$ به جای تابع سیگموئید است. مقادیر بُعد تعبیه‌سازی (m) و گام زمانی تأخیر (T) با توجه به نتایج ارائه شده در [38]، برای سری زمانی بدون نویز به ترتیب ۷ و ۶ و برای سری زمانی نویزدار به ترتیب ۱۰ و ۳ در نظر گرفته شده است. مقایسه نتایج پیش‌بینی بین مدل کاروناسینگ و همکاران و مدل بهبود داده شده با استفاده از مقایسه مقدار خطای مطلق میانگین (Mean Absolute Error) بین مقادیر پیش‌بینی شده و مقادیر اصلی انجام شده است. خطای مطلق میانگین از طریق رابطه زیر قابل محاسبه می‌باشد:

$$MAE = \frac{\sum_{i=1}^N \|x_i - \hat{x}_i\|}{N} \quad (11)$$

که در آن، x_i مقدار مورد نظر در سری زمانی و $\hat{x}_i$ مقدار پیش‌بینی شده از آن توسط مدل پیش‌بینی می‌باشد. با توجه به نتایج ارائه

شده در جدول ۱، اعمال بهبودهای فوق به مدل پیش‌بینی جامع ارائه شده توسط کاروناسینگ و همکاران، باعث بهبود دقت پیش‌بینی حدود ۹۰ درصدی در حالت بدون نویز و بهبود حدود ۱۰ درصدی در حالت نویزدار شده است. این بهبودها با کاهش تعداد نرون‌های مورد استفاده در شبکه عصبی از ۱۷۵ در تحقیق کاروناسینگ و همکاران به ۵۰ در تحقیق حاضر بدست آمده است. دقت بسیار بالای مدل پیش‌بینی در حالت بدون نویز باعث می‌شود که اعمال روش کاهش نویز ارائه شده در تحقیق حاضر به سری‌های

جدول ۱) نتایج حاصل از مدل پیش‌بینی کاروناسینگ و همکاران و مدل بهبود یافته آن در حالت نویزدار و بدون نویز

خطای مطلق میانگین			
مدل‌های جامع شبکه عصبی مصنوعی		گام زمانی	
مدل بهبود یافته (درصد بهبود)	تحقیق کاروناسینگ و همکاران [38]	پیش‌بینی	گام زمانی
(۱۱٪) ۰/۵۷۰۱	۰/۶۳۹۵	۱	۵ درصد
(۱۲٪) ۰/۵۹۶۰	۰/۶۷۶۱	۳	نویز
(۷٪) ۰/۶۶۶۲	۰/۷۱۶۷	۵	افزوده
(۹۰٪) ۰/۰۰۰۳	۰/۰۰۳۲	۱	
(۹۰٪) ۰/۰۰۰۳	۰/۰۰۳۶	۳	بدون نویز
(۹۱٪) ۰/۰۰۰۳	۰/۰۰۴۲	۵	

زمانی بدون نویز یا دارای نویز اندک، سبب آسیب چندانی به اطلاعات آن نشود و نوعی قدرت تشخیص را به روش کاهش نویز می‌افزاید.

۳-۴- تحلیل و مقایسه نتایج حاصل از بکارگیری روش کاهش نویز

به منظور انجام مقایسه، روش کاهش نویز شریبر-گرسبرگر و روش بهبود یافته آن، به سری زمانی برگرفته از حل معادلات لورنز که با نویز گاوسی با میانگین صفر و انحراف معیار ۵ درصد سیگنال بدون نویز آلوده شده است، اعمال گردیده است. متغیرهای l و k در روش اصلی به ترتیب برابر با ۴ و ۵ در نظر گرفته شده‌اند. در روش بهبود یافته نیز متغیر m معادل ۱۰ در نظر گرفته شده است. به این ترتیب در هر دو روش بُعد تعبیه‌سازی (معادل $l + k + 1$ در روش اصلی و m در روش بهبود یافته) برابر می‌باشد. متغیرهای a_0 ، kn و تعداد تکرارها در روش شریبر-گرسبرگر از طریق آزمون و خطا به ترتیب معادل ۵۰، ۰/۵ و ۴۰ انتخاب شده‌اند. در روش بهبود یافته مدل پیش‌بینی از طریق شبکه عصبی با دولا به مخفی که به ترتیب دارای ۲۰ و ۳۰ نرون می‌باشند عمل می‌کند. همچنین در این روش متغیر $\alpha = 0.1$ و تعداد تکرارها برابر ۴۰ در نظر گرفته شده است.


مقایسه عملکرد میان دو روش از طریق محاسبه ۲ معیار مختلف انجام گرفته است. معیار نخست محاسبه بُعد همبستگی (Correlation Dimension) و معیار دیگر محاسبه خطای مطلق میانگین نسبت به سری زمانی بدون نویز می‌باشد. به منظور محاسبه بُعد همبستگی، از روش محاسبه آن به کمک شبکه‌بندی جعبه‌ای (Box-assisted Correlation)، ارائه شده توسط تیلر در [47]، استفاده شده است که روشی بهینه برای محاسبه این متغیر به شمار می‌رود (اطلاعات بیشتر در این زمینه در [47,48] آورده شده است).

با توجه به نتایج ارائه شده در شکل ۳) مقایسه بخشی از نمودارهای حاصل از سری‌های زمانی کاهش نویز داده شده به دو روش شریبر-گرسبرگر و روش بهبود یافته

همانطور که در شکل ۵ مشخص است، نمودار حاصله از سری زمانی بدست آمده از روش بهبود یافته، در مقایسه با روش اصلی، به میزان قابل ملاحظه‌ای مشابه سری زمانی بدون نویز و از نظر فاصله به آن نزدیک‌تر می‌باشد. این موضوع باعث می‌شود که فضای حالت بازسازی شده با استفاده از اطلاعات سری زمانی حاصله از روش بهبود یافته نسبت به روش اولیه، به حالت بدون نویز نزدیک‌تر باشد (شکل ۴).

از طرفی، به دلیل آن‌که روش بهبود یافته از مبانی روش کاهش نویز شریبر-گرسبرگر و روش بازسازی تحلیل طیف منفرد بهره می‌برد، با توجه به موارد ارائه شده در [14,36]، در این روش اطلاعات چندانی از بین نخواهد رفت و قسمت‌های حذف شده از اطلاعات عمدتاً نویز خواهد بود.

بنابراین این روش می‌تواند اطلاعات مناسبی از شکل کلی فضای حالت و جاذب آشوبناک را فراهم آورد. با توجه به مواردی که در قسمت‌های قبل بیان شد، در بسیاری از مسائل واقعی، به ویژه در مسائل مرتبط با سیستم‌های دینامیکی آشوبناک، یافتن هرگونه اطلاعاتی از دینامیک سیستم بسیار ارزشمند است. در این‌گونه مسائل یافتن شکل کلی فضای حالت سیستم دینامیکی و جاذب‌ها می‌تواند در یافتن ویژگی‌های دینامیکی سیستم بسیار کمک کننده باشد [49].





شکل ۳) مقایسه بخشی از نمودارهای حاصل از سری‌های زمانی کاهش نویز داده شده به دو روش شریبر-گرسبرگر و روش بهبود یافته



جدول ۲) نتایج عملکرد روش کاهش نویز شریبر-گرسبرگر و روش کاهش نویز بهبود یافته در تحقیق حاضر

روش کاهش نویز	سری زمانی		خطای مطلق میانگین
	روش شریبر-گرسبرگر	روش شریبر-گرسبرگر با ۵ درصد نویز گاوسی افزوده	سری زمانی بدون نویز
۰/۱۷۵۷	۰/۲۶۲۱	۰/۵۰۲۸	-
(۲٪)	(۹٪)	(۱۳٪)	۱/۷۵۷۰
۱/۷۸۹۸	۱/۹۰۶۲	۱/۹۹۱۶	همبستگی (درصد خطا)

جدول ، استفاده از مدل پیش‌بینی جامع بهبود یافته بر مبنای شبکه عصبی و همچنین به کارگیری روش بازسازی تحلیل طیف منفرد در روش کاهش نویز شریبر-گرسبرگر باعث بهبود ۳۳ درصدی در مقدار خطای مطلق میانگین و همچنین کاهش میزان خطای محاسبه بُعد همبستگی از ۹ درصد به ۲ درصد می‌شود. از طرفی دیگر، با توجه به شکل ۳ مشخص می‌شود که استفاده از بازسازی تحلیل طیف منفرد در روش کاهش نویز باعث کاهش چشمگیر شکستگی‌های ناشی از نویز در شکل نمودار حاصل از سری زمانی می‌گردد. در واقع استفاده از تحلیل طیف منفرد علاوه بر کاهش بخشی از نویز باعث هموار شدن و به طبع آن مشخص‌تر شدن شکل کلی فضای حالت بازسازی شده خواهد شد.





(الف)



(ب)

شکل ۴ (الف) فضای حالت بازسازی شده در ۲ بعد، با تاخیر ۳ گام زمانی و (۲) بخشی از نمودار سری زمانی نویزدار شده، پس از اعمال روش کاهش نویز بهبود یافته، (ب) فضای حالت بازسازی شده در ۲ بعد، با تاخیر ۳ گام زمانی و (۲) بخشی از نمودار سری زمانی نویزدار شده، پس از اعمال روش کاهش نویز ارائه شده توسط شریبر و گرسبرگر در [14].



شکل ۵ مقایسه بخشی از نمودارهای بدست آمده از روش کاهش نویز شریبر-گرسبرگر و روش بهبود یافته با (الف) سری زمانی بدون نویز (ب) سری زمانی با ۵ درصد نویز افزوده

wavelet adaptive thresholding method. Scientific Reports. 2022;12(1):22186.

6- Dastgerdi AK, Mercorelli P. Investigating the effect of noise elimination on LSTM models for financial markets prediction using Kalman Filter and Wavelet Transform. WSEAS Trans Bus Econ. 2022;19:432-41.

7- Niu P, Sun Y, Gong Z. Research on the chaotic characteristics and noise reduction prediction of information system anomalies in equipment manufacturing enterprises. Sustainability. 2021;13(9):4911.

8- Li Y-x, Wang L. A novel noise reduction technique for underwater acoustic signals based on complete ensemble empirical mode decomposition with adaptive noise, minimum mean square variance criterion and least mean square adaptive filter. Defence Technology. 2020;16(3):543-54.

9- Grassberger P, Hegger R, Kantz H, Schaffrath C, Schreiber T. On noise reduction methods for chaotic data. Chaos: An Interdisciplinary Journal of Nonlinear Science. 1993;3(2):127-41.

10- Han M, Liu Y, Xi J, Guo W. Noise smoothing for nonlinear time series using wavelet soft threshold. IEEE signal processing letters. 2006;14(1):62-5.

11- Shang L-J, Shyu K-K. A method for extracting chaotic signal from noisy environment. Chaos, Solitons & Fractals. 2009;42(2):1120-5.

12- Wei G, Shu H. H_{∞} filtering on nonlinear stochastic systems with delay. Chaos, Solitons & Fractals. 2007;33(2):663-70.

13- Billings SA, Lee KL. A smoothing algorithm for nonlinear time series. International Journal of Bifurcation and Chaos. 2004;14(03):1037-51.

14- Schreiber T, Grassberger P. A simple noise-reduction method for real data. Physics letters A. 1991;160(5):411-8.

15- Abarbanel H. Analysis of observed chaotic data. Springer Science & Business Media; 2012 Dec 6.

16- Farmer JD, Sidorowich JJ. Exploiting chaos to predict the future and reduce noise. In Evolution, learning and cognition 1988 (pp. 277-330).

17- Hammel SM. A noise reduction method for chaotic systems. Physics letters A. 1990;148(8-9):421-8.

18- Davies M. Noise reduction schemes for chaotic time series. Physica D: Nonlinear Phenomena. 1994;79(2-4):174-92.

19- Marteau PF, Abarbanel HD. Noise reduction in chaotic time series using scaled probabilistic methods. Journal of Nonlinear Science. 1991 Sep;1:313-43.

20- Pikovsky A. Discrete-time dynamic noise filtering. Sov J Commun Technol Electron. 1986;31:81.

21- Landa PS, Rozenblum MG. A comparison of methods for constructing a phase space and determining the dimension of an attractor from experimental data. Sov. Phys.-Tech. Phys. 1989;34:1229-32.

22- Kostelich EJ, Yorke JA. Noise reduction: Finding the simplest dynamical system consistent with the data. Physica D: Nonlinear Phenomena. 1990;41(2):183-96.

23- Cawley R, Hsu G-H. Local-geometric-projection method for noise reduction in chaotic maps and flows. Physical review A. 1992;46(6):3057.

۵- جمع‌بندی

با توجه به نتایج ارائه شده، به‌کارگیری مدل پیش‌بینی جامع به کمک شبکه عصبی و همچنین استفاده از تحلیل طیف منفرد به منظور بهبود روش کاهش نویز شریبر-گرسبرگر، می‌تواند به میزان قابل توجهی سبب بهبود عملکرد این روش گردد. در تحقیق حاضر با رعایت این موارد در روش کاهش نویز شریبر-گرسبرگر و ارائه روشی بهبود یافته، اقدام به کاهش نویز از سری زمانی برگرفته از معادلات لورنز که با ۵ درصد نویز گاوسی آلوده شده بود، گردید. نتایج کاهش ۳۳ درصدی مقدار خطای مطلق میانگین هنگام استفاده از روش بهبود یافته را نشان می‌دهند. همچنین با استفاده از سری زمانی منتج شده پس از اعمال روش کاهش نویز بهبود یافته، مقدار بُعد همبستگی با دقت کمتر از ۲ درصد قابل محاسبه می‌باشد. از طرفی دیگر به دلیل دقت بالای مدل پیش‌بینی جامع ارائه شده به کمک شبکه عصبی در پیش‌بینی سری زمانی بدون نویز یا با نویز بسیار کم، این امکان فراهم آمده است که بدون داشتن هرگونه اطلاع قبلی از میزان نویز و بدون نگرانی از مخدوش شدن اطلاعات بتوان روش بهبود یافته را به سری‌های زمانی برگرفته از کارهای آزمایشگاهی اعمال نمود. همچنین با بهره‌گیری از روش بازسازی تحلیل طیف منفرد در فرآیند کاهش نویز، می‌توان به هموار نمودن سری زمانی نویزدار و در نتیجه مشخص شدن هرچه بیشتر شکل کلی فضای حالت کمک شایانی نمود.

تأییدیه اخلاقی: محتویات علمی این مقاله حاصل پژوهش نویسندگان است و در هیچ نشریه ایرانی و غیر ایرانی منتشر نشده است.

تعارض منافع: در این مقاله هیچگونه تعارض منافی برای اظهار وجود ندارد.

منابع

- 1- Fan G, Li J, Hao H. Vibration signal denoising for structural health monitoring by residual convolutional neural networks. Measurement. 2020;157:107651.
- 2- Ravizza G, Ferrari R, Rizzi E, Dertimanis V. On the denoising of structural vibration response records from low-cost sensors: A critical comparison and assessment. Journal of Civil Structural Health Monitoring. 2021;11(5):1201-24.
- 3- Wang X, Chakraborty J, Niederleithinger E. Noise reduction for improvement of ultrasonic monitoring using coda wave interferometry on a real bridge. Journal of Nondestructive Evaluation. 2021;40(1):14.
- 4- Kullaa J. Robust damage detection in the time domain using Bayesian virtual sensing with noise reduction and environmental effect elimination capabilities. Journal of Sound and Vibration. 2020;473:115232.
- 5- Zhang Z, Ye Y, Luo B, Chen G, Wu M. Investigation of microseismic signal denoising using an improved

- 41- Ouyang T, Huang H, He Y, Tang Z. Chaotic wind power time series prediction via switching data-driven modes. *Renewable Energy*. 2020 Jan 1;145:270-81.
- 42- Sun W, Chen H, Liu F, Wang Y. Point and interval prediction of crude oil futures prices based on chaos theory and multiobjective slime mold algorithm. *Annals of Operations Research*. 2022 Jun 21:1-31.
- 43- Burden F, Winkler D. Bayesian regularization of neural networks. *Artificial neural networks: methods and applications*. 2009:23-42.
- 44- Feng Q, Li Y. Denoising deep learning network based on singular spectrum analysis—DAS seismic data denoising with multichannel SVDDCNN. *IEEE Transactions on Geoscience and Remote Sensing*. 2021 Apr 23;60:1-1.
- 45- Zheng YB, Huang TZ, Zhao XL, Jiang TX, Ma TH, Ji TY. Mixed noise removal in hyperspectral image via low-fibered-rank regularization. *IEEE Transactions on Geoscience and Remote Sensing*. 2019 Oct 1;58(1):734-49.
- 46- Lorenz EN. Deterministic nonperiodic flow. *Journal of atmospheric sciences*. 1963 Mar;20(2):130-41.
- 47- Theiler J. Efficient algorithm for estimating the correlation dimension from a set of discrete points. *Physical review A*. 1987 Nov 1;36(9):4456.
- 48- Grassberger P, Procaccia I. Measuring the strangeness of strange attractors. *Physica D: nonlinear phenomena*. 1983 Oct 1;9(1-2):189-208.
- 49- Carrassi A, Bocquet M, Demaeyer J, Grudzien C, Raanes P, Vannitsem S. Data assimilation for chaotic dynamics. *Data Assimilation for Atmospheric, Oceanic and Hydrologic Applications (Vol. IV)*. 2022:1-42.
- 24- Sauer T. A noise reduction method for signals from nonlinear systems. *Physica D: Nonlinear Phenomena*. 1992;58(1-4):193-201.
- 25- Davies M. Noise reduction by gradient descent. *International Journal of Bifurcation and Chaos*. 1993 Feb;3(01):113-8.
- 26- Robins V, Abernethy J, Rooney N, Bradley E. Topology and intelligent data analysis. *Intelligent Data Analysis*. 2004 Jan 1;8(5):505-15.
- 27- Robins V, Rooney N, Bradley E. Topology-based signal separation. *Chaos: An Interdisciplinary Journal of Nonlinear Science*. 2004 Jun 19;14(2):305-16.
- 28- Alexander Z, Bradley E, Garland J, Meiss J. Iterated Function System Models in Data Analysis: Detection and Separation; CU-CS-1087-11.
- 29- Wang WB, Zhang XD, Chang Y, Wang XL, Wang Z, Chen X, Zheng L. Denoising of chaotic signal using independent component analysis and empirical mode decomposition with circulate translating. *Chinese Physics B*. 2015 Dec 7;25(1):010202.
- 30- Wang M, Zhou Z, Li Z, Zeng Y. An adaptive denoising algorithm for chaotic signals based on improved empirical mode decomposition. *Circuits, Systems, and Signal Processing*. 2019 Jun 15;38:2471-88.
- 31- Tang G, Yan X, Wang X. Chaotic signal denoising based on adaptive smoothing multiscale morphological filtering. *Complexity*. 2020 Feb 17;2020:1-4.
- 32- Nichols JM, Trickey ST, Todd MD, Virgin LN. Structural health monitoring through chaotic interrogation. *Meccanica*. 2003 Mar;38:239-50.
- 33- Takens F. Detecting strange attractors in turbulence. In *Dynamical Systems and Turbulence, Warwick 1980: proceedings of a symposium held at the University of Warwick 1979/80* 2006 Oct 7 (pp. 366-381). Berlin, Heidelberg: Springer Berlin Heidelberg.
- 34- Kostelich EJ, Schreiber T. Noise reduction in chaotic time-series data: A survey of common methods. *Physical Review E*. 1993 Sep 1;48(3):1752.
- 35- Fraser AM, Swinney HL. Independent coordinates for strange attractors from mutual information. *Physical review A*. 1986 Feb 1;33(2):1134.
- 36- Broomhead DS, King GP. Extracting qualitative dynamics from experimental data. *Physica D: Nonlinear Phenomena*. 1986 Jun 1;20(2-3):217-36.
- 37- Vautard R, Yiou P, Ghil M. Singular-spectrum analysis: A toolkit for short, noisy chaotic signals. *Physica D: Nonlinear Phenomena*. 1992 Sep 15;58(1-4):95-126.
- 38- Karunasinghe DS, Liong SY. Chaotic time series prediction with a global model: Artificial neural network. *Journal of Hydrology*. 2006 May 30;323(1-4):92-105.
- 39- Han M, Zhong K, Qiu T, Han B. Interval type-2 fuzzy neural networks for chaotic time series prediction: A concise overview. *IEEE transactions on cybernetics*. 2018 May 28;49(7):2720-31.
- 40- Fan H, Jiang J, Zhang C, Wang X, Lai YC. Long-term prediction of chaotic systems with machine learning. *Physical Review Research*. 2020 Mar 30;2(1):012080.