پیش‌بینی سری زمانی آشوبی با استفاده از ترکیب نتایج پیش‌بینی کننده خطی و شبکه عصبی غیرخطیNARX

مرضیه نحاسی[1]، مهدی کماندار[2]

[1]فارغ التحصیل ارشد رشته مهندسی فناوری اطلاعات و مدرس در دانشگاه فنی‌حرفه ای (دختران بیرجند) وعلمی کاربردی (جهاد دانشگاهی بیرجند و مرکز بیرجند)nohasimarzie@yahoo.com

[2] مدیر گروه رشته کامپیوتر، دانشگاه تحصیلات تکمیلی صنعتی کرمانm.kamandar@kgut.ac.ir

چکیده: در این مقاله پیش‌بینی سری زمانی آشوبی و تحلیل باقیمانده با استفاده از شبکه‌های عصبی خطی و غیرخطی همراه با تئوری تعبیه انجام گرفته است. از تئوری تعبیه جهت بازسازی سری‌های زمانی به نقاط فضای حالت مناسب استفاده شده است. نقاط فضای حالت به یک شبکه عصبی خطی داده شده و سپس باقیمانده‌ی حاصل از سری زمانی پیش‌بینی شده، به صورت یک سری زمانی جدید در نظر گرفته شده و در فضای حالت مناسب بازسازی شده‌است. در ادامه نقاط فضای حالت بدست آمده به یک شبکه عصبی بازگشتی ***NARX*** خورانده شده تا مورد تحلیل قرار گیرند. در نهایت مقادیر پیش‌بینی شده از سری زمانی اصلی و سری زمانی باقیمانده با هم جمع شده و با مقادیر واقعی سری زمانی مقایسه شده‌اند. برای ارزیابی روش پیشنهاد شده، روش برای معادلات مکی‌گلاس و لورنز که سری‌های زمانی آشوبی تولید می‌کنند و همچنین برای سری زمانی زمان واقعی لکه‌های خورشیدی اجرا شده است. نتایج به دست آمده نشان می دهد که روش پیشنهادی در مقایسه با روش‌های پیش‌بینی موجود می‌تواند به طور موثرتری سری‌های زمانی آشوبی را پیش‌بینی کند.

کلمات کلیدی– پیش‌بینی، تئوری بازسازی، تحلیل باقیمانده، سری‌های زمانی آشوبی، ، شبکه‌های عصبی

مقدمه

پیش‌بینی سری‌های زمانی آشوبی به‌طور گسترده در اقتصاد، پردازش سیگنال، کنترل خودکار و دیگر زمینه‌ها بکار می‌آید [1]، در طول چند دهه گذشته، پیش‌بینی سری‌های زمانی آشوبی یک موضوع چالش‌برانگیز و جالب بوده است. اگرچه سری‌های زمانی آشوب ویژگی‌های سیستم‌های دینامیکی را به‌صورت تصادفی نشان می‌دهند، در فضای حالت آن، رفتارهای قطعی را ارائه می‌دهند. تئوری آشوب به‌عنوان یک بخش اساسی تئوری غیرخطی، یک ابزار مناسب برای نشان دادن ویژگی‌های سیستم‌های دینامیکی و پیش‌بینی روند سیستم‌های پیچیده فراهم کرده است [2].

تئوری تعبیه تاکنز عنصر ضروری تحلیل سری‌های زمانی آشوب است. تاکنز بیان می‌کند که اگر سری زمانی از یک سیستم دینامیکی معین به‌دست‌آمده باشد آنگاه بازسازی فضای حالت این سیستم به کمک یک اسکالر D با نام بُعد محاط و یک اسکالر τ با نام زمان تأخیر امکان‌پذیر می‌باشد [3]. در واقع یک مجموعه مشاهدات از یک سیستم آشوب می‌تواند به یک سری بردارهای n-بُعدی با دو پارامتر D و τ بازسازی شود. مبتنی بر تئوری تاکنز، اگر بُعد به‌اندازه کافی بزرگ باشد، بردار بازسازی تعداد زیادی از نهادهای مهم سری زمانی را نشان خواهد داد [2].

در بین تکنیک‌های هوش محاسباتی شبکه‌های عصبی مصنوعی به‌طور مستقل یا به‌عنوان ابزار کمکی برای پیش‌بینی سری‌های زمانی آشوب بکار گرفته شده‌اند. کارایی و اثربخشی انواع شبکه‌های عصبی ازجمله پیش‌خور چندلایه، بازگشتی و... در پژوهش‌های مختلف بررسی و تشریح شده است. ازجمله در کار تحقیقاتی صورت گرفته توسط [4] مقایسه تجربی بین معماری شبکه عصبی پیش‌خور و چند معماری شبکه بازگشتی (شبکه المان، جردن و شبکه المان توسعه‌یافته)، براساس دقت

پیش‌بینی، زمان آموزش موردنیاز و پایداری انجام گرفته است. فروغ مرزبان و همکارانش [5] پژوهشی در زمینه پیش‌بینی سری‌های زمانی آشوب‌گونه با استفاده از شبکه‌های عصبی مصنوعی دینامیک زمان گسسته انجام داده‌اند. به‌طور تجربی نشان داده شده است که معماری اصلی شبکه‌های

اتورگرسیو غیرخطی با ورودی برون‌زاد -NARX[1] که حلقه‌ای از خروجی‌های تأخیری تولید شده دارد، می‌تواند برای پیش‌بینی بلندمدت سری‌های زمانی تک متغیره به‌طور کارایی استفاده شود [6]. سهم تجزیه‌وتحلیل باقیمانده همراه با ترکیب شبکه‌های عصبی المان و NARX برای افزایش کارایی روش‌های پیش‌بینی بررسی شده است [2]. کاربرد دو روش تجزیه مسئله با شبکه‌های عصبی بازگشتی برای مسئله پیش‌بینی سری‌های زمانی مکی- گلاس، لورنز و لکه‌های خورشیدی توسط [7] ارائه شده است.

همچنین پژوهش‌های مختلفی در جهت ارائه مدل‌هایی از ترکیب روش‌های مختلف هوش محاسباتی به‌منظور پیش‌بینی سری‌های زمانی آشوبی انجام گرفته است، در زیر می‌توان اشاره‌ای به این موارد داشت. یک رویه بهینه‌سازی برای مدل شبکه پس انتشار - BPN[2] مبتنی بر الگوریتم ژنتیک، به‌منظور پیش‌بینی سری‌های زمانی آشوبی پیشنهاد شده است [8]. در پژوهشی دیگر یک مدل شبکه عصبی مصنوعی با الگوریتم ترکیبی، پیشنهاد داده‌اند. این مدل مبتنی بر شبکه عصبی المان بوده و از الگوریتم بهبودیافته‌ی ترکیب بهینه‌سازی ازدحام ذرات با ایده فرآیند تبرید شبیه‌سازی شد به‌جای الگوریتم استاندارد پس انتشار استفاده کرده است [1].

در روش‌های پیش‌بینی تحلیل باقی‌مانده کمتر موردتوجه بوده است. خطاهای پیش‌بینی به علت تصادفی بودن نیستند بلکه همبستگی بالای باقیمانده‌ها را نشان می‌دهند و همچنین در مواردی باقیمانده‌ها ویژگی‌های سیستم اصلی را به ارث می‌برند. در این پژوهش همراه با مدل پیش‌بینی از تحلیل باقیمانده به‌منظور افزایش کارایی مدل بهره خواهیم گرفت. با استفاده از تئوری تاکنز نقاط فضای حالت سری زمانی را بازسازی می‌کنیم. با توجه به این‌که سری‌های زمانی به‌طورکلی شامل مؤلفه‌های خطی و غیرخطی می‌باشند [9]. ارائه روش‌های ترکیبی که بتواند هر دو مؤلفه را مدل کند در جهت بهبود کارایی مدل پیش‌بینی مفید خواهد بود. در این مطالعه شبکه عصبی خطی و شبکه عصبی بازگشتی NARX را برای پیش‌بینی بکار گرفته‌ایم. ادامه مقاله به شرح زیر است: بخش 2 سری‌های زمانی آشوب و روش بازسازی آن‌ها در فضای حالت و خلاصه‌ای از شبکه‌های عصبی مصنوعی را بحث می‌کند. بخش 3 روش پیش‌بینی پیشنهاد شده با جزئیات بیان می‌شود و کارایی روش پیشنهادی روی سه سری زمانی آشوبی شناخته‌شده‌ی مکی‌گلاس، لورنز و لکه‌های خورشیدی مورد بررسی قرار گرفته است. نتیجه‌گیری در بخش 4 ارائه شده است.

بازسازی سری زمانی آشوبی و شبکه‌های عصبی مصنوعی

تعداد زیادی سیستم‌های طبیعی رفتار آشوب‌گونه یا غیرخطی را نشان می‌دهند. تحلیل سری‌های زمانی آشوب‌گونه سه فاز اصلی دارد: 1) بررسی ویژگی‌های سیستم 2) تشخیص پارامترهای فضای حالت برای بازسازی 3) پیش‌بینی سری زمانی [10]. در تجزیه‌وتحلیل سری‌های زمانی، یک گام مهم تعیین ویژگی‌های داده است. روش‌های زیادی برای فرق گذاشتن بین داده‌های تصادفی یا دوره‌ای از داده آشوبی استفاده شده است. تبدیل فوریه، توان لیاپونف، توان هرست، بُعد فراکتال ازجمله روش‌های تشخیص آشوب در سری‌های زمانی هستند [2].

تئوری تعبیه تاکنز عنصر ضروری تحلیل سری‌های زمانی آشوب است. تاکنز بیان می‌کند که اگر سری زمانی از یک سیستم دینامیکی معین به‌دست‌آمده باشد آنگاه بازسازی فضای حالت این سیستم به کمک یک اسکالر D با نام بُعد محاط و یک اسکالر τ با نام زمان تأخیر امکان‌پذیر می‌باشد [3]. یکی از روش‌های مرسوم برای پیداکردن بُعد محاط بهینه سری‌های زمانی آشوبی، روش شمارش نزدیک‌ترین همسایه‌های کاذب می‌باشد [11]. برای انتخاب زمان تأخیر مناسب τ، کمترین وابستگی بین عناصر نزدیک به هم در نقاط فضای فاز باید فراهم شود؛ بنابراین اولین کمترین تابع اطلاعات دوطرفه می‌تواند انتخاب شده باشد [12]. سپس سری زمانی می‌تواند در فضای چندبُعدی به‌وسیله رسم نقاط داده Y(t) به‌صورت معادله (1)، تعبیه می‌شود: که N طول سری زمانی اصلی، D بُعد تعبیه سری زمانی و T زمان تأخیر و t=0,1,2,…,N-DT-1 است.

$$Y(t) = [x(t), x(t-T), \dots, x(t-(D-1)T)] \quad (1)$$

[1] Nonlinear AutoRegressive with eXogenous input
[2] Back-propagation network

می‌توان گفت که یک شبکه عصبی مصنوعی ایده‌ای است برای پردازش اطلاعات که از سیستم عصبی زیستی الهام گرفته شده و مانند مغز به پردازش اطلاعات می‌پردازد.

شبکه‌های عصبی را می‌توان به دودسته ایستا و پویا تقسیم‌بندی نمود. شبکه‌های عصبی فاقد اجزای پسخوردی و تأخیری می‌باشند و خروجی آن‌ها مستقیماً از طریق اتصالات روبه‌جلو شبکه تعیین می‌شود. در شبکه‌های پویا خروجی شبکه علاوه بر ورودی فعلی آن، به ورودی‌ها و خروجی‌های قبل و حالت شبکه نیز بستگی دارد [13]. عموماً شبکه‌های پویا دارای قدرت و کارایی بیشتری نسبت به شبکه‌های ایستا می‌باشند (البته آموزش آن‌ها نیز پیچیده‌تر و دشوارتر می‌باشد). ازآنجاکه شبکه‌های پویا دارای حافظه هستند از آن‌ها می‌توان برای فراگیری الگوهای ترتیبی و متغیر در زمان استفاده نمود. ازجمله‌ی این کاربردها می‌توان به پیش‌بینی‌های مالی، تسهسم کانال‌ها در سیستم ارتباطی، تشخیص فاز در سیستم‌های فشارقوی، مرتب‌سازی، تشخیص خطا، تشخیص گفتار و حتی پیش‌گویی ساختار پروتئین در علم ژنتیک اشاره کرد.

در ادامه به‌طور خلاصه دو شبکه عصبی خطی وNARX را معرفی خواهیم کرد. شبکه‌های خطی کاملاً شبیه به شبکه‌های پرسپترون می‌باشند با این تفاوت که علاوه بر صفر و یک می‌توانند هر مقدار دیگری را به‌عنوان خروجی تولید نمایند زیرا در این شبکه‌ها از یک تابع خطی در تابع انتقال استفاده شده است. شبکه‌های عصبی NARX، متعلق به معماری شبکه‌های عصبی پویای بازگشتی هستند. در شبکه‌های NARX خروجی بر مبنای خروجی‌های مراحل قبل و مقادیر مستقل سیگنال ورودی خارجی می‌باشد. این شبکه دارای کاربردهای زیادی می‌باشد. از این نوع شبکه می‌توان به‌عنوان پیشگو در راستای پیشگویی مقدار بعدی سیگنال ورودی استفاده نمود و یک کاربرد مهم این شبکه‌ها در مدل‌سازی سیستم‌های پویا غیرخطی می‌باشد [13].

مدل پیش‌بینی

با توجه به این‌که سری‌های زمانی به‌طورکلی شامل مؤلفه‌های خطی و غیرخطی می‌باشند [9]. ارائه روش‌های ترکیبی که بتواند هر دو مؤلفه را مدل کند در جهت بهبود کارایی مدل پیش‌بینی مفید خواهد بود. پس از تشخیص حضور آشوب، پارامترهای فضای حالت یعنی بُعد تعبیه و زمان تاخیر تعیین می‌شوند. با استفاده از مقادیر این پارامترها که به‌طورکلی D برای بُعد تعبیه و T برای زمان تأخیر در نظر گرفته شده است، تعداد [N-(D-1)T]از نقاط فضای فاز به‌صورت معادلات (2) تولید می‌شوند:

$$y(j), \quad j = 1 \sim [N-(D-1)T \quad (2)$$

$$Y(1)= [\, x(1), x(1+T), \ldots, x(1+(D-1)]$$
$$Y(2)= [\, x(2), x(2+T), \ldots, x(2+(D-1)]$$
$$\vdots$$
$$Y(j)=[x(N-(D-1)T), x(N-(D-1)T+T), \ldots, x(N)]$$

یک لایه عصبی خطی ایجاد و با D واحد ورودی و D واحد خروجی با استفاده از نقاط فضای حالت تولیدشده‌ی y(j), j=1~[N-(D-1)T-1] به‌عنوان ورودی و y(k), k=2~[N-(D-1)T] به‌عنوان خروجی آموزش داده می‌شود. ورودی و خروجی شبکه به‌وسیله معادلات (3) و (4) مشخص‌شده‌اند.

$$\begin{bmatrix} Y(1) \\ Y(2) \\ \vdots \\ Y(N-(D-1)T-1 \end{bmatrix} \quad (3)$$

$$\begin{bmatrix} Y(2) \\ Y(3) \\ \vdots \\ Y(N-(D-1)T \end{bmatrix} \quad (4)$$

در این مرحله به‌نوعی علاوه بر جداسازی بخش خطی از غیرخطی، یک پیش‌بینی خطی از مقادیر آینده نقاط فضای حالت به دست می‌آید. پس از کامل شدن آموزش، مقادیر باقیمانده را به دست می‌آوریم.

به‌منظور بررسی سهم تحلیل باقیمانده‌ها در بهبود کارایی و دقت روش پیش‌بینی پیشنهاد شده، باقیمانده‌های به‌دست‌آمده را به‌عنوان یک سری زمانی آشوبی جدید با طول $N_1=N-(D-1)T-1$ در نظر گرفته و مشابه مرحله قبل نقاط فضای حالت را با توجه به مقادیر D_1 و T_1 تولید می‌کنیم. یک شبکه NARX موازی جدید با D_1 واحد ورودی و D_1 واحد خروجی ایجاد می‌کنیم. این شبکه عصبی به‌خوبی قابلیت پیش‌بینی مقادیر غیرخطی باقیمانده از سری زمانی را دارد. زمانی که آموزش کامل شد مقادیر پیش‌بینی به‌دست‌آمده از این شبکه را به ازای داده آموزشی بدست می‌آوریم. طول سری زمانی پیش‌بینی باقیمانده‌ها $N_1-(D_1-1)T_1-1$ است، بنابراین آخرین $N_1-(D_1-1)T_1-1$ داده از پیش‌بینی سری زمانی اصلی و مقادیر واقعی سری زمانی انتخاب می‌شوند.

سری زمانی پیش‌بینی باقیمانده را با مقادیر پیش‌بینی سری زمانی اصلی جمع می‌کنیم. مجموع حاصل را در قیاس با مقادیر اصلی قرار می‌دهیم.

شبیه‌سازی و ارزیابی روش پیشنهادی

به‌منظور ارزیابی، روش پیشنهادی روی سه سری زمانی آشوبی شناخته‌شده‌ی مکی‌گلاس، لورنز و لکه‌های خورشیدی اعمال

شده و کارایی آن را با نتایج گزارش شده در سایر پژوهش‌ها برای این مجموعه داده‌ها مقایسه کرده‌ایم.

معادله مکی‌گلاس: مکی‌گلاس در پژوهش‌ها به علت ویژگی‌های آشوب‌گونه‌اش به‌عنوان مدل محک استفاده می‌شود. معادله دیفرانسیل که منجر به سری زمانی می‌شود در معادله (5) مشخص شده است:

$$\frac{dx}{dt} = \frac{ax(t-\tau)}{[1+x^c(t-\tau)} - bx(t) \quad (5)$$

در معادله مکی گلاس، پارامتر تأخیر τ، ویژگی‌های معادله را تعیین می‌کند. به این معنی که $\tau < 4.43$ یک جذب‌کننده* نقطه ثابت، $4.43 < \tau < 13.3$ یک جذب‌کننده چرخه‌ای ثابت، $13.3 < \tau < 16.8$ یک جذب‌کننده چرخه‌ای حد دوبل و $\tau >$ 16.8 آشوب را تولید می‌کند. پارامترها بر طبق گزارش‌های قبلی توسط [14] انتخاب شده‌اند که مقادیر ثابت b=0.1، a=0.2 و c=10 می‌باشند. یک مجموعه نمونه سری زمانی آشوبی با طول 1000 داده تولید شده توسط معادله مذکور استفاده شده است 500 نمونه اول برای آموزش و 500 نمونه بعدی برای تست انتخاب شده‌اند. سری زمانی با بُعد تعبیه D=3 و زمان تأخیر T=2 در فضای حالت بازسازی شده است. نقاط به‌دست‌آمده به لایه عصبی خطی با D واحد ورودی داده شده است. مقادیر پیش‌بینی شده با مقدار داده واقعی مقایسه شده و باقیمانده‌ها محاسبه شده‌اند. 485 نمونه باقیمانده با بُعد تعبیه D_1=3 و زمان تأخیر T_1=2 در فضای حالت بازسازی شده‌اند. نقاط فضای حالت به یک شبکه عصبی بازگشتی NARX موازی با 7 نرون در لایه پنهان داده شده و پس از کامل شدن آموزش خروجی حاصل با مقادیر پیش‌بینی به‌دست‌آمده از مرحله قبل جمع می‌شوند.

جهت ارزیابی با نتایج گزارش شده از سایر پژوهش‌ها خطای مجذور میانگین، خطای مجذور میانگین ریشه، بر طبق معادلات (6) و (7) محاسبه شده‌اند.

$$\text{MSE} = \frac{1}{\text{N}}\sum_{\text{i=1}}^{\text{N}}(\text{y}_\text{i} - \hat{y}_i)^2 \quad (6)$$

$$RMSE = \sqrt{\frac{1}{N}\sum_{\text{i=1}}^{\text{N}}(\text{y}_\text{i} - \hat{y}_i)^2} \quad (7)$$

که y_i و $\hat{y}_i$ به ترتیب داده مشاهده شده، داده پیش‌بینی شده و N طول داده مشاهده شده است. برای 500 نمونه داده سری زمانی آشوبی مکی‌گلاس با نتایج گزارش شده در ادبیات مقایسه شده و در جدول 1 ارائه شده‌اند. آزمایش‌های انجام شده برای سری زمانی مکی-گلاس، تائید می‌کند که کارایی روش پیشنهاد شده قابل قیاس با روش‌های ارائه شده در پژوهش‌ها است.

جدول 1: مقایسه خطای پیش‌بینی در دیگر پژوهش‌ها و روش پیشنهاد شده از سری زمانی مکی‌گلاس

روش پیش‌بینی	منبع	خطای پیش‌بینی	
		MSE	RMSE
تحلیل باقیمانده و ترکیب شبکه عصبی المان- NARX	محمود اردلانی فرسا، 2010، [2]	1.3855e-9	3.7222e-5
الگوریتم ترکیبی با شبکه عصبی المان	زین، 2010، [1]	--	0.0160
ترکیب شبکه عصبی BPN با الگوریتم ژنتیک	ونگ و هانگ، 2007، [8]	--	0.0155394
تجزیه مسئله با شبکه‌های عصبی بازگشتی	ژانگ، 2012، [7]	--	6.3e-4
روش پیشنهاد شده	---	**7.4053e-6**	**2.7e-3**

معادله لورنز: یک مثال سیستم‌های آشوب، آب و هواست. کارهای لورنز به‌طور گسترده برای استقرار تئوری آشوب است. معادلات لورنز به‌صورت معادله (8) نوشته می‌شوند:

$$\frac{dx(t)}{dt} = \sigma[y(t) - \text{x(t)}] \quad (8)$$
$$\frac{dy(t)}{dt} = \text{x(t)}[\text{r} - \text{z(t)}] - \text{y(t)}$$
$$\frac{\text{Dz(t)}}{\text{dt}} = \text{x(t)y(t)} - \text{bz(t)}$$

که σ،r، b پارامترهای بعدی و مقادیر عمومی برای این پارامترها b=8/3، r=28 و $\sigma = 10$هستند [15].

یک مجموعه نمونه سری زمانی آشوبی با طول 2500 داده تولید شده با 1500 نمونه اول برای آموزش و 1000 نمونه بعدی برای تست توسط معادله مذکور استفاده شده است. نقاط فضای حالت با پارامترهای D=3 و T= به لایه عصبی خطی با D واحد ورودی داده شده است. 993 نقطه فضای حالت باقیمانده‌ها با D_1=3 و T_1=1 به یک شبکه عصبی بازگشتی NARX موازی با مشخصاتی که در بالا گذشت، داده شده و پس از کامل شدن آموزش خروجی حاصل با مقادیر پیش‌بینی به‌دست‌آمده از مرحله قبل جمع شده و با مقادیر اصلی مقایسه می‌شوند. مقایسه کارایی روش پیشنهادی را با نتایج گزارش شده در ادبیات در جدول 2 ارائه شده است.

جدول 2: مقایسه خطای پیش‌بینی در دیگر پژوهش‌ها و روش پیشنهاد شده از سری زمانی لورنز

روش پیش‌بینی		خطای پیش‌بینی	
		MSE	RMSE
تحلیل باقیمانده و ترکیب شبکه عصبی المان-NARX	محمود اردلانی فرسا، 2010، [2]	1.1731e-8	1.0831e-4
تجزیه مسئله با شبکه‌های عصبی بازگشتی	ژانگ، 2012، [7]	--	2.2e-2
سیستم ترکیبی موجک- عصبی- فازی انطباقی	بدونسکای، 2013، [17]	--	0.189
روش پیشنهاد شده	---	**1.7462e-7**	**4.1788e-4**

لکه‌های خورشیدی: پیش‌بینی فعالیت‌های خورشیدی موضوعی چالش‌برانگیز و مهم برای محققان مختلف و علاقه‌مند است [16]. سری‌های زمانی هموارشده ماهیانه لکه‌های خورشیدی از SIDC به‌دست‌آمده است. برای مقایسه با تعدادی از کارهای تحقیقاتی منتشر شده در پژوهش‌ها، داده در شرایط مشابه انتخاب شده است. سری لکه‌های خورشیدی از نوامبر 1834 تا ژوئن 2001 (2000 نقطه) انتخاب شده و در بازه [0,1] نرمال شده‌اند.1000 نمونه به‌عنوان داده آموزشی و 1000 نمونه دیگر برای تست مدل پیش‌بینی انتخاب شده‌اند. پارامترهای فضای حالت برای سری زمانی اصلی D=5 و T=1 و برای 995 نمونه باقیمانده D1=5 و T1=1 تعیین شده‌اند. مقایسه کارایی روش پیشنهادی را با نتایج گزارش شده در ادبیات در جدول 3 ارائه شده است.

نتیجه‌گیری

در این مطالعه یک روش پیش‌بینی جدید با استفاده از ترکیب تئوری بازسازی و تحلیل باقیمانده و ترکیب شبکه‌های عصبی خطی و NARX موازی برای پیش‌بینی سری‌های زمانی آشوبی توسعه داده شده است. همان‌طور که مشاهده شد روش پیشنهادی معتبر بوده و کارایی آن قابل قیاس با روش‌های پیشنهاد شده در گذشته است. در این مطالعه پارامترهای فضای حالت براساس بهترین گزینه‌ها در پژوهش‌های گذشته و سعی خطا تعیین شده بود، به‌عنوان پیشنهادی برای کارهای آینده می‌توان این مقادیر می‌تواند از روش‌های معتبر دیگری تعیین شود. همچنین با توجه به اثربخشی مدل می‌توان آن را برای دیگر سری‌های زمانی زمان واقعی نیز مورد آزمایش قرار داد.

جدول 3. مقایسه خطای پیش‌بینی در دیگر پژوهش‌ها و روش پیشنهاد شده از سری زمانی لکه‌های خورشیدی

روش پیش‌بینی	منبع	خطای پیش‌بینی	
		MSE	RMSE
تحلیل باقیمانده و ترکیب شبکه عصبی المان-NARX	محمود اردلانی فرسا، 2010. [2]	1.4078e-4	0.0119
ترکیب PCA و شبکه عصبی	ونگ و هانگ، 2007. [8]	---	13.66
تجزیه مسئله با شبکه‌های عصبی بازگشتی	ژانگ، 2012. [7]	---	2.17e-2
روش پیشنهاد شده	----	**6.1489e-6**	**2.5e-3**

5. مراجع

[1] Y. Xin, Z. Ye, Y.-G. He, and Z. Hai-xia, "Prediction of chaotic time series of neural network and an improved algorithm," in Bio-Inspired Computing: Theories and Applications (BIC-TA), 2010 IEEE Fifth International Conference on, pp. 1282-1286, 2010.

[2] M. Ardalani-Farsa and S. Zolfaghari, "Chaotic time series prediction with residual analysis method using hybrid Elman–NARX neural networks," Neurocomputing, vol. 73, pp. 2540-2553, 2010.

[3] پری‌زنگنه م. و عطایی م. و معلم پ.، «بازسازی فضای حالت سری‌های زمانی آشوبی با استفاده از یک روش هوشمند»، نشریه الکترونیک و قدرت دانشکده مهندسی برق، شماره 2، 1388.

[4] J. Mandziuk and R. Mikolajczak, "Chaotic time series prediction with feed-forward and recurrent neural nets," Control and Cybernetics, vol. 31, pp. 383-406, 2002.

[5] مرزبان ف.، بی‌باک م.، تشنه‌لب م.،« شناسایی و پیش‌بینی سیستم‌های آشوب با استفاده از شبکه‌های عصبی دینامیک زمان گسسته»، چهارمین کنفرانس داده‌کاوی ایران، دانشگاه صنعتی شریف، تهران، ایران، 1389.

[6] J . M. P. Menezes Jr and G. A. Barreto, "Long-term time series prediction with the NARX network: An empirical evaluation," Neurocomputing, vol. 71, pp. 3335-3343, 2008.

[7] R. Chandra and M. Zhang, "Cooperative coevolution of Elman recurrent neural networks for chaotic time series prediction," Neurocomputing, vol. 86, pp. 116-123, 2012.

[8] T.-Y. Wang and C.-Y. Huang, "Applying optimized BPN to a chaotic time series problem," *Expert Systems with Applications,* vol. 32, pp. 193-200, 2007.

[9] Ufuk Yolcu, E. E .“ A new linear & nonlinear artificial neural network model for time series forecasting”,.Decision Support Systems, PP 1340-1347, 2013.

[10] D. S. Karunasinghe and S.-Y. Liong, "Chaotic time series prediction with a global model: Artificial neural network," *Journal of Hydrology,* vol. 323, pp. 92-105, 2006.

[11] M. B. Kennel, R. Brown, and H. D. Abarbanel, "Determining embedding dimension for phase-space reconstruction using a geometrical construction," Physical review A, vol. 45, p. 3403, 1992.

[12] C. Frazier and K. M. Kockelman, "Chaos theory and transportation systems: instructive example," Transportation Research Record: Journal of the Transportation Research Board, vol. 1897, pp. 9-17, 2004.

[13] کیا م.، شـــبکه‌های عصـــبی در MATLAB، ویرایش دوم، انتشارات کیان رایانه،1390.

[14] J. Zhang and K. Man, "Time series prediction using RNN in multi-dimension embedding phase space," in Systems, Man, and Cybernetics, 1998. 1998 IEEE International Conference on, 1998, pp. 1868-1873.

[15] Q.-L. Ma, Q.-L. Zheng, H. Peng, T.-W. Zhong, and L.-Q. Xu, "Chaotic time series prediction based on evolving recurrent neural networks," in Machine Learning and Cybernetics, 2007 International Conference on, 2007, pp. 3496-3500.

[16] Sello, S ., “Solar cycle forecasting: a nonlinear dynamics approach”, Astronomy & Astrophysics PP.312-320, 2001.

[17] Y. Bodyanskiy and O. Vynokurova, "Hybrid adaptive wavelet-neuro-fuzzy system for chaotic time series identification," Information Sciences, vol. 220, pp. 170-179, 2013.