

## پیش‌بینی سرعت باد با شبکه عصبی RBF بر اساس نظریه آشوب

طیبه خانجانی<sup>۱</sup>، محمد عطایی<sup>۲</sup>، پیمان معلم<sup>۳</sup>

۱- دانشجوی کارشنای ارشد، گروه مهندسی برق- دانشکده فنی و مهندسی- دانشگاه اصفهان- اصفهان- ایران

t.khanjani@gmail.com

۲- دانشیار، گروه مهندسی برق- دانشکده فنی و مهندسی - دانشگاه اصفهان- اصفهان- ایران

ataei@eng.ui.ac.ir

۳- استاد، گروه مهندسی برق- دانشکده فنی و مهندسی - دانشگاه اصفهان- اصفهان- ایران

p\_moallem@eng.ui.ac.ir

**چکیده:** پیش‌بینی سرعت باد در مواردی همچون کنترل و برنامه‌ریزی جهت قطع و وصل توربین‌های بادی و تضمین عملکرد پایدار سیستم می‌تواند حائز اهمیت باشد که به‌طور کلاسیک به روش‌های متعددی صورت می‌گیرد. در این مقاله، ارائه روشی صرفاً براساس آنالیز داده‌های اندازه‌گیری شده قبلی مد نظر است. به این منظور، ضمن بررسی آشوبناک بودن داده‌های سرعت باد، با ترکیب مفاهیم مربوط به نظریه آشوب و تکنیک‌های موجود در پیش‌بینی با استفاده از شبکه‌های عصبی، روشی جهت پیش‌بینی سرعت باد پیشنهاد شده است. داده‌های استفاده شده در این تحقیق، اطلاعات ثبت شده در ایستگاه ورزنه استان اصفهان است. در این راستا، ابتدا با استفاده از محاسبه بُعد همبستگی از روی سری زمانی مفروض، آشوبناک بودن دینامیک سیستم مولد این داده‌ها اثبات شده و سپس فضای حالت سیستم دینامیکی مولد بازسازی شده است. بدین منظور از روش  $FNN$  برای محاسبه بعد محاط و از روش  $AMI$  برای محاسبه زمان تأخیر جهت بازسازی فضای حالت استفاده شده است. در ادامه شبکه عصبی  $RBF$  جهت پیش‌بینی سرعت باد پیشنهاد شده است که ساختار آن با استفاده از اطلاعات بعد محاط و زمان تأخیر محاسبه شده طراحی شده است. در پایان، روش پیشنهادی بر روی داده‌های عملی، اعمال و نتایج بیان شده است.

**واژه‌های کلیدی:** آشوب، پیش‌بینی، سرعت باد، سری‌های زمانی، شبکه عصبی  $RBF$

### ۱- مقدمه

تجدیدپذیربودن، پاک‌بودن و البته فراوانی آن، به‌طور گسترده‌ای به‌عنوان یک منبع جایگزین استفاده می‌شود. انجمن انرژی بادی اروپا ( $EWEA^1$ ) میزان برق مصرفی شبکه جهانی در سال ۲۰۳۰ که از طریق انرژی بادی تولید می‌شود را ۲۴,۴٪ پیش‌بینی کرده است. بنا به گزارش  $REN21^2$  این انرژی در سال ۲۰۱۴ نزدیک به ۲۰٪ از کل الکتریسیته تولیدی را به خود اختصاص داده است و انجمن انرژی بادی اروپا ( $EWEA^3$ ) میزان برق مصرفی شبکه جهانی در سال ۲۰۳۰ که از طریق انرژی بادی تولید می‌شود را ۲۴,۴٪ پیش‌بینی کرده است. [۱،۲].

با این وجود، استفاده از انرژی بادی مشکلاتی را در

سوخت‌های فسیلی تأثیرات مخربی روی محیط زیست دارند و علاوه بر این، منابع آن‌ها نیز رو به پایان است. همین امر باعث شده است کشورها به استفاده از انرژی‌های تجدیدپذیر روی بیاورند. انرژی بادی نیز به خاطر

<sup>۱</sup> تاریخ ارسال مقاله: ۱۳۹۲/۱۱/۲۵

تاریخ پذیرش مقاله: ۱۳۹۵/۰۴/۲۳

نام نویسنده مسئول: محمد عطایی

نشانی نویسنده مسئول: ایران - اصفهان - دانشگاه اصفهان - دانشکده فنی و مهندسی

آماري و روش‌های دینامیکی.

در روش‌های آماری سرعت باد به صورت یک پدیده کاملاً تصادفی در نظر گرفته شده است و براساس مدل‌سازی‌ها و روش‌های مختلف و مناسب همچون<sup>۴</sup> ARMA، فیلتر کالمن و ... مقادیر آینده آن را پیش‌بینی می‌کنند. در روش‌های دینامیکی با استفاده از سری زمانی موجود دینامیک فرایند مولد داده‌ها را بررسی و پیش‌بینی می‌کنند.

در این مقاله، ابتدا آشوبی بودن سری زمانی سرعت باد بررسی شده است. بعد از اطمینان درباره آشوبناک بودن رفتار سرعت باد، فضای حالت دینامیک مولد سرعت، بازسازی شده است. سپس از این فضای بازسازی شده جهت پیش‌بینی سرعت باد به کمک شبکه عصبی RBF استفاده شده است. روش پیشنهادی را روی داده‌های موجود برای سرعت باد در منطقه ورزش استان اصفهان پیاده‌سازی شده است و برای بررسی عملکرد شبکه عصبی RBF، فرایند پیش‌بینی با شبکه عصبی MLP نیز انجام شده و نتایج با هم مقایسه شده است.

## ۲- سری‌های زمانی آشوبی

تئوری آشوب، سیستم‌های غیرخطی را در محدوده‌ای بین رفتار نوسانی و رفتار تصادفی مطالعه می‌کند. به طوری که می‌توان گفت سیستم‌های آشوبی آن دسته از پدیده‌هایی هستند که دینامیک معین بسیار پیچیده غیرخطی متغیر با زمان دارند؛ لذا داده‌های حاصل از مشاهدات خروجی‌های این‌گونه پدیده‌ها منجر به تولید سری‌های زمانی آشوبناک می‌شود.

نخستین گام در راستای تجزیه و تحلیل سری‌های زمانی آشوبی، تمییز سری زمانی تصادفی از سری زمانی آشوبی است. بدین منظور از مفاهیمی به نام بعد همبستگی و نمای لیاپانوف برای تشخیص معین یا تصادفی بودن سری زمانی استفاده می‌شود.

### ۲-۱- نمای لیاپانوف

معیار نمای لیاپانوف براساس این ویژگی سری‌های زمانی آشوبی است که نقاط مجاور در این سری‌ها به مرور

عملکرد پایدار و مطمئن شبکه توزیع ایجاد خواهد کرد. این مشکلات ناشی از ماهیت متغیر و نامعلوم سرعت باد است. از این رو، دانستن توان تولیدی در چند ساعت یا روز آینده کمک بسیاری به اپراتورها می‌کند تا بتوانند برنامه‌ریزی مناسبی برای قطع و وصل توربین‌های بادی، مدیریت بار و نگهداری تجهیزات داشته باشند.

بین انرژی بادی P (در زمان واحد) که با سرعت  $v(m/s)$  از یک مقطع با مساحت  $A(m^2)$  می‌گذرد از لحاظ تئوری رابطه (۱) برقرار است:

$$P = \frac{1}{2} \rho A v^3 \quad (1)$$

که در این رابطه  $\rho$  چگالی هوا بر حسب  $(kg/m^3)$  است و به دما و فشار هوا وابسته است؛ بنابراین دقت پیش‌بینی توان باد شدیداً متأثر از دقت پیش‌بینی سرعت باد خواهد بود. به همین دلیل برای پیش‌بینی توان باد تولیدی می‌توان ابتدا سرعت باد را در چند ساعت آینده پیش‌بینی کرد؛ سپس از روی منحنی توان موجود، توان تولیدی را پیش‌بینی کرد. در عمل پیش‌بینی از یک تا شش ساعت برای بهبود عملکرد سیستم‌ها و شبکه‌های توزیع مفید و کارآمد است [۳].

روش‌های پیش‌بینی سرعت باد را می‌توان بسته به اینکه چه پارامترهایی به عنوان ورودی در نظر گرفته می‌شوند به دو دسته تقسیم کرد: دسته اول، روش‌هایی است که از اطلاعات فیزیکی مانند داده‌های هواشناسی (فشار هوا و دما و ...) و زمین‌شناسی (توصیف‌های کوه‌شناسی، صافی زمین) و قوانین دینامیک و ترمودینامیک فیزیکی استفاده می‌کنند. دسته دوم، روش‌هایی است که از مدل‌های ریاضی و متغیرهای توصیفی و داده‌های اندازه‌گیری شده قبلی استفاده می‌کنند و معمولاً با به‌کارگیری تکنیک‌های بازگشتی، مقادیر آینده را برای سرعت باد پیش‌بینی می‌کنند. دسته دوم را می‌توان روش مبتنی بر سری زمانی نیز نامید؛ زیرا که برای مدل‌سازی سرعت باد از سری زمانی سرعت باد استفاده می‌کنند.

هنگامی که تنها مشاهدات اسکالری از یک فرآیند مد نظر را در قالب یک سری زمانی داریم، دو روش عمده برای تجزیه و تحلیل این سری زمانی وجود دارد: روش‌های

$u \geq 0$  و  $H(u)=0$  برای  $u < 0$  است که در این رابطه  $U=R-$  می‌کند. محاسبه نمای لیاپانوف از طریق اندازه‌گیری مقدار کشیدگی یا خمیدگی که در حرکت سیستم رخ می‌دهد، انجام می‌شود. در واقع، در این روش، سرعت متوسطی که مسیرهای انتقالی دو نقطه‌ای که در ابتدا به هم نزدیک بوده‌اند و به‌طور نمایی از یکدیگر منحرف می‌شوند، محاسبه می‌شود. اگر بزرگ‌ترین نمای محاسبه‌شده لیاپانوف مقدار مثبتی داشته باشد، سیستم دارای رفتار آشوبی است. روش محاسبه به‌صورت زیر است [۴]:

$$C(R) = \lim_{R \rightarrow 0} KR^{DC} \quad (6)$$

در این رابطه،  $DC$  بیانگر بعد همبستگی است. گراسبرگر و پروکاکسیا ارزیابی  $C(R)$  را در محدوده‌ای از مقادیر  $R$  پیشنهاد کردند و سپس نتیجه گرفتند که  $DC$  از شیب خط مستقیمی که بر ناحیه خطی از پلات  $LnC(R)$  در مقابل  $Ln(R)$  متناسب شده است، به دست می‌آید. اگر  $DC$  عدد صحیح نباشد، در این حالت، یکی از خصایص مهم سامانه‌های آشوبناک را به‌روز می‌کند.

## ۲-۳- بازسازی فضای حالت

گام بعدی که یکی از اساسی‌ترین گام‌ها در تحلیل سری‌های زمانی آشوبی است، بازسازی فضای حالت معادل با فضای حالت فرایند مولد داده‌ها است. بازسازی فضای حالت بر مبنای نظریه محاط بنا شده است. ساختن یک سیستم دینامیکی معادل با استفاده از تنها یک سری زمانی با روش محاط کردن تأخیری امکان‌پذیر می‌شود. محاط نگاشتی دیفئومورفیک از یک سیستم دینامیکی به سیستم دیگری است که ویژگی‌های اساسی سیستم اولیه شامل توپولوژی بستر جذب سیستم و احتمالات مربوطه را حفظ می‌کند. تاکنر در «تئوری ابعاد محاط‌شده تاکنر» اثبات می‌کند که اگر سری زمانی به‌دست‌آمده از یک سیستم دینامیکی معین برای  $t=1,2,\dots,n$  مطابق (۷) باشد،

$$X(t) = (x(t), x(t-1), \dots, x(t-(n-1))) \quad (7)$$

می‌توان فضای حالت معادل دینامیک مولد داده‌ها را برای  $t=1,2,\dots,n-(m-1)\tau$  به‌صورت (۸) بازسازی کرد [۶].

$$Y(t) = f(x(t), x(t-\tau), x(t-2\tau), \dots, x(t-(m-1)\tau)) \quad (8)$$

که در این رابطه  $m$  یک اسکالر با نام بعد محاط و  $\tau$  یک

زمان از هم جدا و نسبت به هم واگرا می‌شوند. نمای لیاپانوف این واگرایی را به‌وسیله یک تابع نمایی اندازه‌گیری می‌کند. محاسبه نمای لیاپانوف از طریق اندازه‌گیری مقدار کشیدگی یا خمیدگی که در حرکت سیستم رخ می‌دهد، انجام می‌شود. در واقع، در این روش، سرعت متوسطی که مسیرهای انتقالی دو نقطه‌ای که در ابتدا به هم نزدیک بوده‌اند و به‌طور نمایی از یکدیگر منحرف می‌شوند، محاسبه می‌شود. اگر بزرگ‌ترین نمای محاسبه‌شده لیاپانوف مقدار مثبتی داشته باشد، سیستم دارای رفتار آشوبی است. روش محاسبه به‌صورت زیر است [۴]:

$$\text{اگر بین } X_n \text{ و } X_{n+1} \text{ رابطه تبعی (۲) وجود داشته باشد،} \\ X_{n+1} = f(X_n) \quad (2)$$

می‌توان فاصله بین  $X_0$  و  $X_{0+\varepsilon}$  را با  $\varepsilon$  و فاصله بین  $f^n(X_0)$  و  $f^n(X_{0+\varepsilon})$  را با تابع نمایی  $e^{n\lambda(X_0)}$  نشان داد. به عبارت دیگر:

$$e^{n\lambda(X_0)} = \left| f^n(X_0 + \varepsilon) - f^n(X_0) \right| \quad (3)$$

که در آن  $e^{n\lambda(X_0)}$  در واقع میانگین اختلاف بین نقاط مجاور در هر تکرار را نشان می‌دهد. در این رابطه  $\lambda$  به نمای لیاپانوف معروف است. حد رابطه (۳) به‌صورت (۴) خواهد بود:

$$\lambda(X_0) = \lim_{\varepsilon \rightarrow 0} \lim_{n \rightarrow \infty} \frac{1}{n} \log \left| \frac{f^n(X_0 + \varepsilon) - f^n(X_0)}{\varepsilon} \right| \quad (4)$$

## ۲-۲- بعد همبستگی

یکی دیگر از روش‌های تشخیص آشوب، تخمین بعد همبستگی است. برای تخمین بعد همبستگی چندین روش وجود دارد. روشی که در این مقاله استفاده شده است الگوریتم گراسبرگر - پروکاکسیا است [۵]. در این الگوریتم برای فضای فاز  $d$  بعدی، تابع همبستگی  $C(R)$  به‌صورت زیر تعریف می‌شود:

$$C(R) = \frac{1}{N(N-1)} \sum_{i=0}^{N-dT-1} \sum_{j=0, j \neq i}^{N-dT-1} H(R - |x(i) - x(j)|) \quad (5)$$

که در آن  $H$  یک تابع هویساید پله‌ای با  $H(u)=I$  برای

انقطاعی در مسیرهای حالت جاذب بازسازی شده، روش شمارش نزدیک‌ترین همسایه‌های کاذب FNN است. به این منظور، حالتی را در نظر بگیرید که بازسازی فضای حالت در فضای  $m$  بُعدی منجر به ایجاد محاط مناسب شده باشد، درحالی‌که در فضای  $m-1$  بُعدی چنین نباشد؛ در این حالت، رفتن از فضای  $m$  بُعدی به فضای  $m-1$  بُعدی سبب می‌شود که قسمت‌های مختلف جاذب روی یکدیگر تصویر شوند؛ بنابراین اگر تعدادی نقاط نزدیک به هم (نقاط همسایه) از این قسمت انتخاب شوند، تصاویر آن‌ها در فضای  $m$  بُعدی، دسته‌های متفاوتی را ایجاد خواهند کرد که می‌توانند از هم فاصله‌دار باشند؛ بنابراین، اگر نقاط همسایه در فضای  $R^m$  در فضای  $R^{m+1}$  نیز همسایه باشند،  $m$  برابر بُعد مینیمم برای بازسازی موفق فضای حالت است. از این رو، در این روش، وضعیت همسایه‌ها به‌زای بُعدهای متوالی محاط بررسی می‌شود تا اینکه تعداد همسایه‌های کاذب (که از تصویرکردن جاذب در فضای کوچک ناشی می‌شود) حدوداً به صفر برسد [۸].

### ۳- پیش‌بینی سری زمانی آشوبی

پیش‌بینی، گام نهایی در راستای تجزیه و تحلیل سری‌های زمانی آشوبی است. مسئله پیش‌بینی سری‌های زمانی آشوبی را می‌توان به نوعی یک مسئله معکوس دانست که هدف آن تقریب تابع  $f$  در رابطه (۲) است. این تابع، همان تابعی است که از روی سری زمانی رابطه (۷)، فضای فاز معادل با دینامیک مولد داده‌ها را بازسازی می‌کند. برای تقریب این تابع، روش‌های مختلفی وجود دارد. یکی از این روش‌ها، روش تقریب شعاعی است. در این روش نیمه‌محلی با استفاده از یک مجموعه توابع پایه شعاعی  $\phi$ ، با رابطه (۱۰)، تابع مد نظر تقریب زده می‌شود.

$$\hat{f}(x) = \sum_{j=1}^p w_j \phi(\|x - u_j\|) \quad (10)$$

در این رابطه  $u_j$ ها مراکز توابع شعاعی  $\phi$  هستند و  $w_j$ ها ضرایبی هستند که تأثیر هر یک از توابع را تعیین می‌کنند. اینجاست که ایده استفاده از شبکه‌های عصبی با تابع پایه شعاعی به‌منظور پیش‌بینی سری‌های زمانی آشوبی مطرح

اسکالر با نام زمان تأخیر است. برای به‌دست‌آوردن این دو پارامتر، روش‌های مختلفی وجود دارد که در این مقاله از روش نزدیک‌ترین همسایگی کاذب، FNN<sup>o</sup> برای محاسبه  $m$  و از روش میانگین اطلاعات متقابل، AMI<sup>T</sup> برای محاسبه  $\tau$  استفاده شده است.

### ۲-۴- محاسبه زمان تأخیر

روش‌های متفاوتی برای محاسبه زمان تأخیر لازم برای بازسازی فضای حالت دینامیک مولد داده‌های آشوبناک وجود دارد که از این میان کاربردی‌ترین روش، روش مبتنی بر میانگین اطلاعات متقابل بین داده‌های سری زمانی است [۷].

میانگین اطلاعات متقابل بین داده‌های دو مجموعه  $x(t)$  و  $x(t+\tau)$  عبارت است از:

$$I(\tau) = \sum_{y(t), y(t+\tau)} P(x(t), x(t+\tau)). \quad (9)$$

$$\log_2 \left[ \frac{P(x(t), x(t+\tau))}{P(x(t)).P(x(t+\tau))} \right]$$

این عبارت میزان فراگیری درمورد داده‌های  $x(t+\tau)$  را با استفاده از اندازه‌گیری  $x(t)$  بیان می‌کند. در این رابطه  $P$  تابع چگالی احتمال است.

در یک سیستم معین، این احتمال‌ها با ایجاد یک هیستوگرام از تغییرات  $x(t)$  و  $x(t+\tau)$  در اندازه‌گیری‌هایشان ارزیابی می‌شود. اگر اندازه‌گیری یک مقدار از مجموعه  $x(t)$ ، کاملاً مستقل از اندازه‌گیری یک مقدار از مجموعه  $x(t+\tau)$  باشد، در این صورت، چگالی احتمال توأم برابر حاصل ضرب چگالی احتمال‌های مجزا می‌شود و در این حالت مقدار اطلاعات متقابل بین اندازه‌گیری‌ها برابر صفر خواهد شد.

تابع  $I(\tau)$  به‌زای  $\tau$ های مختلف محاسبه می‌شود و زمان وقوع اولین مینیمم در این تابع به‌عنوان زمان تأخیر مناسب انتخاب می‌شود که در آن وابستگی داده‌های بردار  $x(t)$  و  $x(t+\tau)$  به حداقل رسیده است.

### ۲-۵- محاسبه بعد محاط

یکی از روش‌های مناسب جهت بررسی شرط عدم خود

می‌شود.

مهمی در تبدیل الگوهای غیرخطی به الگوهای تفکیک‌پذیر خطی دارد. لایه خروجی، جمع وزنی الگوهای خطی شده را به همراه یک خروجی خطی تولید می‌کند. در صورتی که از RBF برای تقریب تابع استفاده شود، چنین خروجی‌ای مفید خواهد بود؛ ولی در صورتی که نیاز باشد طبقه‌بندی الگوها انجام شود، آنگاه یک محدودکننده سخت یا یک تابع سیگموئید را می‌توان بر روی عصب‌های خروجی قرار داد تا مقادیر خروجی ۰ یا ۱ تولید شوند.

همان‌طور که از توضیحات بالا مشخص می‌شود، خصوصیت منحصر به فرد این شبکه، پردازشی است که در لایه پنهان انجام می‌شود. تابع لایه پنهان، رابطه‌ای مطابق با رابطه (۱۱) دارد:

$$F(x) = \sum_{j=1}^p w_j \phi(\|x - u_j\|) \quad (11)$$

$w_j$  ها وزن‌های مربوط به هر نرون و  $u_j$  ها مراکز ثقل تابع هر نرون هستند. تابع معروف در شبکه‌های شعاعی تابع گوسی یا نمایی به فرم (۱۲) است:

$$\phi(\|x - u_j\|) = e^{-\sigma_j \|x - u_j\|} \quad (12)$$

در این رابطه  $\sigma$  فاکتور عرض کرنل  $z$  است. شبکه عصبی با تابع شعاع مداری نیز مانند هر شبکه عصبی دیگر، دو مد عملکردی آموزش و مرجع دارد. در طی مد آموزش، پارامترهای تعدیل‌پذیر شبکه که عبارتند از:  $u_i$ ،  $\sigma_i$  و ماتریس وزن لایه خروجی  $W$  چنان تغییر می‌کند که خطای میانگین بین خروجی‌های شبکه در یک مجموعه آموزشی و مقادیر واقعی به حداقل برسد. در مد مرجع، شبکه آموزش دیده با ارائه بردارهای ورودی جدید به شبکه، بردارهای خروجی را به دست می‌آورد.


### ۵- پیش‌بینی سرعت باد با شبکه عصبی RBF

در این بخش نحوه آماده‌سازی الگوهای ورودی و خروجی مطلوب جهت ارائه به شبکه RBF بیان شده است. انتخاب ورودی‌ها اولین مرحله در پیش‌بینی با شبکه عصبی است. با توجه به توضیحات گفته‌شده در بخش‌های ۲ و ۳

### ۴- شبکه عصبی RBF


شبکه‌های عصبی با تابع پایه شعاعی ب‌طور گسترده برای تخمین غیرپارامتریک توابع چند بعدی از طریق مجموعه‌ای محدود از اطلاعات آموزشی به کار می‌روند. شبکه‌های عصبی شعاعی با آموزش سریع و فراگیر، بسیار جالب و کارآمد هستند و به آن توجه خاصی شده است [۹]. ژیروسی، پوگی و همچنین هارتمن و کپلر در سال ۱۹۹۰ میلادی اثبات کردند که شبکه‌های با تابع پایه شعاعی، تقریب سازهای بسیار قدرتمندی هستند؛ به طوری که با داشتن تعداد نرون‌های کافی در لایه مخفی، قادر به تقریب‌زدن هر تابع پیوسته و با هر درجه دقت هستند. نکته بسیار جالب آن است که این شبکه‌ها تنها با داشتن یک لایه مخفی، دارای چنین خاصیتی هستند. شبکه‌های با تابع پایه شعاعی بیشترین الهام را از تکنیک‌های آماری طبقه‌بندی الگوها گرفته‌اند و اساساً به عنوان گونه‌ای از شبکه‌های عصبی، حیاتی نو یافته‌اند و مزیت عمده آن‌ها، طبقه‌بندی الگوهایی است که فضای غیرخطی دارند. این تکنیک‌ها، گرچه تعدادشان اندک است، به فراوانی به کار گرفته شده‌اند. این شبکه‌ها، اغلب با شبکه عصبی پس انتشار خطا مقایسه می‌شود.

معماری اصلی RBF متشکل از یک شبکه دو لایه مانند شکل (۱) است.



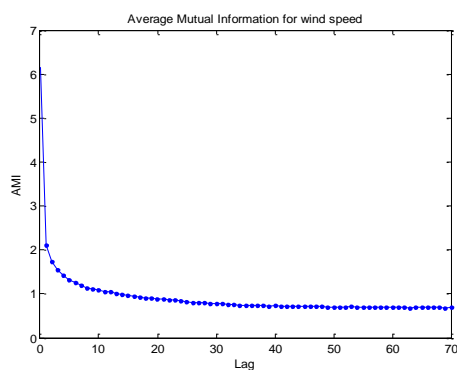
شکل (۱): ساختار شبکه عصبی RBF

لایه پنهان، یک انطباق غیرخطی مابین فضای ورودی و یک فضای معمولاً با بُعد بزرگ‌تر برقرار می‌کند و نقش



شکل (۲): تغییرات سرعت متوسط باد در منطقه ورزش در طول یک ماه

از میان داده‌های موجود برای آموزش هر یک از شبکه‌های مدل نظر، ۵۰۰ داده (حدود ۸ ساعت) استفاده شده است و پیش‌بینی برای ۱۲۰ داده (۲ ساعت) انجام شده است. برای محاسبه زمان تأخیر مناسب از روش میانگین اطلاعات متقابل استفاده شده است. همان‌طور که در شکل (۳) مشاهده می‌شود، اولین مینیمم نمودار میانگین اطلاعات متقابل داده‌ها در زمان ۲۲ اتفاق افتاده است و به همین دلیل  $\tau=22$  به‌عنوان زمان تأخیر مناسب انتخاب شده است.



شکل (۳): نمودار میانگین اطلاعات متقابل سرعت باد

برای محاسبه بعد محاط از الگوریتم نزدیک‌ترین همسایگی کاذب استفاده شد که با توجه به شکل (۴) مشاهده می‌شود که بعد از نمونه ششم، تعداد همسایه‌های کاذب به صفر می‌رسد؛ بنابراین می‌توان گفت که بعد محاط بهینه برای سری مفروض ۷ است.

تعیین دو پارامتر مهم بعد محاط  $m$  و زمان تأخیر  $\tau$  در بازسازی دینامیک سرعت باد بر پایه سری زمانی اهمیت بسیاری دارد. با به‌دست‌آوردن این دو پارامتر، از فضای حالت بازسازی‌شده مطابق (۱۳) به‌عنوان ورودی شبکه استفاده شده است.

$$Y_i = [x(i), x(i + \tau), \dots, x(i + (m-1)\tau)] \quad (13)$$

شبکه عصبی در ورودی شامل  $m$  (بعد محاط) نرون خواهد بود و در لایه مخفی فضای حالت مفروض بازسازی خواهد شد. تعداد نرون‌های لایه پنهان با توجه به تعداد ورودی‌ها مشخص می‌شود. تابعی که برای لایه پنهان در نظر گرفته می‌شود، تابع گوسی معرفی‌شده با ضابطه (۱۱) است و برای نرم اقلیدسی از رابطه (۱۴) استفاده می‌شود.

$$\|x - u_j\| = \sqrt{\sum_{k=1}^p [x(k) - u_j(k)]^2} \quad (14)$$

که در این رابطه  $p$  تعداد نقاط موجود در فضای حالت است.

برای محاسبه مراکز ثقل از الگوریتم  $k$  میانگین استفاده شده است [۹]. عرض کرنل‌ها نیز در راستای مینیمم‌کردن خطای میان خروجی شبکه آموزش‌دیده و مقادیر واقعی برابر ۳۰ به دست آمد. خروجی شبکه RBF سرعت آینده باد خواهد بود.

داده‌هایی که برای شبیه‌سازی روش پیشنهادی استفاده شده است، سری زمانی سرعت متوسط باد در طول یک سال در ارتفاع ۴۰ متری است که در ایستگاه ورزشگاه واقع در استان اصفهان است که آن را سازمان انرژی‌های نو ایران ثبت کرده است. داده‌ها با فاصله‌های ده دقیقه‌ای ثبت شده‌اند. در شکل (۲) می‌توان بخشی از سری زمانی مربوطه را مشاهده کرد. این سری زمانه برای یک ماه رسم شده است.

میانگین مربعات خطا،  $RMSE^y$  است. این معیار را می‌توان طبق رابطه (۱۶) محاسبه کرد. هر چقدر خطای  $RMSE$  پیش‌بینی کمتر باشد، عملکرد شبکه بهتر بوده است.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (16)$$

در این رابطه  $\hat{y}_i$  مقدار پیش‌بینی شده برای نمونه  $i$  ام و  $y_i$  مقدار واقعی آن نمونه است.

یک معیار دیگر که برای ارزیابی عملکرد شبکه استفاده شده، ضریب همبستگی است. این ضریب بیان‌کننده میزان همبستگی بین نتایج پیش‌بینی شده مدل و داده‌های واقعی است که براساس رابطه (۱۷) محاسبه می‌شود. بدیهی است که هرچه مقدار آن به یک نزدیک‌تر باشد، نشان‌دهنده نزدیکی بیشتر مقادیر پیش‌بینی شده به مقادیر واقعی است.

$$R = \frac{\sum_{i=1}^N (y_i - \bar{y})(\hat{y}_i - \bar{\hat{y}})}{\sqrt{\sum_{i=1}^N (y_i - \bar{y})^2 \sum_{i=1}^N (\hat{y}_i - \bar{\hat{y}})^2}} \quad (17)$$


که در آن،  $\hat{y}$  سرعت باد پیش‌بینی شده و  $\bar{\hat{y}}$  میانگین مقادیر پیش‌بینی شده،  $y$  مقدار واقعی سرعت باد و  $\bar{y}$  میانگین مقادیر واقعی هستند.

### ۵-۳- نتایج شبیه‌سازی

شبیه‌سازی‌ها با نرم‌افزار Matlab انجام شده است. نتایج حاصل از پیش‌بینی شبکه پیشنهادی را می‌توان در شکل (۵-۵) الف) مشاهده کرد. مشاهده شد که سرعت باد با تقریب خوبی پیش‌بینی می‌شود. خطای پیش‌بینی در شکل (۵-۵) ب) رسم شده است. تنها در بعضی نمونه‌ها اختلاف مقدار واقعی و مقدار پیش‌بینی شده شبکه عصبی به بیشتر از ۰٫۲ متر بر ثانیه رسیده است.

مقدار خطای  $RMSE$  محاسبه شده برای این پیش‌بینی برابر ۰٫۸٪ و ضریب همبستگی ۰٫۸ به دست آمد.

عملکرد شبکه عصبی RBF معمولاً با شبکه عصبی MLP مقایسه می‌شود. برای تعیین میزان موفقیت شبکه به کار برده شده، پیش‌بینی سرعت باد با استفاده از شبکه عصبی MLP انجام شد. بدین‌منظور از یک شبکه پیش‌خور



شکل (۴): نمودار تعداد همسایگی‌های کاذب برای سرعت باد

برای تعیین آشوبناک بودن رفتار سرعت باد، بعد همبستگی سری زمانی مربوطه به دست آمد که عددی برابر ۱٫۵۲۶ حاصل شد. غیرصحیح بودن این عدد، تأییدی بر حضور آشوب در رفتار سرعت باد است. علاوه بر آن، بزرگ‌ترین نمای لیاپانوف برای داده‌های موجود نیز محاسبه شد که برابر ۰٫۳۳۹۶ به دست آمد. با توجه به آزمون توضیح داده شده در بخش ۲، مثبت بودن این عدد نیز حضور آشوب را اثبات خواهد کرد.

### ۵-۱- پیش پردازش داده‌ها

پس از محاسبه بعد محاط و زمان تأخیر، شبکه RBF مناسب جهت پیش‌بینی سرعت باد تا ۲۴ ساعت آینده طبق ساختار ارائه شده در بخش ۵ طراحی می‌شود.

الگوهای آموزشی قبل از ارائه به شبکه، طبق (۱۵) به گونه‌ای پیش‌پردازش شدند که میانگین مجموعه آموزشی، صفر و انحراف معیار، یک شود.

$$x_p = \frac{x - \text{mean}(x)}{\text{std}(x)} \quad (15)$$

که  $x$  الگوهای اولیه آموزشی،  $\text{mean}(x)$  میانگین و  $\text{std}(x)$  انحراف معیار الگوهای  $x$  است. پیش‌پردازش موجب می‌شود آموزش شبکه به صورت مؤثرتری انجام شود.

### ۵-۲- ارزیابی شبکه

تابع معیاری که برای بررسی عملکرد پیش‌بینی‌پذیری و میزان دقت عملکرد شبکه عصبی استفاده شد، تابع مجذور

پیش‌بینی، به خاطر نتایج بهتر، پایداری بیشتر و زمان کم می‌تواند بهبودی در روش‌های پیش‌بینی سرعت باد حاصل کند.

جدول (۱): نتایج پیش‌بینی سرعت باد با دو شبکه عصبی

MLP و RBF

متوسط ضریب همبستگی برای ۲۰ بار پیش‌بینی	متوسط خطای RMSE برای ۲۰ بار پیش‌بینی (%)	متوسط زمان مورد نیاز برای پیش‌بینی (ثانیه)	شبکه عصبی مورد استفاده برای پیش‌بینی
۰,۸	۸,۷	۱۳	RBF
۰,۷۵	۱۷,۵	۷۵۴	MLP

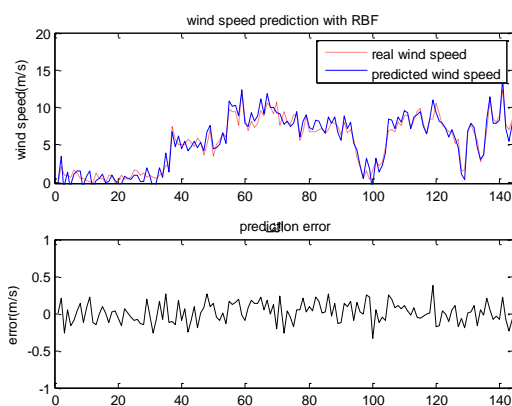
## ۶- نتیجه‌گیری و پیشنهادات

در این مقاله، برای پیش‌بینی سرعت باد روشی مبتنی بر تئوری آشوب ارائه شد. در این روش از روی سری زمانی ثبت‌شده برای سرعت باد در ایستگاه‌های هواشناسی، فضای حالت دینامیک سرعت باد با استفاده از قضیه تاکنز، بازسازی می‌شود. برای این بازسازی، نیاز است تابعی غیرخطی که توصیف‌کننده فضای حالت مولد داده‌هاست تقریب زده شود. یکی از روش‌های تقریب تابع، استفاده از توابع شعاعی است که روشی نیمه‌محلی بوده است و با استفاده از یک مجموعه توابع شعاعی تابع مد نظر تقریب زده می‌شود. با تکیه بر این روش، ایده استفاده از شبکه عصبی RBF مطرح شد. بردارهای تأخیری به‌دست‌آمده از قضیه تاکنز، این شبکه را طراحی کرده‌اند و آموزش صحیح داده‌اند. با طراحی و آموزش صحیح این شبکه، فضای حالت معادل دینامیک سرعت باد در لایه پنهان بازسازی شده است و با استفاده از این فضا، مقادیر آینده سرعت باد پیش‌بینی می‌شود. همان‌طور که مشاهده شد، نتیجه به‌دست‌آمده از تقریب بسیار خوبی نسبت به روش‌های معمول برخوردار است.


پیشنهادی که می‌توان برای ادامه کار مطرح کرد، استفاده از شبکه‌های عصبی تأخیر زمانی TDNN، یا شبکه‌های خود بازگشتی با ورودی اضافی NARX، جهت تشکیل بردارهای تأخیر زمانی ورودی شبکه RBF است. این شبکه‌ها در لایه ورودی خود یک خط تأخیر زمانی TDL

سه لایه استفاده شد. ساختار این شبکه متناسب با روش بازسازی فضای حالت دینامیک مولد داده‌ها طراحی شده است. نتایج حاصل از پیش‌بینی این شبکه در شکل (۶) نمایش داده شده است.

همان‌طور که مشاهده می‌شود، خطای پیش‌بینی شبکه عصبی MLP که در شکل (۶-ب) نشان داده شده است نسبت به خطای پیش‌بینی شبکه عصبی RBF در شکل (۵-ب) بیشتر است. یکی از مزایای شبکه RBF نسبت به شبکه MLP، عملکرد پایدار آن است؛ طوری که در هر بار اجرای برنامه نتیجه یکسانی حاصل می‌شود؛ ولی در هر بار پیش‌بینی شبکه MLP نتایج نسبتاً متفاوتی حاصل می‌شود. میانگین خطای RMSE پیش‌بینی این شبکه برای ۲۰ مرتبه اجرا برابر ۱۷,۵٪ و ضریب همبستگی ۰,۷۵ به دست آمد.



شکل (۵): نتایج پیش‌بینی سرعت باد با شبکه RBF



شکل (۶): نتایج پیش‌بینی سرعت باد با شبکه MLP

نتایج حاصل از پیش‌بینی دو شبکه عصبی RBF و MLP در جدول (۱) جمع‌آوری شده است. با توجه به این جدول می‌توان گفت که استفاده از شبکه عصبی RBF برای



- information", *Physical Review A*, Vol. 33, No. 2, pp. 1134-114, 1986.
- [8] Abarbanel, H. D., Kennel, M. B., "Local false nearest neighbors and dynamical dimensions from observed chaotic data", *Physical Review E*, Vol. 47, No. 5, pp. 3057-3068, 1993.
- [9] Hartman, E., Keeler, J. D., Kowalski, J. M., "Layered neural networks with Gaussian hidden units as universal approximations", *Neural Computation*, Vol. 2, No. 2, pp. 210-215, 1990.
- [10] Lei, D., Shuang, G., "Chaos characteristic analysis on the time series of wind power generation capacity", *Acta Energiæ Solaris Sinica*, Vol. 28, pp. 1290-1294, 2007.
- [11] Chen, P., Chen, H., Ye, R., "Chaotic wind speed series forecasting based on wavelet packet decomposition and support vector regression", *IEEE IPEC*, pp. 256-261, 2010.
- [12] Gangui, Y., et al., "The Ultra-short term prediction of wind power Based on chaotic Time Series", *Journal of Energy procedia* 17, pp. 1490-1496, 2012.
- [13] Abedinia, O., Amjady N., "Short-Term wind power prediction based on hybrid neural network and chaotic shark smell optimization", *international journal of precision engineering and manufacturing-green technology* Vol. 2, No. 3, pp. 245-254, 2015.

دارند که می‌تواند تأخیرهای مربوط به  $\tau, 2\tau, \dots, (m-1)\tau$  را تولید کند.

## مراجع

- [1] "Wind energy scenarios for 2030", a report by the EWEA, 2015.
- [2] Zervos A., "Renewable Global Status Report", *Renewable Energy Policy Network for the 21<sup>st</sup> Century*, 2015.
- [3] Burton, T et al. *Wind Energy Handbook*, Wiley, 2001.
- [4] Wolf, A., Swift, B., Swinney, H. L. and Vastano, J., "Determining Lyapunov exponents from a time series", *Physical D*, Vol. 16, pp.285-317, 1999.
- [5] Grassberger, P., Procaccia, I., "Characterization of Strange Attractors", *Physical Review Letters*, Vol. 50, pp. 346-349, 1983.
- [6] Takens, F., "Detecting strange attractors in turbulence" in: Rand DA, Young LS, editors. *Dynamical systems and turbulence. Lecture notes in mathematics*, Vol. 898. Berlin: Springer, pp. 366-381, 1981.
- [7] Fraser, A., Swinney, H.L., "Independent coordinates for strange attractors from mutual

<sup>1</sup> European Wind Energy Association

<sup>2</sup> Renewable Energy policy Network for 21<sup>st</sup> century

<sup>3</sup> European Wind Energy Association

<sup>4</sup> Auto Regressive Moving Average

<sup>5</sup> False Nearest Neighbor

<sup>6</sup> Average Mutual Information

<sup>7</sup> Root Mean Square Error

