

پیشگویی گام- بلند سرعت باد مبتنی بر مدل ترکیبی RNNGA

محمدحسین رfan^{۱*}، عادل دمشقی^۲، مهرنوش کمرزین^۳

^۱ دانشیار دانشکده مهندسی برق، دانشگاه تربیت دبیر شهید رجایی، تهران، ایران

refan@srttu.edu

^۲ دانشجوی دکتری دانشکده مهندسی برق، دانشگاه تربیت دبیر شهید رجایی، تهران، ایران

a.dameshghi@srttu.edu

^۳ کارشناس ارشد معاونت پژوهش و فناوری، شرکت مهندسی و ساخت برق و کنترل مینا (مکو)، کرج، ایران

kamarzarrin.mehrnoosh@mapnaec.com

چکیده: برای استفاده مناسب و کارآمد از انرژی باد، پیش‌بینی سرعت باد بسیار مهم است. باد یکی از منابع اصلی انرژی در جهان است، اما توربین‌های بادی دارای عدم قابلیت اطمینان، پیوستگی و یکنواختی در تولید توان هستند. از طرفی تغییرات ناگهانی سرعت باد موجب به خطر افتادن سلامتی واحدهای توربین باد می‌شود؛ از این رو پیشگویی سرعت باد برای نگهداری توربین و همچنین برنامه‌ریزی برای توان تولیدی اهمیت فراوانی دارد. این مقاله یک روش جدید برای پیشگویی سرعت باد ارائه می‌دهد. این روش براساس ترکیبی از الگوریتم ژنتیک و شبکه عصبی است. اطلاعات گذشته سرعت باد به‌عنوان ورودی مدل برای پیشگویی با گام بلند (چندروزه) سرعت باد استفاده می‌شوند. عملکرد روش ارائه‌شده براساس اطلاعات واقعی جمع‌آوری‌شده از مزرعه بادی کهک شرکت مینا مورد سنجش قرار گرفته است. نتایج شبیه‌سازی دقت مدل پیشنهادشده را در پیشگویی سرعت باد نشان دادند. دقت مدل پیشگویی براساس معیار **RMSE (Root Mean Squared Error)**، 0.96 متر بر ثانیه به‌دست آمد. نتایج حاصل از روش **RNNGA (Recurrent Neural Network Genetic Algorithm)** با روش‌های برخی مراجع مقایسه شد که این مدل با اطلاعات ورودی کمتر (سرعت باد)، دقت مشابه یا بهتر داشته است.

واژه‌های کلیدی: شبکه عصبی بازگشتی، الگوریتم ژنتیک، سرعت باد.

۱. مقدمه

همراه راهکارهای مربوط نشان داده شده است. با توجه به هدف مقاله، یعنی نگهداری توربین باد، مقادیر پیشگویی سرعت باد که مورد نیاز بخش CMS است، مورد تحلیل قرار گرفته است. توصیف ریاضی از پیشگویی سرعت باد پیدا کردن تقریبی از $V(t+n)$ از بردار $V(t)$ براساس اندازه‌گیری‌های m نمونه قبلی شامل $V(t), V(t-1), \dots, V(t-m+1)$ است. با توجه به مقدار n گام زمانی پیشگویی با توجه به کاربردهای تعریف‌شده در جدول (۱) مشخص می‌شود [۱۷-۱۹]. نویسندگان این مقاله یک راهبرد جدید را در پیشگویی سرعت باد براساس شبکه عصبی بازگشتی^۲ و الگوریتم ژنتیک^۳ ارائه داده‌اند، GA به بهبود عملکرد RNN کمک کرده است. در این مقاله، اطلاعات ورودی RNN با سرعت باد تأمین می‌شود، اطلاعات متعلق به سایت کهک شرکت مینا واقع در تاکستان قزوین است. در نیروگاه بادی کهک، نواحی عملکردی توربین باد براساس سرعت باد بدین صورت است؛ در سرعت‌های باد کمتر از ۳/۵ متر بر ثانیه، توربین باد توانی تولید نمی‌شود و زاویه پیچ ۹۰ درجه می‌ماند، در سرعت‌های باد ۳/۵ تا ۱۲ متر بر ثانیه (سرعت نامی)، زاویه پیچ صفر درجه است تا توربین به توان مطلوب برسد. در سرعت‌های بین ۱۲ تا ۲۵ متر بر ثانیه، به‌منظور محدود کردن سرعت چرخشی روتور به ۱۷/۱ rpm کنترل پیچ صورت می‌گیرد. ساختار مقاله به این صورت تنظیم شده است: در بخش دوم مقاله مروری روی کارهای گذشته پرداخته می‌شود، بخش سوم مدل پیشگویی RNNGA است. بخش چهارم بررسی نتایج شبیه‌سازی است. در نهایت، بخش پنجم به نتیجه‌گیری می‌پردازد.

جدول (۱): گام‌های زمانی متفاوت پیشگویی سرعت باد [۱۵]

هدف	گام زمانی	روش‌ها
نگهداری واحد	۰	سری زمانی / روش‌های آماری
کنترل	چند ثانیه یا دقیقه	سری زمانی / روش‌های آماری
عملکرد سامانه‌های توان کوچک	۱ تا ۶ ساعت	سری زمانی / روش‌های آماری
عملکرد سامانه‌های توان به هم پیوسته	۱ تا ۷۲ ساعت	سری زمانی / روش‌های آماری / مدل‌های فیزیکی
برنامه‌ریزی نگهداری و سلامتی مورد نیاز CMS	۱ تا ۷ روز	سری زمانی / روش‌های آماری / مدل‌های فیزیکی

انرژی بخش بزرگی از نیاز زندگی گذشته، حال و آینده بشریت را تشکیل داده و در حال حاضر به دلیل کمبود منابع فسیلی، به یکی از نگرانی‌های بشریت تبدیل شده است [۱]. کاهش منابع سوخت فسیلی، افزایش روزافزون هزینه آن‌ها و مصرف بی‌رویه انرژی از مهم‌ترین دلایلی است که محققان را بر آن داشته تا روش‌های جدیدی از جمله منابع تجدیدپذیر را برای تولید انرژی ارائه دهند [۲]. با توجه به اینکه مقدار توان تولیدشده بستگی به تغییرات تصادفی منابع انرژی از قبیل باد، خورشید، آب و... دارد، عموماً خروجی این روش‌ها غیرقابل پیش‌بینی و با قابلیت اطمینان پایین است. از مهم‌ترین انرژی‌های تجدیدپذیر، باد است. انرژی در دسترس و همیشگی که محققان و صاحبان صنعت را بر آن داشته تا آن را به انرژی الکتریکی پاک تبدیل کنند [۳-۷]. این انرژی هم‌اکنون یکی از محصولات راهبردی در بازارهای تجاری انرژی است. توربین باد قابلیت تبدیل انرژی باد به انرژی الکتریکی را دارد. بر طبق اطلاعات جمع‌آوری‌شده، در حدود ۲/۳ درصد از انرژی مصرفی الکتریکی دنیا با استفاده از انرژی باد تولید می‌شود [۸-۱۰]. استفاده از توان باد در همه نقاط جهان در حال رشد است، به‌گونه‌ای که پیش‌بینی می‌شود تا سال ۲۰۲۰ نزدیک به ۱۲ درصد از تولید انرژی الکتریکی جهان را به خود اختصاص دهد و تا سال ۲۰۳۰، این مقدار به ۳۰ درصد می‌رسد [۱۱-۱۴]. در پایان سال ۲۰۱۱، کشور چین چیزی در حدود ۶۲ گیگاوات توان به‌وسیله توربین‌های بادی تولید و رتبه اول را در کل جهان کسب کرد [۱۵]. از این رهگذر، استفاده از روش‌های پیشرفته در حفظ سلامت توربین باد از جمله پیش‌بینی تغییرات سرعت باد دارای اهمیت است. از کار افتادن توربین باد موجب افزایش هزینه‌های تعمیر و نگهداری و کاهش تولید توان می‌شود [۱۳]. به‌منظور تولید توان مؤثر توسط یک توربین بادی باید عملکرد توربین توسط سامانه پایش وضعیت^۱ مورد بررسی قرار گیرد. یکی از پارامترهای مهم عملکردی در کنار توان و گام-پیچ، سرعت باد است که نتایج CMS باید با توجه به آن تحلیل شود [۱۴].

پیشگویی سرعت باد به دلایل زیر اهمیت دارد:

۱. نگهداری واحدهای توربین باد؛

۲. زمان‌بندی تولید توان؛

۳. بازیابی انرژی و طرح ذخیره‌سازی.

هر پیشگویی برای گام زمانی مشخص انجام می‌شود [۱۵]. این گام براساس نیازمندی‌هایی که در مراکز کنترل، برنامه‌ریزی و نگهداری وجود دارد تعیین می‌شود [۱۶]. در جدول (۱) گام‌زمانی پیشگویی به

2. Recurrent Neural Network (RNN)
3. Genetic Algorithm (GA)

1. Condition Monitoring System (CMS)

جدول (۲): مروری روی روش‌های پیشگویی سرعت باد قبل از سال ۲۰۰۵

سال	مرجع	روش	سال	مرجع	روش
۱۹۸۰	[۲۰]	Autoregressive-Moving-Average (ARMA)	۱۹۹۷	[۲۶]	ARMA
۱۹۸۱	[۲۱]	ARMA-Kalman Filter (KF)	۱۹۹۸	[۴۸]	NN
۱۹۸۴	[۲۳]	AR	۱۹۹۹	[۳۹]	Support Vector Machine (SVM)
۱۹۸۴	[۳۷]	Tree based regression	۲۰۰۱	[۴۲]	NN
۱۹۸۵	[۱۲]	AR	۲۰۰۱	[۳۵]	Gradient Boosting Machine
۹۳-۱۹۹۰	[۴۳-۴۴]	Neural Network (NN)	۲۰۰۱	[۴۲]	NN
۱۹۹۴	[۲۴]	AR	۲۰۰۱	[۳۵]	Gradient Boosting Machine
۱۹۹۴	[۴۱]	NN	۲۰۰۲	[۳۴]	Stochastic Gradient Boosting
۱۹۹۵	[۲۵]	KF and AR	۱۹۹۵ و ۲۰۰۴	[۵۲ و ۵۵]	SVM
۱۹۹۶	[۲۲]	KF-AR	۲۰۰۴	[۳۸]	Nearest-neighbor

۲. مروری بر کارهای گذشته

پیشگویی سرعت باد در سه دوره زمانی کوتاه، متوسط و بلندمدت انجام می‌شود. گام پیشگویی کوتاه‌مدت در حدود ۱۰ ثانیه تا ۱۰ دقیقه، پیشگویی زمان متوسط سرعت باد چندساعته و پیشگویی طولانی‌مدت شامل چند روز است. پیشگویی کوتاه‌مدت برای کنترل توربین باد مؤثر است، پیشگویی مدت متوسط توسط بخش برنامه‌ریزی قابل استفاده است و در نهایت، پیشگویی بلندمدت برای تعیین تولید توان ثابت، نگهداری و سلامت توربین باد مورد استفاده قرار می‌گیرد. در طی ۲۵ سال اخیر روش‌های گوناگونی برای پیشگویی سرعت باد استفاده شده است. در جدول (۲) مقالات منتشر شده از سال ۱۹۹۰ تا سال ۲۰۰۵ آمده است. در ادامه، مقالات سال ۲۰۰۵ به بعد مرور می‌شود. در سال ۲۰۱۱ از روش خود رگرسیون میانگین متحرک^۱ برای پیشگویی سرعت باد استفاده شده است [۲۷]. در مرجع [۲۸] و در سال ۲۰۱۲، یک تحقیق براساس پیشگویی مدت متوسط انجام شد و نتایج آن نشان داد که دقت مدل پیشگویی به سبب افزایش گام زمانی پیشگویی کاهش پیدا کرده است. علاوه بر روش‌های آماری موروشده، روش‌های فیزیکی نیز در پیشگویی سرعت باد استفاده شده است. مدل‌های مبتنی بر پیش‌بینی عدد آب‌وهوا برای پیشگویی سرعت باد است. معمولاً روش‌های مبتنی بر پیشگویی آب‌وهوایی عددی^۲ با روش‌های آماری، باهم برای پیشگویی سرعت باد استفاده می‌شوند. در مرجع [۲۹] از مدل ARMA استفاده شده است. در مرجع [۳۰] از اطلاعات NWP به‌عنوان ورودی فیلتر کالمن^۳ برای بهبود دقت پیشگویی سرعت باد استفاده شده است. در مرجع [۳۱] از مدل AR برای پیشگویی سرعت باد براساس اطلاعات سرعت یک توربین باد و همچنین اطلاعات سرعت حاصل از NWP

به‌کار گرفته شده است. در مرجع [۳۲] روش تطبیقی و موجک شبکه عصبی^۴ برای پیشگویی سرعت باد براساس اطلاعات NWP مطرح شده است. در پژوهش‌هایی مبتنی بر NWP از دو لایه برای ترکیب NWP و مدل‌های آماری استفاده می‌شود. مدل NWP نتایج پیشگویی سرعت باد را فراهم می‌کند و سپس نتایج به‌عنوان ورودی آموزشی مدل‌های آماری برای پیشگویی دقیق‌تر سرعت باد استفاده می‌شوند. این روش‌ها در هر سه دوره زمانی پیشگویی کاربرد دارند. مرجع [۳۱] ترکیب AR و NWP برای گام کوتاه‌مدت است. مرجع [۳۳] برای پیشگویی ساعتی از NWP و NN استفاده می‌کند و نتایج حسن عملکرد روش را نشان می‌دهد. استفاده از ماشین بردار پشتیبان^۵ در سال ۲۰۰۸ انجام شده است [۴۰]. مدل شبکه عصبی برای پیشگویی کوتاه و بلندمدت سرعت باد مطرح شده است. در پیشگویی کوتاه‌مدت در مرجع [۴۵] سرعت باد اندازه‌گیری شده در هر ۱۰ ثانیه، براساس NN به‌عنوان ورودی است. در مرجع [۱۰] روش‌های مختلف پیشگویی شامل روش درخت، SVM و NN با یکدیگر مقایسه شده‌اند، NN در سنجش صورت گرفته این مقاله، رتبه برتر را کسب کرده است. گزارش صورت گرفته از مقادیر پیشگویی شده با گام ۱ دقیقه بوده است. در مرجع [۴۶] یک سنسور مجازی برای تخمین سرعت باد منعکس شده است. در این مقاله، خطای تخمین و شبیه‌سازی‌ها عملکرد مدل را مطلوب نشان داده‌اند. در مرجع [۴۷] از روش RNN برای پیشگویی سرعت باد تا ۱ دقیقه استفاده شده است. گام‌های چندگانه پیشگویی از ۱۵ دقیقه تا ۳ ساعت در این مرجع گزارش شده است. ثبات و پایداری این روش بسیار خوب است. از NN مصنوعی در مرجع [۴۹] استفاده شده است. در مرجع [۵۰] روش NN با روش بهینه‌سازی گروهی ذرات^۶ [۵۱] در پیشگویی سرعت باد مقایسه شده است. در مرجع [۵۶] پیشگویی ساعتی سرعت باد با استفاده

4. Wavelet Neural Network (WNN)
5. Support Vector Machine (SVM)
6. Particle Swarm Optimization (PSO)

1. Autoregressive Moving Average (ARMA)
2. Numerical Weather Prediction (NWP)
3. Kalman Filter (KF)

در معادله (۱)، τ_i نشان‌دهنده ثابت‌های زمانی، σ تابع فعال‌سازی، b_i بایاس، W_{ij} وزن‌های خروجی y_j از نرون i ام، و W_{ij}^{IN} وزن‌های ورودی خارجی I_j است. \dot{y}_i مطابق با رابطه (۲) محاسبه می‌شود:

$$\dot{y}_i \approx \frac{y_i(t + \Delta t) - y_i(t)}{\Delta t} \quad (2)$$

در رابطه اخیر، Δt گام زمانی است. تابع فعال‌سازی با رابطه (۳) مشخص می‌شود:

$$\sigma_i(s) = \tanh(\beta_i s), i = 1, \dots, n \quad (3)$$

جایی که β_i ثابت است. زمان بین هر دو ورودی با Δt نشان داده شده است و سیگنال خروجی پس از گام زمانی محاسبه می‌شود. مجموعه گام‌ها با N نشان داده می‌شود که مطابق با رابطه (۴) است:

$$N = \frac{\Delta T}{\Delta t} \quad (4)$$

بنابراین $y_i(t + \Delta t)$ مطابق با رابطه (۵) محاسبه می‌شود:

$$y_i(t + \Delta t) = y_i(t) + \frac{\Delta T}{\Delta t} \times \left[\sigma \left(b_i + \sum_j W_{ij} y_j(t) + \sum_j W_{ij}^{IN} I_j(t) \right) - y_i(t) \right] \quad (5)$$

نرون‌های خروجی برای $N-1$ گام زمانی به روش مشابه محاسبه می‌شود و پیشگویی برای زمان $(t + N\Delta t)$ مطابق با رابطه (۶) است:

$$y_i(t + N\Delta t) = y_i(t + \Delta t) = y_i(t + (N-1)\Delta t) + \frac{\Delta T}{\Delta t} \times \left[\sigma \left(b_i + \sum_j W_{ij} y_j(t + (N-1)\Delta t) + \sum_j W_{ij}^{IN} I_j(t) \right) - y_i(t + (N-1)\Delta t) \right] \quad (6)$$

ساختار شبکه‌ای یک شبکه RNN در شکل (۱) نشان داده شده که در آن، بردارها نشان‌دهنده اتصالات وزن‌ها، و نرون یک، نرون خروجی است [۱۹].

۲.۳. روش RNNGA

ساختار کلی الگوریتم RNNGA در شکل (۲) نشان داده شده است. الگوریتم‌های تکاملی اغلب برای آموزش شبکه‌های عصبی استفاده می‌شوند و شامل الگوریتم ژنتیک، برنامه‌نویسی ژنتیک و راهبرد تکاملی می‌شوند. این روش‌ها در بسیاری از کاربردها مثل بهینه‌سازی، دسته‌بندی و عملیات رگرسیون استفاده می‌شوند. مفاهیم اصلی الگوریتم ژنتیک شامل عملگرهای سه‌گانه انتخاب، آمیزش و جهش

از مدل SVM انجام شده است. در مرجع [۵۷] یک روش ترکیبی مبتنی بر منطق فازی و شبکه عصبی ارائه شده است. مرجع [۵۸] روش شبکه عصبی مصنوعی برای پیشگویی گام کوتاه سرعت باد است. در مرجع [۵۹] یک روش ترکیبی متشکل از موجک و آنالیز سری‌های زمانی به‌منظور پیشگویی سرعت باد مزارع بادی با توربین‌های کوچک استفاده شده است. نتایج نشان داد که این روش از NN مبتنی بر پخش [۵۹] بهتر است. در مرجع [۶۰] یک روش AR دوره‌ای با یک روش ماشین بردار پشتیبان حداقل مربعات^۱ ترکیب شده است. در این مقاله، روش‌ها به‌تنهایی و به‌صورت ترکیب‌شده مورد سنجش و تحلیل قرار گرفتند؛ نتایج حاکی از آن است که حالت ترکیبی پاسخ بهتری دارد.

۳. شبکه عصبی بازگشتی

شبکه عصبی بازگشتی یک قابلیت مهم در ذخیره اطلاعات برای استفاده در آینده دارد. این خاصیت در شبکه پیشخور وجود ندارد. شبکه RNN یک حافظه کوتاه‌مدت دارد که اطلاعات ورودی RNN را به‌روزرسانی می‌کند و با اطلاعات پس‌انتشار ذخیره‌شده نیز به‌روزرسانی می‌شود. وجود فیدبک در این ساختار باعث می‌شود تا حین آموزش، شبکه خود را به‌روز کند. شبکه RNN در حوزه زمان کار می‌کند. در هر واحد زمان، یک بردار ورودی را دریافت می‌کند، لایه مخفی خود را با تابع فعال‌سازی غیرخطی به‌روزرسانی کرده و از آن برای پیش‌بینی خروجی استفاده می‌کند. این مدل در لایه مخفی خود، توانایی ذخیره اطلاعات به‌صورت گسترده با ابعاد زیاد را دارد و دارای قدرت محاسباتی بالایی نیز است. از RNN برای پیش‌بینی‌های دشوار بهره می‌برند. در این مقاله، یک RNN با اتصالات کامل در نظر گرفته شده است که در آن، اتصالات بازگشتی کامل از لایه‌های پنهان قبلی به لایه‌های پنهان بعدی وجود دارد. این اتصالات اثر نمونه‌های قبلی را بر روی نمونه‌های فعلی در نظر می‌گیرند. همچنین اتصال کامل از لایه پنهان قبلی به لایه ورودی فعلی وجود دارد که درصدی از ورودی فعلی را از روی نمونه‌های قبلی تخمین می‌زند [۶۱-۶۲].

۱.۳. معادلات شبکه عصبی بازگشتی

سیگنال مربوط به نرون‌های شبکه عصبی بازگشتی مطابق با معادله (۱) است:

$$\tau_i \dot{y}_i = \sigma \left(b_i + \sum_j W_{ij} y_j + \sum_j W_{ij}^{IN} I_j \right), i = 1, \dots, n \quad (1)$$

G_1 نخستین ژن کروموزوم G است و ماکزیمم مقدار نرون‌ها M_n است. M_n در حین فرایند آموزش ثابت است. گام زمان Δt از رابطه (۸) محاسبه می‌شود:

$$\Delta t = |G_2| \quad (8)$$

مقدار $|G_2| \geq 0.001$ است. τ_i برابر است با:

$$\tau_i = |G_j| \quad (9)$$

در آن $|G_j|$ بزرگ‌تر از 0.01 است یا به بیان دیگر τ_i روی 0.01 تنظیم می‌شود.

$$\beta_i = C_s (G_j + 1) \quad (10)$$

C_s در اینجا ۲ در نظر گرفته شده است. بنابراین β در بازه $[0.2C_s]$ است. b_i مطابق با رابطه (۱۱) است:

$$b_i = C_i G_j \quad (11)$$

در این رابطه، C_i ثابتی با مقدار ۲ در نظر گرفته شده است. مطابق با روابط بالا وزن‌ها بین $[-2]$ و $[2]$ است.

پس از تولید نسل، به منظور انتخاب نسل از بازی انتخاب استفاده می‌شود، یک تعداد، n_t افراد مختلف به طور تصادفی از میان جمعیت انتخاب می‌شوند که n_t برابر است با:

$$n_t = \max(2, 0.15n_{ind}) \quad (12)$$

n_{ind} سایز جمعیت است. نرخ جهش برای هر فرد مطابق با رابطه (۱۳) است:

$$p_{mut} = \frac{10}{N_G} \quad (13)$$

N_G تعداد ژن استفاده شده در ساختار RNN است. مطابق با شکل (۲) از دو نوع جهش استفاده می‌شود. در نوع کامل به طور تصادفی یک واحد ورودی یا یک نرون انتخاب می‌شود. یکی از ژن‌ها به طور تصادفی انتخاب شده و سپس جهش اتفاق می‌افتد. در نوع کامل جهش مقدار جدید که ژن جهش یافته در بازه $[-1]$ و $[1]$ به طور تصادفی انتخاب می‌شود. در نوع خیزشی، فقط یک ژن در کروموزوم جهش می‌کند. نوع جهش خیزشی به صورت (۱۴) محاسبه می‌شود:

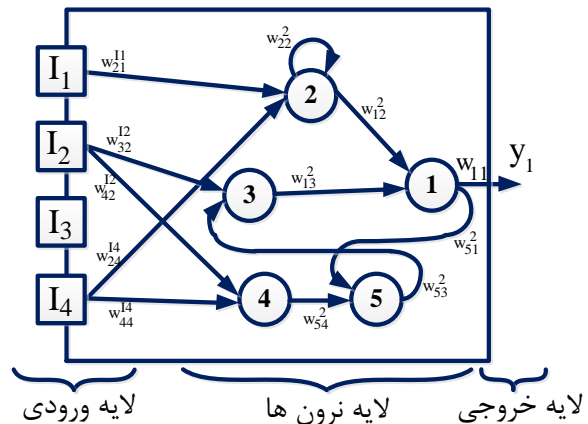
$$G_{new} = G_{old} (1 - 2rc + c) \quad (14)$$

در این رابطه، G ژن است و r شماره تصادفی بین بازه $[0]$ و $[1]$ و c ثابت نرخ خیزش است که معمولاً 0.5 است. گام زمانی جهش مطابق با رابطه (۱۵) است:

$$\Delta t_{new} = \frac{1}{\frac{1}{\Delta t_{old}} \pm 1} \quad (15)$$

جهش ساختاری نیز قابل استفاده است، نرخ جهش به صورت تجربی تعیین می‌شود. با نرخ 0.3 p_{mut} شبکه یک جهش ساختاری کاهشی را انجام می‌دهد (کاهش یک نرون) و با نرخ 0.1 p_{mut} شبکه

است [۱۷-۱۸]. در فرایند تکثیر، کروموزوم‌هایی با شایستگی بالا شانس تکرار بیشتر در جمعیت منتخب را پیدا می‌کنند که این کار توسط فرایند انتخاب صورت می‌پذیرد. پس از تکمیل فرایند انتخاب، نوبت به اعمال پیوند به منظور تولید جمعیت فرزندان می‌رسد. در انجام فرایند پیوند، با انتخاب مقدار ثابت نرخ پیوند، به ترتیب برای هر کروموزوم یک عدد تصادفی تولید می‌شود.



شکل (۱): ساختار شبکه RNN

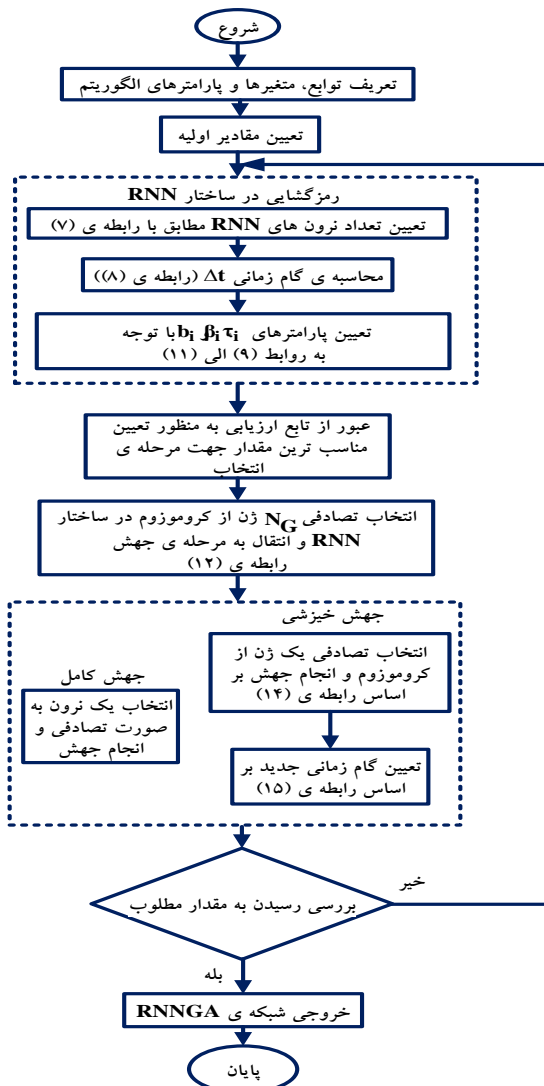
اگر عدد تصادفی تولید شده از نرخ پیوند کمتر باشد، این کروموزوم انتخاب می‌شود تا با کروموزوم‌های بعدی که شرایط فوق را دارد، آمیزش نماید. در انجام فرایند جهش، با انتخاب مقدار ثابت نرخ جهش، برای همه بیت‌های کروموزوم‌های جمعیت عدد تصادفی تولید می‌شود. اگر عدد تصادفی تولید شده از نرخ جهش کوچک‌تر باشد، مقدار آن بیت عوض می‌شود، یعنی مقدار صفر به یک یا بالعکس تبدیل می‌شود. هنگامی که برخی ضوابط مانند تعداد معینی تولید نسل یا میانگین انحراف معیار عملکرد اشخاص جمعیت تأمین شود، الگوریتم ژنتیک به پایان می‌رسد. در این مقاله از الگوریتم ژنتیک بهبود یافته استفاده شده، به طوری که تفاوت اصلی در مقایسه با GA استاندارد این است که در آن هیچ پیوندی وجود ندارد، جهش‌های ساختاری به آن اضافه می‌شوند و نرخ جهش با اندازه شبکه کدگذاری شده در کروموزوم‌ها متفاوت است. در این مقاله، ژنوم تنها از یک کروموزوم تشکیل شده، ولی تعداد ژن‌ها در یک کروموزوم و تعداد نرون‌های شکل دهنده RNN ممکن است متفاوت باشد. ساختار کلی روش RNNGA در شکل (۲) آمده است. کروموزوم‌ها که متشکل از ژن‌ها هستند با مقدار واقعی بین $[-1]$ و $[1]$ نشان داده می‌شوند. تعداد نرون‌ها در RNN مطابق با رابطه (۷) است:

$$n = |G_1| M_n \quad (7)$$

1. Crossover

۷ پیشگویی گام - بلند سرعت باد مبتنی بر مدل ترکیبی RNNGA

داده به‌عنوان نماینده آن روز استخراج و استفاده می‌شود، اطلاعات استخراج شده برای پیشگویی گام بلند (روز) است. از حدود ۱/۳ (۱۲۰ روز) اطلاعات برای تست استفاده می‌شود. در شکل (۴) داده‌های مورد استفاده نشان داده شده است. حداکثر سرعت باد به ۲۸/۵ متر بر ثانیه می‌رسد و حداقل این اطلاعات به نزدیک صفر متر بر ثانیه است. میانگین سرعت باد در طول ۱۲ ماه تقریباً ۶/۸ متر بر ثانیه است.



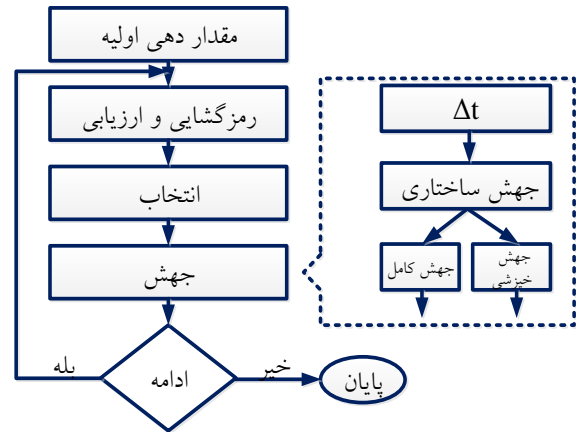
شکل (۴): فلوچارت الگوریتم RNNGA

۲.۴. معیارهای سنجش

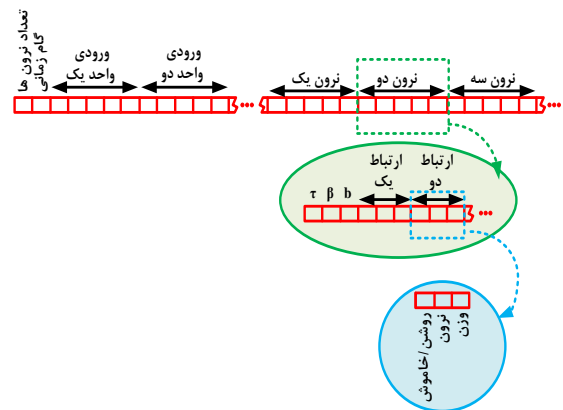
برای سنجش عملکرد مدل از معیارهای مختلفی استفاده می‌شود. این معیارها باعث می‌شود که به‌طور عددی، عملکرد روش مورد تحلیل قرار گیرد و قابل مقایسه با روش‌های دیگر باشد. دو معیار اصلی، جذر میانگین مربعات خطا و ضریب تعیین است [۱۱ و ۱۲]:

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

خود را با افزودن یک نرون گسترش می‌دهد. بهترین فرد در هر تولید نسل به‌عنوان تولید بعدی بدون تغییر کمی می‌شود. این مورد بالاترین شایستگی را تضمین می‌کند. شکل (۳) شرح روش RNN در کدگشایی کروموزوم‌ها را نشان می‌دهد. فلوچارت الگوریتم مورد نظر در شکل (۴) آمده است.



شکل (۲): ساختار کلی روش RNNGA



شکل (۳): شرح روش RNN در کدگشایی کروموزوم‌ها

۴. شبیه‌سازی و آزمایشات

۱.۴. اطلاعات

به‌منظور سنجش مدل RNNGA تشریح شده از داده متشکل از ۳۶۵ روز اطلاعات از تاریخ ۱۳۹۲/۱۲/۱۰ تا تاریخ ۱۳۹۳/۱۲/۹ سرعت باد استفاده شد. اطلاعات به دو دسته آموزش و تست تقسیم می‌شوند. داده‌های تست به‌منظور سنجش عملکرد مدل است. به‌منظور رسیدن به اطلاعات مناسب، نمونه‌برداری به‌طور پیوسته و با نرخ ۵ دقیقه‌ای انجام شده است. اطلاعات در هر روز میانگین‌گیری شده است. به‌طور کلی اطلاعات شامل ۱۷۵۲۰ نمونه و هر ساعت شامل ۱۲ نمونه است، ۲۴ ساعت (یک روز) ۲۸۸ داده است که با میانگین‌گیری از آن، یک

تناوب دقت کاهش پیدا کرده است، در واقع جذر میانگین مربعات خطا بزرگتر، و ضریب تعیین به ۱ نزدیک شده است. در این جدول، دو مدل RNN و RNNGA با یکدیگر مقایسه شده‌اند. نتایج حکایت از برتری قاطع مدل RNNGA دارد. در شکل (۷) گراف مقادیر واقعی و مقادیر پیشگویی شده با گام زمانی ۱ روز نشان داده شده است. رنگ آبی گراف مقادیر پیشگویی شده و رنگ قرمز گراف مقادیر واقعی است. در این شکل مشخص است که مدل RNNGA به خوبی پیشگویی لازم را با دقت فراوانی انجام داده است. در شکل (۸)، گراف مقادیر واقعی و پیشگویی شده با گام زمانی ۳ روز نشان داده شده است. همچنین شکل (۹) گراف مقادیر واقعی و پیشگویی شده با گام ۷ روز به جلو است. ملاحظه می‌شود در این شکل عملکرد مدل با توجه به افزایش گام کاسته شده است.

۴.۴. مقایسه با روش‌های دیگر

با توجه به هدف مقاله که پیشگویی گام بلند و قابل کاربرد در واحد CMS است، نتایج روش‌های مقالاتی که در این حوزه بودند، با روش پیشنهادی مقایسه شدند. گام زمانی مشترک همه روش‌ها ۱ روز است. جدول (۴) این مقایسه را نشان می‌دهد. این مقایسه به ترتیب با مراجع [۱۶]، [۴۸] و [۵۵] و براساس معیار RMSE است.

$$COD = 1 - \frac{\sigma_{yx}^2}{\sigma_y^2} \quad (17)$$

$$\sigma_y = \sqrt{\frac{\sum_{i=1}^N (y_i - y_m)^2}{N-1}} \quad (18)$$

$$\sigma_{y,x} = \sqrt{\frac{\sum_{i=1}^N (y_i - y_{ip})^2}{N-2}} \quad (19)$$

در روابط بالا N تعداد نمونه‌ها، y_i اطلاعات واقعی، y_{ip} اطلاعات پیشگویی و y_m میانگین اطلاعات y_i است. معیار RMSE خطای مطلق بین مقادیر واقع و مقادیر پیشگویی شده است. کمتر بودن این پارامتر به معنی تقریب خوب سرعت باد است. معیار ضریب تعیین مشخص می‌کند که گراف مدل چه مقدار از گراف واقعی فاصله دارد. این مقدار بین ۰ و ۱ است، ۰ به معنی بسیار ضعیف بودن و ۱ به معنی بسیار عالی بودن آن است.

۳.۴. نتایج

در اشکال (۵) و (۶) گراف مقادیر استفاده شده برای تست و آموزش RNN پیش‌پردازش نشان داده شده است. جدول (۳) معیارهای مختلف سنجش نتایج مدل پیشگویی RNNGA را نشان می‌دهد. در این جدول مشخص است که با افزایش گام زمانی از ۱ تا ۷ روز به

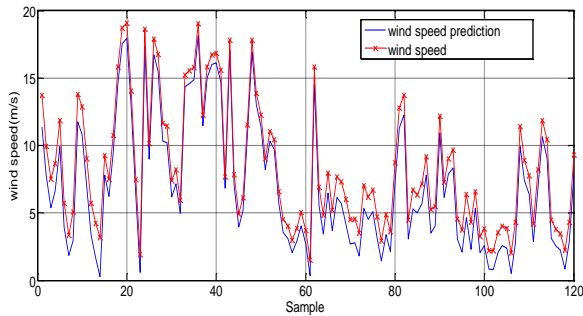
جدول (۳): نتیجه معیارهای سنجش دو مدل RNN و RNNGA (گام روز)

معیار	RNN/RNNGA	گام ۱	گام ۲	گام ۳	گام ۴	گام ۵	گام ۶	گام ۷
ماکزیمم	RNN	۲/۴	۲/۹۸	۳/۲۱	۳/۶۳	۳/۷۸	۴/۰۱	۴/۱۲
	RNNGA	۰/۹	۱/۱	۱/۳	۱/۴	۱/۷۱	۱/۸	۲/۲۱
مینیمم	RNN	۰	۰	۰	۰/۱۲	۰/۱۲	۰/۲۳	۰/۳۷
	RNNGA	۰	۰	۰	۰/۰۶	۰/۱	۰/۱۶	۰/۲۳
واریانس	RNN	۱/۴۶	۱/۶۳	۱/۶۳	۱/۷۰	۱/۸۱	۱/۸۹	۲/۲۳
	RNNGA	۰/۹۸	۱/۱۱	۱/۱۱	۱/۲۱	۱/۳۱	۱/۳۸	۱/۵۹
میانگین	RNN	۱/۳۶	۱/۵۶	۱/۵۶	۱/۶۳	۱/۷۳	۱/۹۱	۲/۰۱
	RNNGA	۰/۶۶	۰/۷۱	۰/۷۱	۰/۷۸	۰/۸۳	۰/۹۳	۱/۱۱
ج.م.خ*	RNN	۱/۶۷	۱/۸۷	۱/۸۷	۱/۹۳	۲/۰۳	۲/۲۶	۲/۷۸
	RNNGA	۰/۹۶	۱/۰۹	۱/۰۹	۱/۱۸	۱/۳۲	۱/۵۱	۱/۷۳
ضریب تعیین	RNN	۰/۷۸	۰/۶۵	۰/۶۱	۰/۵۸	۰/۵۳	۰/۴۶	۰/۳۹
	RNNGA	۱/۹۰	۱/۸۶	۰/۸۰	۰/۷۸	۰/۷۲	۰/۶۶	۰/۵۴

* جذر میانگین مربعات خطا

SVM و AR می‌شود. مطابق با مرجع [۴۸] عملکرد مدل RNNGA در مقایسه با NN و AR بهتر است، از طرفی این عملکرد با داده آموزشی کمتر حاصل شده که یک حسن برای RNNGA است،

دلیل انتخاب این سه مرجع به سبب آن است که اولاً پیشگویی براساس اطلاعات ورودی روزانه (با گام زمانی ۱ روز) باشد، از طرفی دیگر شامل روش‌های داده‌کاوی و آماری قدرتمند از جمله NN،



شکل (۹): گراف مقادیر پیشگویی شده برای ۱۰۰ روز (گام: ۷ روز)

همان‌طور که از جدول (۴) مشخص است، روش پیشنهادی در مقایسه با سایر روش‌ها عملکرد تقریباً برابر یا بهتر داشته است.


جدول (۴): مقایسه روش RNNGA با روش‌های دیگر

RMSE	عنوان روش	گام زمانی	سال	شماره مرجع
۱/۲۴	NN	۱	۱۹۹۸	[۴۸]
۱/۳۷	AR	۱		
۱/۷۲	SVM	۱	۲۰۰۴	[۵۵]
۱/۷۶	NN-MLP	۱		
۱/۹۹	Multiple Linear Regression	۱	۲۰۰۱	[۱۶]
۱/۷۳	ANN- Multi-Layer Perceptron (MLP)	۱		
۱/۷۹	ANN- Radial Basis Functions (RBF)	۱		
۱/۷۰	SVM	۱		
۱/۶۸	multiple architecture system (MAS)	۱		
۰/۹۶	RNNGA	۱	۲۰۱۵	روش این مقاله


۵. نتیجه‌گیری

برای پیشگویی سرعت باد از یک ساختار جدید شبکه عصبی بازگشتی در این مقاله استفاده شد. الگوریتم ژنتیک به خوبی عملکرد مدل RNN را بهبود داده است و این مهم در مقایسه با مراجع دیگر مشخص شد. استفاده از GA موجب کاهش زمان محاسباتی در مقایسه با RNN تنها شده و از طرفی دقت مدل پیشگویی را زیاد کرده است. برای سنجش مدل از معیارهای ضریب تعیین و جذر میانگین مربعات خطا استفاده شد. بررسی نتایج مدل RNNGA با توجه به اطلاعات ورودی دریافتی از سایت بادی کهک مپنا شامل نتایج کلی زیر بود:
الف. مدل RNNGA در مقایسه با RNN متداول عملکرد بهتری دارد و قابلیت اطمینان بهتری را برای استفاده از نتایج پیشگویی ایجاد می‌کند.

به‌گونه‌ای که برای NN ۷۳۰ داده برای آموزش استفاده شده، درحالی‌که برای RNNGA این تعداد ۴۹۰ است.

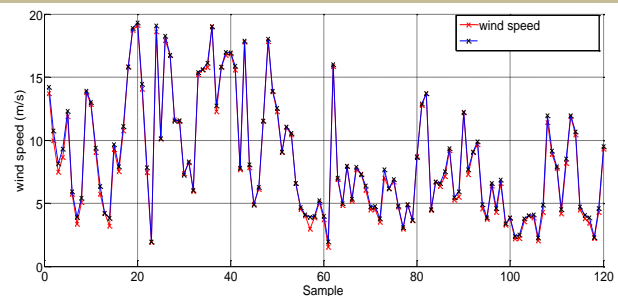


شکل (۵): گراف مقادیر واقعی سرعت باد




شکل (۶): گراف مقادیر واقعی باد (داده تست و آموزش پس از

پیش‌پردازش)



شکل (۷): گراف مقادیر پیشگویی شده برای ۱۰۰ روز (گام: ۱ روز)



شکل (۸): گراف مقادیر پیشگویی شده برای ۱۰۰ روز (گام: ۳ روز)

اتفاقات ناگهانی و آسیب به توربین بادی جلوگیری کرده و سلامت توربین تضمین شود. این امر خاموشی توربین را کاهش داده و موجب کاهش هزینه و افزایش توان تولیدی می‌شود.

ب. مدل RNNGA با داده ورودی کمتر نتایج مشابه یا برتر از روش‌های مطرح‌شده در مقالات داشته است.

ج. عملکرد خوب این روش در پیشگویی با گام بلند، چشم‌انداز روشنی برای واحد CMS خواهد بود تا با استفاده از آن از بروز

مراجع

- [1] Blaabjerg, F., Marco, L., and Ke, M., "Power Electronics Converters for Wind Turbine Systems", IEEE Transactions on Industry Applications, Vol. 48, No. 2, pp. 708-719, 2012.
- [2] Master, G. M., "Renewable and Efficient Electric Power Systems", John Wiley & Sons Inc., 2004.
- [3] Leung, D., Yang, Y., "Wind Energy Development and its Environmental Impact: a Review", Renew Sustain Energy Rev, Vol. 16, No. 1, pp. 1031-1039, 2012.
- [4] Blaabjerg, F., and Ke, M., "Future on Power Electronics for Wind Turbine Systems", IEEE Journal of Emerging and Selected Topics in Power Electronics, Vol. 1, No. 3, pp. 139-152, 2013.
- [5] Ranky, P., An Introduction to windmill and Wind Turbine Design and Manufacturing Processes, 2011.
- [6] Nehrir, M. H., et al. "A review of hybrid renewable/alternative energy systems for electric power generation: configurations, control, and applications", IEEE Transactions on Sustainable Energy; Vol. 2, No. 4, pp. 392-403, 2011.
- [7] Erich, H., "Wind Energy with Fundamentals", Technologies, Applications, and Economics, Springer, 2005.
- [8] Shafiullah, G. M., et al., "Potential Challenges of Integrating Large-Scale wind Energy into the Power Grid-A Review", Energy Reviews Renewable and Sustainable, Vol. 20, No. 2, pp. 306-321, 2013.
- [9] Mazharul, I., Ting, D. and Fartaj, A., "Aerodynamic Models for Darrieus-Type Straight-Bladed Vertical Axis wind Turbines", Renewable and Sustainable Energy Reviews, Vol. 12, No. 4, pp. 1087-1109, 2008.
- [10] Kusiak, A., Zhang, Z., "Short-Horizon Prediction of Wind Power: a Data-Driven Approach", IEEE Transactions on Energy Conversion, Vol. 25, No. 4, pp. 1112-1122, 2010.
- [11] Riah, GH., Abedi, M., "Short Term Wind Speed Forecasting for Wind Turbine Applications Using Linear Prediction Method", Renewable Energy, Vol. 33, No. 1, pp. 35-41, 2008.
- [12] Bossanyi, EA., "Short-term Wind Prediction Using Kalman Filters," Wind Engineering, Vol. 9, No. 1, pp. 1-8, 1985.
- [13] Nitin, K., Joshi, A. and Sudhakar, K., Multivariable Control Strategy for Large Scale Wind Turbine, 2008.
- [14] Ackermann, T., "Wind Power in Power Systems", Chichester, UK: John Wiley, Vol. 140, 2005.
- [15] Rebecca, J., Kurt, S., and Pryor, S., "Meteorological Controls on Wind Turbine Wake", Proceedings of the IEEE; Vol. 101, No. 4, pp. 1010-1019, 2013.
- [16] Bouzgou, H, Benoudjit, N, "Multiple Architecture System for Wind Speed Prediction", Applied Energy, Vol. 88, No. 7, pp. 2463-2471, 2011.
- [17] Refan, M.H., Dameshghi, A. and Kamarzarin, M., "Improving RTDGPS Accuracy Using Hybrid PSOSVM Prediction Model", Aerospace Science and Technology Vol. 37, pp. 55-69, 2014.
- [18] Refan, M. H., Dameshghi, A. and Kamarzarin, M., "Real Time Pseudo-Range Correction Predicting by a Hybrid GASVM Model in order to Improve RTDGPS Accuracy", Iranian Journal of Electrical & Electronic Engineering, Vol. 9, No. 4, pp. 12-18, 2013.
- [19] Refan, M. H., Dameshghi, A. and Kamarzarin, M., "Utilizing Hybrid Recurrent Neural Network and Genetic Algorithm for Predicting the Pseudo-Range Correction Factors to Improve the Accuracy of RTDGPS," Gyroscope and Navigation, Vol. 6, No. 30, pp. 197-206, 2015.
- [20] Jones, RH., "Maximum Likelihood Fitting of ARMA Models to Time Series with Missing Observations", Technometrics, Vol. 22, No. 3, pp. 389-395, 1980.
- [21] Gardner, G., Harvey, AC., Phillips GDA., "Algorithm AS154: an Algorithm for Exact Maximum Likelihood Estimation of Autoregressive-Moving Average Models by Means of Kalman Filtering", Applied Statistics, Vol. 29, No. 3, pp. 311-322, 1980.
- [22] Brockwell, PJ., Davis, RA., Introduction to Time Series and Forecasting. New York: Springer; 1996.
- [23] Brown, BG, Katz, RW, Murphy, AH., "Time Series Models to Simulate and Forecast Wind Speed and Wind Power", Journal of Climate and Applied Meteorology; Vol. 23, No. 8, pp. 1184-1195, 1984.
- [24] Box, G., Jenkins, GM., Reinsel, G., Time Series Analysis: Forecasting and Control. 3rd ed. Prentice Hall; 1994.
- [25] Huang, Z., Chalabi, ZS., "Use of Time-Series Analysis to Model and Forecast Wind Speed. Journal of Wind Engineering and Industrial Aerodynamics", Vol. 56, No. 3, pp. 311-322, 1995.
- [26] Kamal, L., Jafri, YZ., "Time Series Models to Simulate and Forecast Hourly Averaged Wind Speed in Quetta, Pakistan", Solar Energy, Vol. 61, No. 1, pp. 23-32, 1997.
- [27] Erdem, E., Shi, J., "ARMA Based Approaches for Forecasting the Tuple of Wind Speed and Direction", Applied Energy, Vol. 88, No. 4, pp. 1405-1414, 2011.
- [28] Jeon, J., Taylor, JW., "Using Conditional Kernel Density Estimation for Wind Power Density Forecasting", Journal of the American Statistical Association, Vol. 107, No. 497, pp. 66-79, 2012.
- [29] Torres, JT., Garcia, A., De Blas, M., De Francisco, A., "Forecast of Hourly Average Wind Speed with ARMA Models in Navarre (Spain)", Solar Energy, Vol. 70, No. 1, pp. 65-77, 2005.
- [30] Zhao, P., Wang J., Xia, J., Dai, Y., Sheng, Y., Yue, J., "Performance Evaluation and Accuracy Enhancement of

- a Day-Ahead Wind Power Forecasting System in China*, Renewable Energy, Vol. 43, pp. 234-241, 2012.
- [31] Khalid, M., Savkin, AV., "A Method for Short-Term Wind Power Prediction with Multiple Observation Points", IEEE Transactions on Power Systems; Vol. 27, No. 2, pp. 579-586, 2012.
- [32] Bhaskar, K., Singh, SN., "AWNN-Assisted Wind Power Forecasting Using Feed-Forward Neural Network. IEEE Transactions on Sustainable Energy", Vol. 3, No. 2, pp. 306-15, 2012.
- [33] Salonen, K., Niemela, S., Fortelius, C., "Application of Radar Wind Observations for Low-Level NWP Wind Forecast Validation", Journal of Applied Meteorology and Climatology, Vol. 50, No. 6, pp. 1362-1371, 2011.
- [34] Friedman, JH., "Stochastic Gradient Boosting. Computational Statistics and Data Analysis", Vol. 38, No. 4, pp. 367-378, 2002.
- [35] Friedman, JH., "Greedy Function Approximation: a Gradient Boosting Machine", Annals of Statistics, Vol. 29, No. 5, pp. 1189-1232, 2001.
- [36] Breiman, L., "Random Forests", Machine Learning, Vol. 45, No. 1, pp. 5-32, 2001.
- [37] Breiman, L., Friedman, JH., Olshen, RA., Stone, CJ. Classification and Regression Trees. Monterey, CA: Wadsworth & Brooks/Cole; 1984.
- [38] Shakhnarovich, G., Darrell, T., Indyk, P. Nearest-Neighbor Methods in Learning and Vision. Cambridge, MA: The MIT Press, 2005.
- [39] Schölkopf, B., Burges, CJC., Smola, AJ., "Advances in Kernel Methods: Support Vector Learning", Cambridge, MA: The MIT Press, 1999.
- [40] Steinwart, I., Christmann, A., "Support Vector Machines", New York: Springer-Verlag, 2008.
- [41] Siegelmann, H., Sontag, E., "Analog Computation Via Neural Networks", Theoretical Computer Science, Vol. 131, No. 2, pp. 331-360, 1994.
- [42] Liu, GP., "Nonlinear Identification and Control: a Neural Network Approach", London, UK: Springer, 2001.
- [43] Smith, M., "Neural Networks for Statistical Modeling", New York: Van Nostrand Reinhold, 1993.
- [44] Hansen, LK., Salamon, P., "Neural Network Ensembles", IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 12, No. 10, pp. 993-1001, 1990.
- [45] Kusiak, A., Li, W., "Estimation of Wind Speed: a Data-Driven Approach", Journal of Wind Engineering and Industrial Aerodynamics, Vol. 98, No. 10-11, pp. 559-567, 2010.
- [46] Kusiak, A., Zheng, HY., Zhang, Z., "A Wind Speed Virtual Sensor for Wind Turbines", ASCE Journal of Energy Engineering, Vol. 137, No. 2, pp. 60-69, 2011.
- [47] Barbounis, TG., Theocharis, JB., "Locally Recurrent Neural Networks for Wind Speed Prediction Using Spatial Correlation", Information Sciences, Vol. 177, No. 24, pp. 5775-5797, 2007.
- [48] Mohandes, MA., Rehman, S., Halawani, TO., "A Neural Networks Approach for Wind Speed Prediction", Renewable Energy, Vol. 13, No. 3, pp. 345-354, 1998.
- [49] Bilgili, M., Sahin, B., Yasar, A., "Application of Artificial Neural Networks for the Wind Speed Prediction of Target Station Using Reference Stations Data", Renewable Energy, Vol. 32, No. 14, pp. 2350-2360, 2007.
- [50] Poitras, G., Cormier, G., "Wind Speed Prediction for a Target Station Using Neural Networks and Particle Swarm Optimization", Wind Engineering, Vol. 35, No. 3, pp. 369-380, 2011.
- [51] Kennedy, J., Eberhart, RC., "Particle Swarm Optimization", In: IEEE International Conference on Neural Networks, pp. 1942-81995.
- [52] Cortes, C., Vapnik, V., "Support-vector Networks", Machine Learning, Vol. 20, No. 3, pp. 273-297, 1995.
- [53] Drucker, H., Burges, CJC., Kaufman, L., Smola, A., Vapnik V., "Support Vector Regression Machines", In: Advances in Neural Information Processing Systems, Vol. 9., pp. 155-161, 1997.
- [54] Salcedo-Sanz, S., Ortiz-Garcia, EG., Perez-Bellido, AM., Portilla-Figueras, A., Prieto, L., "Short Term Wind Speed Prediction based on Support Vector Regression Algorithms", Expert Systems with Applications, Vol. 38, No. 4, pp. 4052-4057, 2011.
- [55] Mohandes, MA., Halawani, TO., Rehman, S., Hussain, AA., "Support Vector Machines for Wind Speed Prediction", Renewable Energy, Vol. 29, No. 6, pp. 939-947, 2004.
- [56] Ortiz-Garcia, EG., Salcedo-Sanz, S., Perez-Bellido, AM., Gascon-Moreno, J., Portilla-Figueras, JA., Prieto, L., "Short-term Wind Speed Prediction in Wind Farms based on Banks of Support Vector Machines", Wind Energy, Vol. 14, No. 2, pp. 193-207, 2011.
- [57] Monfared, M., Rastegar, H., Kojabadi, HM., "A New Strategy for Wind Speed Forecasting Using Artificial Intelligent Methods", Renewable Energy, Vol. 34, No. 3, pp. 845-848, 2009.
- [58] Salcedo-Sanz, S., Perez-Bellido, AM., Ortiz-Garcia, EG., Portilla-Figueras, A., Prieto, L., Correoso, F., "Accurate Short-Term Wind Speed Prediction by Exploiting Diversity in Input Data Using Banks of Artificial Neural Networks", Neurocomputing, Vol. 72, No. 4e6, pp. 1336-1341, 2009.
- [59] Liu, H., Tian, H., Chen, C., Li, Y., "A Hybrid Statistical Method to Predict Wind Speed and Wind Power", Renewable Energy, Vol. 35, No. 8, pp. 1857-1861, 2010.
- [60] Guo, Z., Zhao, J., Zhang, W., Wang, J., "A Corrected Hybrid Approach for Wind Speed Prediction in Hexi Corridor of China", Energy, Vol. 36, No. 3, pp. 1668-1679, 2011.
- [61] Bod'en, M., A Guide to Recurrent Neural Networks and back Propagation. In In the Dallas project, SICS Technical Report, 2002.
- [62] Graves, A., Schmidhuber, J., "Offline Handwriting Recognition with Multi-Dimensional Recurrent Neural Networks", in Advances in Neural Information Processing Systems, 2009.