

Wind Power Forecasting by a New Hybrid Forecast Engine Composed of GA/EP SO-Based Mutual Information and Group Method of Data Handling (GMDH)

Vahid Vahidinasab, Hossein Sohrabi Vafa

1- Electric Energy Systems Planning and Operation Group, Department of Electrical Engineering, Abbaspour School of Engineering, Shahid Beheshti University, Tehran, Iran

2- Abbaspour School of Engineering, Shahid Beheshti University, Tehran, Iran

Abstract

The proper forecasting of the intermittent wind power for optimal power systems operation is a really tough and complicated issue. In this paper, a successful method is proposed for predicting the wind power productions which is based on the self-organized neural networks called Group Method of Data Handling (GMDH). By analyzing and discovering the hidden relationships between the inputs, the GMDH-based neural network intelligently presents the optimal model and predicts the output variable. Patterns used in this study are based on the two methods of artificial intelligence and information theory. At first, the effective variables are selected based on Mutual Information (MI) technique and the mixed particle swarm and genetic algorithm and after that the proposed forecast engine is used. In contrast to the mutual correlation method, in the proposed cross-entropy-based approach of this paper, non-linear relations between the variables are considered and the selection of effective variables in the forecasting of wind power in which nonlinear fluctuations and trends are observed are chosen more precisely and more accurately. In order to evaluate the ability, speed and accuracy of the proposed framework, real-world data of Sotavento wind farm in the Spain were used. The results of the study indicate that the proposed technique has a higher speed and accuracy than other methods.

Keywords: Wind Power Forecasting, Artificial Neural Networks, GMDH, Mutual Information, Intelligent Systems.

پیش‌بینی توان تولیدی واحدهای بادی با استفاده از یک موتور پیش‌بینی

ترکیبی بر مبنای آنالیز اطلاعات متقابل و شبکه عصبی GMDH

وحید وحیدی‌نسب^۱، حسین سهرابی‌وفا^۲

۱- استادیار، گروه برنامه‌ریزی و بهره‌برداری سیستم‌های انرژی الکتریکی، دانشکده مهندسی برق، پردیس فنی

و مهندسی شهید عباسپور، دانشگاه شهید بهشتی، تهران، ایران

v_vahidinasab@sbu.ac.ir

۲- کارشناس ارشد، دانشکده مدیریت و اقتصاد، پردیس فنی و مهندسی شهید عباسپور، دانشگاه شهید

بهشتی، تهران، ایران

sohrabivafa@gmail.com

چکیده: تخمین مناسب میزان تولید پرنوسان واحدهای بادی برای استفاده بهینه در سیستم‌های قدرت، امری دشوار و تابع پیچیدگی‌های بسیار است. در این مقاله روشی موفق برای پیش‌بینی توان تولیدی واحدهای بادی با استفاده از شبکه عصبی خودسازمانده موسوم به GMDH ارائه شده است. در شبکه عصبی GMDH، متغیرهایی که بر سری زمانی تأثیر می‌گذارند، به‌عنوان ورودی شبکه استفاده می‌شوند. این شبکه با بررسی و کشف روابط بین ورودی‌ها، به‌طور هوشمند مدل بهینه‌ای را ارائه و متغیر خروجی را پیش‌بینی می‌کند. الگوسازی‌های به‌کاررفته در این مطالعه مبتنی بر دو روش هوش مصنوعی و نظریه اطلاعات است. در ابتدا متغیرهای مؤثر بر اساس اطلاعات متقابل (MI) و با الگوریتم ترکیبی انبوه ذرات و ژنتیک، انتخاب و سپس در موتور پیش‌بینی به کار گرفته می‌شوند. برخلاف روش همبستگی متقابل، در رویکرد مبتنی بر آنالیز متقابل استفاده‌شده در این مقاله، روابط غیرخطی میان متغیرها در نظر گرفته می‌شوند و انتخاب متغیرهای مؤثر در پیش‌بینی انرژی بادی که در آن، نوسانات و روند غیرخطی شدیدی مشاهده می‌شود، با دقت و اعتبار بیشتری انتخاب می‌شود. برای ارزیابی توانایی، سرعت و دقت چارچوب پیشنهادی، از داده‌های واقعی مزرعه بادی سوتاونتو کشور اسپانیا استفاده شده است. نتایج مطالعه نشان می‌دهند تکنیک پیشنهادی سرعت و دقت بیشتری در مقایسه با سایر روش‌ها دارد.

واژه‌های کلیدی: پیش‌بینی توان تولیدی واحدهای بادی، شبکه‌های عصبی مصنوعی، شبکه عصبی GMDH، آنالیز متقابل، سیستم‌های هوشمند.

۱- مقدمه

بهره‌برداری سیستم‌های قدرت را موجب می‌شود؛ بنابراین، اطلاع از میزان تولید واحدهای بادی، عامل بسیار مهمی در بهبود تصمیم‌گیری خواهد شد؛ اما از سوی دیگر، با توجه به نیاز فزاینده به منابع انرژی در اثر اجرای سیاست‌های توسعه اقتصادی و افزایش جمعیت جهانی و نیز کم‌یابی منابع سوخت‌های فسیلی و خطرات زیست محیطی ناشی از این سوخت‌ها، اهمیت توجه به سیاست‌گذاری و مدیریت انرژی را دوچندان می‌کند [۱]. در این زمینه رویکردهای مختلفی همچون کاهش مصرف انرژی با اجرای

افزایش روزافزون نفوذ واحدهای بادی در سیستم‌های قدرت، تغییرات اساسی در تصمیمات برنامه‌ریزی و

^۱ تاریخ ارسال مقاله: ۱۳۹۳/۰۵/۰۴

تاریخ پذیرش مقاله: ۱۳۹۷/۰۴/۱۹

نام نویسنده مسئول: وحید وحیدی‌نسب

نشانی نویسنده مسئول: ایران - تهران - دانشگاه شهید بهشتی - پردیس فنی و مهندسی شهید عباسپور - دانشکده مهندسی برق

پیش‌بینی دقیق انرژی بادی در مزارع بادی روزبه‌روز در حال افزایش است [۶]. در این بین، پیش‌بینی کوتاه‌مدت انرژی بادی برای کاهش هزینه‌های مقادیر رزرو شده (به منظور قابلیت اطمینان سیستم) و افزایش درآمد ژنراتورهای بادی (با ارائه پیشنهادات بهینه در بازار برق) اهمیت فراوانی دارند.

مطالعات مختلف نتایج مطلوبی از پیش‌بینی انرژی بادی با استفاده از تکنیک‌های سری‌زمانی ارائه می‌کنند. تکنیک‌های خانواده ARIMA یکی از رویکردهای پرکاربرد در این میان است [۷] و [۸]. این دسته شامل تکنیک‌هایی همچون AR، MA، ARMA، ARIMA و SARIMA است. با وجود توانایی این رویکرد در ارائه فرم تبعی میان ورودی و خروجی، محدود بودن به معادلات خطی از معایب این رویکرد به شمار می‌رود. در مقابل رویکردهای هوش مصنوعی (AI) و یادگیری ماشینی (ML) به دلیل توانایی بیشتر در مدل‌سازی روابط غیرخطی توجه پژوهشگران در زمینه پیش‌بینی انرژی بادی را جلب کرده‌اند. این تکنیک‌ها شامل انواع مختلف شبکه‌های عصبی از جمله BP و RBF [۹] و [۱۰]، SVM [۱۱] و منطق فازی [۱۲] هستند. در زمینه کاربرد تکنیک‌های مختلف در پیش‌بینی انرژی بادی [۱۳] و [۱۴] و [۱۵] و [۱۶] بررسی‌های مفیدی ارائه کرده‌اند. مروری بر نتایج مطالعات مختلف در این زمینه نشان می‌دهند که دلیل روند غیرخطی و پرنوسان انرژی بادی تکنیک‌های غیرخطی به خصوص شبکه‌های عصبی نتایج مطلوبی داشته‌اند.

با وجود این، شبکه‌های عصبی استفاده‌شده در مطالعات مختلف کاستی‌هایی نیز دارند. در رویکرد سنتی پیش از اقدام به آموزش شبکه لازم است ساختار آن از قبل تعیین شده باشد. از سوی دیگر، نتایج بسیار متفاوتی با تغییر در ساختار پارامترهای شبکه از جمله مقادیر وزن‌های اولیه، تعداد لایه‌های پنهان و تعداد نرون‌ها در لایه پنهان در مرحله آموزش شبکه حاصل می‌شوند. همچنین چرخه‌های تکراری زیادی با ساختارهای مختلف لازم است تا ساختار دقیق شبکه مشخص شود؛ از این رو، شبکه عصبی GMDH برای غلبه بر کاستی‌های فوق ارائه شده است.

شبکه عصبی GMDH بر اساس فرآیند خودسازماندهی و ارزیابی داده‌ها به صورت جداگانه با استفاده از معیار خارجی^۳

سیاست‌های صرفه‌جویی انرژی و افزایش کارایی انرژی و همچنین استفاده از منابع انرژی تجدیدپذیر وجود دارند [۲]. فناوری‌های انرژی تجدیدپذیر با وجود مسائلی همچون تناوب در تولید انرژی و هزینه نگهداری زیاد، مزایای فراوانی دارند که رقابت‌پذیری آنها را در مقایسه با رقبای سنتی خود کمتر می‌کند. کاهش وابستگی به منابع سوخت فسیلی، کاهش آلودگی‌های زیست‌محیطی و گازهای گلخانه‌ای و نبود مسائل ایمنی مرتبط با انرژی اتمی [۳] توجیه مناسبی است تا این منابع از دید اجتماعی از اقبال گسترده‌ای برخوردار باشند [۴]. با وجود این، انتخاب نوع فناوری انرژی تجدیدپذیر نیز تصمیم مهمی است؛ به گونه‌ای که برخی پژوهشگران به بررسی و اولویت‌بندی انواع مختلف فناوری تولید انرژی تجدیدپذیر پرداخته‌اند. ایوانز و همکاران [۵] در مطالعه‌ای بر اساس قابلیت پایداری^۱ تکنولوژی‌های عمده تولید انرژی تجدیدپذیر ارزیابی کرده‌اند. ایشان منابعی همچون انرژی بادی، برق‌آبی، فتووالتائی و زمین‌گرایی را بر اساس بهای انرژی تولیدی، انتشار گازهای گلخانه‌ای، سهولت دسترسی، کارایی تبدیل انرژی، مساحت مورد نیاز، مصرف آب و اثرات اجتماعی ارزیابی و مقایسه کرده‌اند. نتایج مطالعه نشان دادند انرژی بادی با وجود نیاز به مساحت و سرمایه زیاد، کمترین میزان آلودگی و مصرف آب و اثرات اجتماعی مطلوبی دارد. بر اساس این، انرژی بادی سهم عمده‌ای در میان انرژی‌های تجدیدپذیر داشته و اخیراً نفوذ چشمگیری در بازار برق کشورهای مختلف داشته است؛ به گونه‌ای که گزارش شورای جهانی انرژی بادی^۲ ظرفیت انرژی بادی از ۱۷/۴ گیگاوات در سال ۲۰۰۰ به ۲۸۲/۵۸۷ گیگاوات در سال ۲۰۱۲ رسیده است. با وجود این، به دلیل وابستگی انرژی بادی به شرایط متغیر و ناپایدار جوی، میزان عرضه آن پرنوسان است؛ به‌ویژه آنکه سرعت باد در تولید انرژی بادی نقش عمده‌ای دارد و ممکن است در طی زمان نوسانات شدیدی داشته باشد؛ از این رو، عرضه‌کنندگان و فعالان حیطه انرژی بادی به پیش‌بینی‌های دقیق در این زمینه بسیار علاقه‌مند بوده‌اند و سعی می‌کنند به کمک ابزار پیش‌بینی مناسب با سایر نیروگاه‌های شبکه هماهنگ شوند و از هزینه‌های تولید مازاد خودداری کنند؛ از این رو، اهمیت

نشانه پیش‌بینی‌پذیری اندک است؛ بنابراین پیامی با پیش‌بینی‌پذیری اندک دارای آنتروپی و «اطلاعات» بسیار است. برعکس، پیامی با پیش‌بینی‌پذیری زیاد، حشو بسیار و «اطلاعات» اندک دارد؛ بنابراین آنتروپی، به تصادفی بودن یا نبود سازمان (نظم) در یک موقعیت گفته می‌شود. هرچه میزان پیش‌بینی در پیام کمتر شود، میزان آنتروپی آن افزایش می‌یابد. بر اساس این، در زمینه پیش‌بینی سری‌های زمانی نیز به کمک نظریه اطلاعات از میان انبوهی از متغیرهای متنوع تنها تعداد محدود و مؤثری از آنها به‌عنوان متغیر توضیحی استفاده می‌شوند. در این زمینه برخی مطالعات به کمک معیار اطلاعات متقابل (MI) به انتخاب ویژگی پرداخته‌اند. سایمون و ورلیسن (۲۰۰۷) به‌منظور انتخاب وقفه بهینه سری زمانی، استفاده از ابزار اطلاعات متقابل را پیشنهاد می‌کنند [۱۸]. همچنین فرانسوا و همکاران (۲۰۰۷) در مطالعه‌ای با ترکیب معیار اطلاعات متقابل و استراتژی انتخاب ویژگی روبه‌جلو^۷ سعی در ارائه راه‌حلی بهینه میان مجموعه ویژگی‌های (متغیرهای) انتخاب‌شده و زمان محاسبه داشتند [۱۹]. می و همکاران (۲۰۰۸) در مطالعه‌ای به‌منظور پیش‌بینی کیفیت آب میان سیستم‌های توزیع آب از معیار اطلاعات متقابل در انتخاب متغیرهای ورودی شبکه عصبی بهره بردند [۲۰]. امجدی و دارایی‌پور (۲۰۰۹) در مطالعه خود به‌منظور پیش‌بینی قیمت‌های آتی در بازار برق با استفاده از شبکه عصبی آبخار از معیار اطلاعات متقابل برای انتخاب متغیرهای ورودی شبکه استفاده کردند [۲۱]. امجدی و کی‌نیا (۲۰۱۱) در مطالعه‌ای دیگر به‌منظور پیش‌بینی قیمت برق با استفاده از شبکه‌های عصبی احتمالی و ترکیبی از معیار اطلاعات متقابل در انتخاب مجموعه متغیرهای مؤثر ورودی شبکه استفاده کردند [۲۲]. امجدی و همکاران (۲۰۱۱) در مطالعه‌ای در زمینه پیش‌بینی انرژی بادی به کمک شبکه عصبی ریجالت از معیار اطلاعات متقابل به‌منظور انتخاب متغیرهای ورودی شبکه بهره بردند [۲۳]. کی‌نیا (۲۰۱۲) در مطالعه‌ای به کمک شبکه عصبی مرکب و معیار اطلاعات متقابل به پیش‌بینی قیمت برق پرداخت. کاظم و همکاران (۲۰۱۳) به‌منظور پیش‌بینی شاخص سهام نزدیک، بانک جهانی و مایکروسافت با استفاده

برای مدل‌سازی‌های پیچیده کاربرد دارد. در این الگوریتم، متغیرهایی تأثیرگذار بر فرآیند به‌عنوان ورودی شبکه استفاده می‌شوند. این الگوریتم با بررسی و کشف روابط بین آنها و آزمون مدل‌های پیشنهادی به‌طور هوشمند، مدل بهینه‌ای را ارائه و متغیر خروجی را پیش‌بینی می‌کند. بر اساس این، الگوسازی‌های به‌کاررفته در این مطالعه مبتنی بر دو روش هوش مصنوعی و نظریه اطلاعات است؛ به گونه‌ای که در الگوریتم پیشنهادی ابتدا متغیرهای مؤثر بر اساس اطلاعات متقابل (MI) و به کمک الگوریتم ترکیبی انبوه‌ذرات و ژنتیک (PSO-GA)، انتخاب و سپس در موتور پیش‌بینی به کار گرفته می‌شوند. برخلاف روش ارتباط متقابل^۸ در رویکرد استفاده‌شده، (Cross entropy) روابط غیرخطی میان متغیرها در نظر گرفته می‌شود و انتخاب متغیرهای مؤثر در پیش‌بینی انرژی بادی که در آن نوسانات و روند غیرخطی مشاهده می‌شود، با دقت و اعتبار بیشتری انتخاب می‌شود. در ادامه ابتدا به تشریح روش انتخاب متغیرهای مؤثر و تکنیک شبکه عصبی GMDH پرداخته و سپس الگوریتم پیشنهادی به‌منظور پیش‌بینی انرژی بادی ارائه می‌شود.

۲- انتخاب متغیرها با روش آنتروپی متقابل

در این بخش مختصری از نظریه اطلاعات و مفاهیم مربوط به آن، ارائه و درنهایت به‌منظور انتخاب متغیرهای مؤثر تابعی مبتنی بر آن ارائه می‌شود. نظریه اطلاعات به نظریه ریاضی ارتباطات معروف است و با ویژگی‌هایی چون قلمرو فوق‌العاده کلی، برخورد اصولی و پایه‌ای با مسائل و مشکلات و سادگی و استحکام نتایج به‌بارآورنده توصیف شده است [۱۷].

نظریه ریاضی ارتباطات، به‌منزله پایه نظریه اطلاعات از سوی کلودشانون در سال ۱۹۴۸ ارائه شد. این نظریه راه‌حلی بود برای مسئله فرستادن حداکثر مقدار اطلاعات از مجرای معین و اندازه‌گیری ظرفیت مجرا برای حمل اطلاعات.

در نظریه اطلاعات حشو^۹ و آنتروپی دو مفهوم رایج به‌شمار می‌روند. حشو، متضاد آنتروپی است که به پیش‌بینی‌پذیری یا قراردادی بودن پیام دلالت دارد. درواقع، حشو نتیجه پیش‌بینی‌پذیری زیاد است؛ در حالی که آنتروپی

پیش‌بینی توان تولیدی واحدهای بادی با استفاده از یک موتور پیش‌بینی ترکیبی بر مبنای آنالیز اطلاعات ...

$$H(Y/X) = \sum_{k=1}^N H(Y/x_k) - H(X) \quad (۴)$$

که نشان‌دهنده عدم قطعیت درباره Y در صورت مشخص بودن تمام رخدادهای X است و فرم مناسب برای آن به صورت زیر خواهد بود [۲۶]:

$$H(Y/X) = H(X,Y) - H(X) \quad (۵)$$

در رابطه فوق H(X,Y) به صورت زیر محاسبه می‌شود که نشان‌دهنده آنتروپی مشترک X و Y است [۲۶]:

$$H(X,Y) = \sum_{i=1}^N \sum_{k=1}^N -\log(P(x_i, y_k)) \cdot P(x_i, y_k) \quad (۶)$$

به‌طور کلی آنتروپی شرطی Y در قبال متغیرهای توضیحی x_1, x_2, \dots, x_n به صورت زیر خواهد بود [۲۶]:

$$H(Y/(x_1, x_2, \dots, x_n)) = H(x_1, x_2, \dots, x_n, Y) - H(x_1, x_2, \dots, x_n) \quad (۷)$$

در صورتی که ارزش عددی رابطه فوق برابر با صفر باشد، به این معنی خواهد بود که متغیرهای توضیحی کاملاً به توضیح تغییرات متغیر هدف (Y) قادرند [۲۸].

همان‌طور که گفته شد در این مطالعه به‌منظور یافتن همبستگی (خطی و غیرخطی) میان متغیرهای ورودی و متغیر هدف از تابع آنتروپی متقابل استفاده شده است. هدف این تکنیک انتخاب وقفه‌های بهینه مدل پویا در کنار انتخاب هر متغیر مؤثر است. بر اساس این، ابتدا لازم است مختصری درباره تابع همبستگی متقابل توضیح داده شود.

تابع همبستگی متقابل بر اساس ضریب همبستگی پیرسون r بنا شده است که این ضریب درجه همبستگی میان دو متغیر تصادفی را مبتنی بر انطباق خطی داده‌ها نشان می‌دهد. این ضریب مقداری بین -۱ تا +۱ می‌پذیرد؛ به‌گونه‌ای که مقدار +۱ نشان‌دهنده همبستگی مثبت کامل خطی و مقدار -۱ همبستگی منفی کامل خطی را نشان می‌دهد و مقدار ۰ برای این ضریب نشان می‌دهد دو متغیر بررسی شده هیچ ارتباط خطی باهم ندارند. با وجود این، در چنین شرایطی احتمال وجود روابط غیرخطی وجود خواهد داشت.

از شبکه‌های عصبی مختلف به انتخاب متغیرهای ورودی شبکه به کمک اطلاعات متقابل پرداختند [۲۴].

در این مطالعه نیز بر اساس نظریه اطلاعات و به کمک تابع آنتروپی متقابل (CEF) متغیرهای مؤثر، ورودی شبکه‌های عصبی انتخاب می‌شود. این تکنیک نه تنها در انتخاب انواع متغیرهای مؤثر (سرعت و جهت باد)، در انتخاب وقفه‌های متغیر هدف و متغیرهای ورودی راه‌گشا خواهد بود. تحلیل‌های مبتنی بر رویکرد پیشنهادی نه تنها همانند تابع همبستگی متقابل (CCF) روابط خطی را در انتخاب متغیرهای مؤثر لحاظ می‌کند، روابط غیرخطی میان آنها را نیز لحاظ می‌کند.

اطلاعات متقابل دو متغیر پیوسته تصادفی x و y با $MI(y,x)$ نشان داده می‌شوند که مبتنی بر تابع چگالی احتمال مشترک آنها $P(y,x)$ و همچنین تابع چگالی احتمال تک‌تک آنها $P(y)$ و $P(x)$ است [۲۵]:

$$MI(Y; X) = \iint p(Y, X) \times \log_2 \left(\frac{P(Y, X)}{P(Y)P(X)} \right) dX dY \quad (۱)$$

رابطه فوق چنانچه متغیرهای مورد بحث گسسته باشند، به صورت زیر خواهد بود [۲۶]:

$$MI(Y; X) = \sum_{n=1}^N \sum_{m=1}^M p(Y_n, X_m) \times \log_2 \left(\frac{P(Y_n, X_m)}{P(Y_n)P(X_m)} \right) \quad (۲)$$

بنابراین متغیرهای در مرحله انتخاب ویژگی بر اساس رویکرد گسسته‌سازی چهارکی^۸ به متغیر گسسته تبدیل می‌شوند. تبدیل و گسسته‌سازی متغیرهای حقیقی به نوعی از داده‌ها با مقادیر محدود، بیشتر در الگوریتم‌های یادگیری ماشینی ضروری است [۲۷].

آنتروپی شرطی^۹ متغیر تصادفی گسسته Y با فرض رخداد $X = x_k$ به صورت زیر خواهد بود [۲۶]:

$$H(Y/x_k) = \sum_{i=1}^N \log(P(y_i/x_k)) \cdot P(y_i/x_k) \quad (۳)$$

که در آن احتمال $P(y_i | x_k)$ با فرض رخداد $X = x_k$ است. آنتروپی شرطی Y در صورت معین بودن X نیز به صورت زیر خواهد بود [۲۶]:

وقفه انتخاب شود، نشان‌دهنده سیستم ایستا است و در صورتی که وقفه پیشنهادی منفی باشد، نشان‌دهنده رابطه علیت معکوس خواهد بود. بدین صورت که مقادیر فعلی متغیر هدف بر مقادیر آتی متغیر ورودی اثرگذار است. همان‌گونه که مشاهده می‌شود در رابطه (۹) همبستگی میان متغیرهای ورودی در نظر گرفته نشده است؛ بنابراین براساس اصول حداکثر ارتباط و حداقل حشو مسئله بهینه‌یابی چندهدفه زیر برای جلوگیری از حشو در انتخاب مؤثرترین ورودی‌های سیستم استفاده می‌شود [۳۰]:

$$\max_{x_1, \dots, x_n} V \quad (10)$$

$$\min_{x_1, \dots, x_n} P \quad (11)$$

در روابط فوق V و P به صورت زیر محاسبه می‌شوند:

$$V = \frac{1}{n} \sum_{i=1}^n I(X_i; Y) \quad (12)$$

$$P = \frac{1}{n^2} \sum_{i=1}^n \sum_{j=1}^n I(X_i; X_j) \quad (13)$$

در روابط فوق نیز $I(a, b)$ نشان‌دهنده اطلاعات مشترک میان دو متغیر تصادفی a و b است. اجرای اصل حداکثر ارتباط، مبتنی بر انتخاب متغیرها و وقفه‌هایی از آنهاست که رابطه (۱۰) را حداکثر کنند؛ به این صورت که در $I(X_i; Y)$ که در آن X_i ورودی i ام و Y خروجی سیستم است، باید میانگین اطلاعات متقابل کلیه ورودی‌ها افزایش یابد. اجرای اصل حداقل حشو نیز مبتنی بر انتخاب متغیرها و وقفه‌هایی از آنهاست که رابطه (۱۱) را حداقل کنند؛ به این صورت که در $I(X_i; X_j)$ که در آن X_i و X_j متغیرهای ورودی‌اند، باید میانگین اطلاعات متقابل کلیه ورودی‌ها کاهش یابد.

به منظور یافتن پاسخ بهینه مسئله فوق در الگوریتم بهینه‌یابی با فرض $\phi = P - V$ می‌توان آن را به صورت مسئله حداقل‌سازی زیر در نظر گرفت [۲۶]:

$$\min_{x_1, \dots, x_n} \phi \quad (14)$$

حداقل‌سازی ϕ رویکرد مناسب برای حداکثرسازی رابطه (۱۰) و حداقل‌سازی رابطه (۱۱) است.

رابطه زیر نحوه محاسبه این ضریب میان دو متغیر با N مشاهده را نشان می‌دهد [۲۹]:

$$r = \frac{\sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^N (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^N (y_i - \bar{y})^2}} \quad (8)$$

در رابطه فوق x_i و y_i مقادیر اندازه‌گیری شده متغیرهای تصادفی x و y بوده‌اند و \bar{x} و \bar{y} نیز میانگین آنها هستند. بر اساس این، برای هر متغیر و وقفه آن ضریب پیرسون محاسبه شده است و برای یافتن مؤثرترین آنها، متغیرهایی با بیشترین ضریب پیرسون انتخاب خواهد شد. با وجود این، همان‌گونه که گفته شد این ضریب تنها براساس روابط خطی محاسبه شده‌اند و بنابراین در مواجهه با سیستم‌های غیرخطی کاستی‌هایی دارند. برای غلبه بر این کاستی‌ها در این مطالعه تکنیک مناسبی برای تحلیل سیستم‌های غیرخطی ارائه شده است. رابطه زیر نشان‌دهنده اطلاعات متقابل نرمال شده میان دو سری زمانی X و Y است [۲۶]:

$$R = \frac{H(Y) - H(Y|X)}{H(Y)} \quad (9)$$

در رابطه فوق پارامتر R مقداری بین ۰ و ۱ می‌پذیرد و نشان‌دهنده میزان اطلاعاتی درباره متغیر هدف است که با متغیر ورودی توضیح داده می‌شود. بر اساس این، چنانچه متغیر X کلیه اطلاعات ضروری برای پیش‌بینی Y را دارا باشد، در این صورت $H(Y|X)$ برابر با صفر می‌شود و در نتیجه R برابر ۱ خواهد بود. از سوی دیگر، چنانچه متغیر X هیچ اطلاعاتی از متغیر Y را در بر نداشته باشد، $H(Y|X)$ برابر با $H(Y)$ می‌شود و در نتیجه R برابر با ۰ خواهد بود [۳۰].

تابع اطلاعات متقابل ارائه شده در رابطه (۹) برای هر متغیر و وقفه‌های آن محاسبه می‌شود و به دنبال آن، متغیرهایی که دارای مقدار بیشتری برای این تابع باشند، متغیر مؤثر انتخاب خواهند شد. این رویکرد برای انتخاب هر متغیر و وقفه بهینه آن به طور مستقل و بدون توجه به وابستگی میان آنها نتایج مطلوبی خواهد داشت.

در این رویکرد چنانچه وقفه انتخابی مثبت باشد، نشان‌دهنده پویایی سیستم و ارتباط مقادیر فعلی متغیر هدف با مقادیر گذشته متغیر توضیحی است. چنانچه متغیر بدون

پیش‌بینی توان تولیدی واحدهای بادی با استفاده از یک موتور پیش‌بینی ترکیبی بر مبنای آنالیز اطلاعات ...

برای یافتن پاسخ بهینه را موجب می‌شود؛ در حالی که الگوریتم ژنتیک در یافتن پاسخ دقیق با مشکل مواجه است، در یافتن بهینه سراسری عملکرد مناسبی دارد [۳۲].

با وجود این، بدون عملگر انتخاب الگوریتم انبوه ذرات ممکن است منابع محاسباتی را روی ذراتی به هدر دهد که از نظر پاسخ مسئله ضعیف ارزیابی می‌شوند و در ناحیه نامناسبی قرار دارند. مقایسه میان هر دو الگوریتم ژنتیک و انبوه ذرات با [۳۳] و [۳۴] انجام شده است و در نهایت هر دو مطالعه پیشنهاد کرده‌اند ترکیبی از الگوریتم ژنتیک و انبوه ذرات استاندارد به استراتژی جستجوی کارآمدتری منجر خواهد شد. الگوریتم انبوه ذرات استاندارد ممکن است انعطاف کافی برای مسائل کاربردی را نداشته باشد؛ به خصوص زمانی که این مسائل پیچیده، ناسازگار و چندهدفه^{۱۱} باشند.

روش‌های مختلفی برای ترکیب این دو الگوریتم وجود دارند. یک رویکرد استفاده از تنها یک الگوریتم در مرحله انتخاب و سپس استفاده از عملگرهای الگوریتم دیگر برای ایجاد پاسخ‌های بهینه است. مطالعه [۳۵] و [۳۶] چنین رویکردی داشته است. رویکرد دیگر در ترکیب این دو الگوریتم تقسیم جمعیت به دو دسته است که در آن برای هر دسته تنها عملگرهای یک الگوریتم اعمال می‌شود. مطالعه [۳۷] و [۳۸] چنین رویکردی داشته‌اند.

باید توجه داشت انتخاب متغیرهای مؤثر از میان n متغیر با وقتهای $t=0,1,\dots,k$ بسیار زمان‌بر است. در چنین شرایطی n^k متغیر کاندید وجود خواهد داشت که با در نظر گرفتن جایگشت‌های مختلف آنها فضای جستجو برابر با n^k خواهد بود؛ از این رو در چنین مسئله‌ای استفاده از الگوریتم‌های تکاملی برای جستجوی فضای بسیار گسترده مسئله ضروری است.

۳- الگوریتم ترکیبی انبوه ذرات و ژنتیک

همان‌گونه که در بخش قبل بیان شد جستجوی متغیرهای مؤثر در فضای بسیار گسترده، ابزار بهینه‌یابی مناسبی را می‌طلبد؛ بنابراین در این بخش به معرفی الگوریتم ترکیبی انبوه ذرات و ژنتیک بهبودیافته پرداخته می‌شود. الگوریتم ژنتیک و الگوریتم انبوه ذرات هر دو از الگوریتم‌های جمعیت محورند که قدرت آنها در حل مسائل بهینه‌یابی بسیار دشوار به اثبات رسیده است [۳۱]. با وجود این، دو مدل برجستگی‌ها و کاستی‌های خاص خود را دارند. الگوریتم انبوه ذرات از نظر مفهومی بسیار ساده و از نظر پیاده‌سازی تنها در چند خط، کد می‌شوند. الگوریتم انبوه ذرات همچنین برخلاف الگوریتم ژنتیک دارای حافظه‌اند؛ در حالی که در الگوریتم ژنتیک چنانچه ذره‌ای برای نسل بعد انتخاب نشود، خاطرات آن کلاً محو خواهد شد. در الگوریتم انبوه ذرات فعل و انفعالات مشترک و همکاری گروه، بهبود جستجو

1	3	5	2	8	4	9	7	6	Insertion	1	3	2	8	4	9	5	7	6
1	3	5	2	8	4	9	7	6	Swapping	1	3	5	7	8	4	9	2	6
1	3	5	2	8	4	9	7	6	Reversion	1	3	5	9	4	8	2	7	6

شکل (۱): نتایج اعمال عملگرهای جابه‌جایی بر جواب فرضی

شکل (۱) نتیجه اعمال این عملگرها به پاسخ فرضی را نشان می‌دهد.

همچنین شکل (۲) مراحل اجرای الگوریتم ترکیبی ارائه شده در این مطالعه را نشان می‌دهد. با توجه به شکل (۲)، در این تکنیک پس از ایجاد جمعیت اولیه به ترتیب عملگرهای الگوریتم انبوه ذرات و الگوریتم ژنتیک بر کلیه افراد اعمال می‌شوند که فرایند مربوط به هریک پیش‌تر بحث شد. شرط

در این مطالعه رویکرد نوینی در ترکیب این دو الگوریتم ارائه شده است؛ به گونه‌ای ضمن اعمال همزمان کلیه عملگرهای هر دو الگوریتم روی جمعیت، از عملگرهای متناسب با مسئله این مطالعه برای بهبود نتایج نیز استفاده شده است. در این رویکرد عملگرهای درج^{۱۱}، تعویض^{۱۲} و وارون^{۱۳} کردن استفاده شده‌اند که کلیه این عملگرها را عملگرهای جابه‌جایی^{۱۴} می‌نامیم.

شبکه‌های عصبی مصنوعی از تعدادی واحد پردازش متصل به هم تشکیل شده‌اند که نرون نامیده می‌شوند. ساختار شبکه عصبی مصنوعی به گونه‌ای است که نرون‌ها در دسته‌هایی که لایه نام دارند، مرتب می‌شوند. یکی از قابلیت‌های شبکه عصبی این است که می‌توان با داشتن ورودی، شبکه را طوری آموزش داد (یعنی وزن‌های نرون‌ها را طوری اختیار کرد) تا خروجی مطلوب به دست آید.

نخستین بار دانشمند اوکراینی به نام ایواخنکو در سال ۱۹۶۵ شبکه عصبی GMDH را معرفی کرد [۳۹]. شبکه عصبی GMDH شبکه‌ای خودسازمانده و یک‌سویه است که از چندین لایه حاصل شده و هر لایه از چندین نرون تشکیل شده است. تمامی نرون‌ها از ساختار مشابهی برخوردارند؛ طوری که دارای دو ورودی و یک خروجی اند و هر نرون با ۵ وزن و یک بایاس عمل پردازش را میان داده‌های ورودی و خروجی براساس رابطه (۱۵) برقرار می‌کند [۳۹].

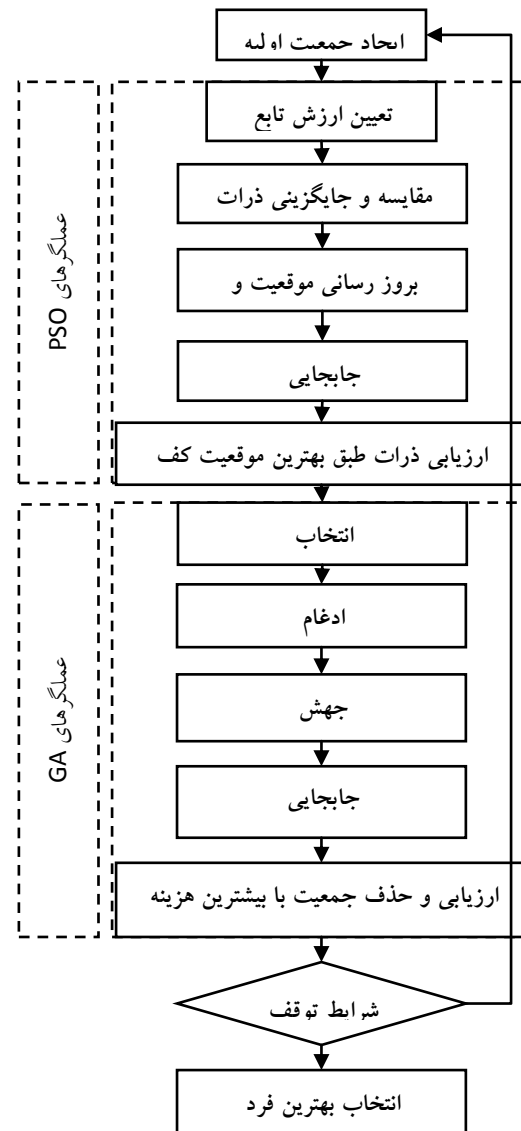
$$y_{ik}^* = N(x_i, x_j) = b^k + w_1^k x_{ia} + w_2^k x_{ib} + w_3^k x_{ia}^2 + w_4^k x_{ib}^2 + w_5^k x_{ia} x_{ib} \quad (15)$$

در رابطه فوق، $(i = 1, 2, 3, \dots, N)$ که در آن (N) تعداد مشاهدات بوده و $(k = 1, 2, 3, \dots, C_m^2)$ و $\beta \in \{1, 2, 3, \dots, m\}$ که در آنها (m) تعداد نرون‌های لایه قبلی است، وزن‌ها براساس روش حداقل مربعات معمولی (OLS)، محاسبه و سپس به‌عنوان مقادیر مشخص و ثابت در داخل هر نرون جایگذاری می‌شوند. ویژگی بارز این نوع شبکه آن است که نرون‌های مرحله قبل و یا لایه قبلی عامل مولد تولید نرون‌های جدید به تعداد $C_m^2 = \frac{m(m-1)}{2}$ هستند و از میان نرون‌های تولیدشده، لزوماً تعدادی حذف می‌شوند تا بدین‌وسیله از واگرایی شبکه جلوگیری شود. همچنین نرون‌هایی که برای ادامه و گسترش شبکه باقی می‌مانند نیز ممکن است به دلیل ارتباط نداشتن مستقیم یا غیرمستقیم با لایه آخر و ایجاد فرم همگرایی شبکه حذف شوند که اصطلاحاً به آنها نرون‌های غیرفعال می‌گویند. معیار حذف و گزینش مجموعه‌ای از نرون‌ها در یک لایه، میانگین

توقف در این الگوریتم، معیار حداکثر تعداد تکرار و بهبود نیافتن تابع هدف است.

۴- شبکه عصبی GMDH

امروزه دیدگاه دیگری به موازات مدل‌های سری زمانی در زمینه پیش‌بینی مطرح است. برتری مهم این روش‌ها که به شبکه‌های عصبی مصنوعی (ANN) معروف‌اند، نیاز نداشتن به اعمال فرضیه‌های خاص درباره رفتار متغیرها است. شبکه‌های عصبی مصنوعی از عناصر عملیاتی ساده‌ای ساخته شده‌اند که سازوکار آنها از سیستم‌های عصبی بیولوژیکی الهام گرفته شده است.



شکل (۲): فلوچارت ترکیب الگوریتم انبوه ذرات و ژنتیک

پیش‌بینی توان تولیدی واحدهای بادی با استفاده از یک موتور پیش‌بینی ترکیبی بر مبنای آنالیز اطلاعات ...

ضرایب مجهول تمامی نرون‌ها با استفاده از روش حداقل مربعات به دست می‌آیند؛ بنابراین $\binom{n}{2} = \frac{n(n-1)}{2}$ نرون در لایه دوم ساخته می‌شوند که می‌توان آنها را به شکل مجموعه زیر نمایش داد.

$$\left\{ (y_i, x_{ip}, x_{iq}) \mid \begin{matrix} (i=1,2,\dots,m) \\ p,q \in (1,2,\dots,m) \end{matrix} \right\} \quad (19)$$

از شکل درجه دوم تابع بیان‌شده در معادله (۱۸)، برای هر M ردیف سه‌تایی استفاده می‌شود. این معادلات را می‌توان به شکل ماتریسی (۲۰) بیان کرد:

$$Aa = Y \quad (20)$$

که در آن A ، بردار ضرایب مجهول معادله درجه دو نشان داده شده در معادله (۱۸) است؛ یعنی:

$$a = \{a_0, a_1, \dots, a_5\} \quad (21)$$

و

$$Y = \{y_1, y_2, \dots, y_m\} \quad (22)$$

از مقادیر بردارهای ورودی و شکل تابع به راحتی مشاهده می‌شود که:

$$A = \begin{bmatrix} 1 & x_{1p} & x_{1q} & x_{1p}^2 & x_{1q}^2 & x_{1p}x_{1q} \\ 1 & x_{2p} & x_{2q} & x_{2p}^2 & x_{2q}^2 & x_{2p}x_{2q} \\ \dots & \dots & \dots & \dots & \dots & \dots \\ M & M & M & M & M & M \\ 1 & x_{Mp} & x_{Mq} & x_{Mp}^2 & x_{Mq}^2 & x_{Mp}x_{Mq} \end{bmatrix} \quad (23)$$

روش حداقل مربعات از آنالیز رگرسیون چندگانه، حل معادلات را به شکل معادله (۲۴) به دست می‌دهد [۴۱]:

$$a = (A^T A)^{-1} A^T Y \quad (24)$$

این معادله بردار ضرایب معادله (۱۸) را برای تمام M مجموعه سه‌تایی ایجاد می‌کند.

شکل (۳) ساختار نمونه از شبکه عصبی GMDH را نشان می‌دهد.

مجموع مربع خطاها (MSE) میان خروجی واقعی و خروجی هر نرون است. این معیار برای خروجی نرون j ام یعنی (y_{ij}^*) به صورت رابطه (۱۶) خواهد بود [۳۹]:

$$mse_j = \frac{\sum_{i=1}^N (y_i - y_i^*)^2}{N} \quad (16)$$

در رابطه فوق $j \in \{1, 2, 3, \dots, C_m^2\}$ است که در آن m تعداد نرون‌های گزینش‌شده در لایه قبلی است. نگاشتی بین متغیرهای ورودی و خروجی که این نوع از شبکه‌های عصبی برقرار می‌کنند، به صورت تابع غیرخطی ولتر^{۱۵} به صورت رابطه (۱۷) است [۴۰]:

$$\hat{y} = a_0 + \sum_{i=1}^m a_i x_i + \sum_{i=1}^m \sum_{j=1}^m a_{ij} x_i x_j + \sum_{i=1}^m \sum_{j=1}^m \sum_{k=1}^m a_{ijk} x_i x_j x_k \quad (17)$$

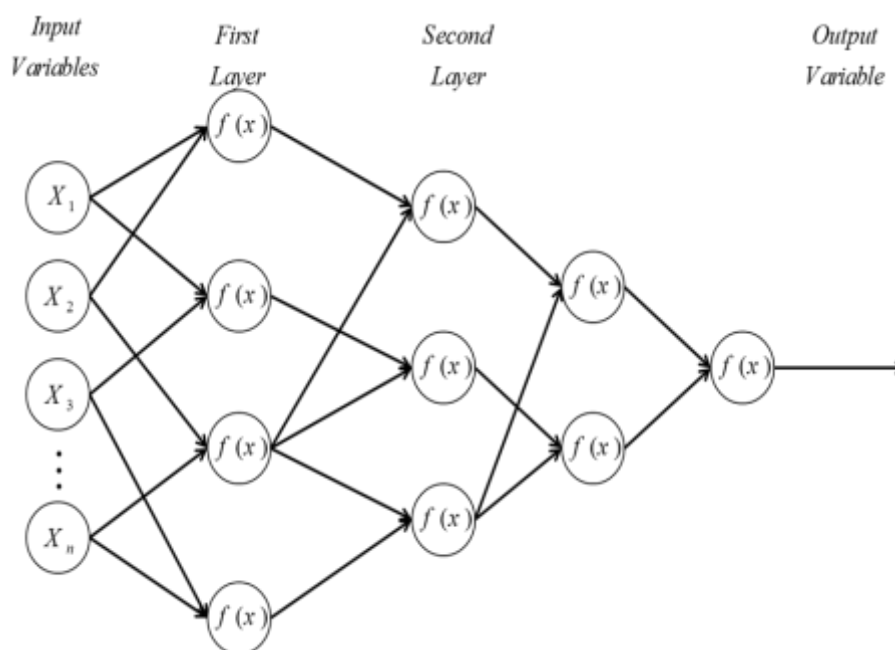
ساختاری که برای نرون‌ها در نظر گرفته شده است، به صورت فرم خلاصه‌شده دو متغیره درجه دوم زیر خواهد بود:

$$\hat{y} = f(x_i, x_j) = a_0 + a_1 x_i + a_2 x_j + a_3 x_i^2 + a_4 x_j^2 + a_5 x_i x_j \quad (18)$$

ضرایب مجهول α_i در معادله (۱۸) با تکنیک رگرسیون چنان به دست می‌آیند که اختلاف بین خروجی واقعی y و مقادیر محاسبه‌شده \hat{y} ، برای هر جفت متغیر ورودی x_i و x_j کمینه شود. مجموعه‌ای از چند جمله‌ای‌ها، با استفاده از معادله (۱۸) است که ضرایب مجهول همه آنها، با استفاده از روش حداقل مربعات معمولی (OLS) به دست می‌آید. برای هر تابع G_i (هر نرون ساخته‌شده)، ضرایب معادلات هر نرون برای حداقل کردن خطای آن، به منظور انطباق بهینه ورودی‌ها بر تمام جفت مجموعه‌های ورودی - خروجی به دست می‌آیند.

$$E = \frac{\sum_{i=1}^m (y_i - G_i)^2}{m} \rightarrow \min \quad (19)$$

در روش پایه‌ای الگوریتم GMDH، تمام ترکیبات دوتایی (نرون‌ها) از n متغیر ورودی ساخته شده‌اند و



شکل (۳): ساختار شبکه عصبی GMDH

(RMSE) و میانگین درصد مربع (MAPE) خطاهای پیش‌بینی از پرکاربردترین آنان محسوب می‌شوند [۲۳] و [۴۲]:

$$RMSE = \left[\frac{1}{N} \sum_{i=1}^N (WP_i^{ACT} - WP_i^{FOR})^2 \right]^{\frac{1}{2}} \quad (25)$$

$$MAPE = \frac{1}{N} \sum_{i=1}^N \frac{|WP_i^{ACT} - WP_i^{FOR}|}{WP_i^{ACT}} \times 100 \quad (26)$$


در روابط فوق WP_i^{ACT} و WP_i^{FOR} به ترتیب نشان‌دهنده انرژی بادی تولیدشده و پیش‌بینی شده در زمان t ام هستند. با وجود این، در مسئله موجود در این مطالعه معیار MAPE به سادگی استنادپذیر نخواهد بود؛ زیرا در برخی شرایط انرژی بادی تولیدی بسیار اندک و حتی ممکن است برابر با صفر باشد که در چنین شرایطی حتی اگر میزان پیش‌بینی شده به مقدار واقعی، بسیار نزدیک و صورت کسر رابطه (۲۶) بسیار اندک باشد، کل کسر این رابطه مقدار بسیار بزرگ یا حتی بی‌نهایت را نشان خواهد داد؛ از این رو، در این مطالعه از معیار میانگین درصد مربع اصلاح‌شده (MMAPE) برای غلبه بر کاستی فوق استفاده شده است [۲۳]:

۵- پیش‌بینی توان تولیدی واحد بادی

در این مطالعه به منظور مقایسه کارایی عملیاتی روش‌های مختلف (GMDH, RBF, MLP, ARIMA) در کنار رویکرد پیش‌بینی یک‌گام به جلو، از رویکرد چندگام به جلو نیز استفاده شده است. با توجه به استفاده از داده‌های ساعتی و اهمیت پیش‌بینی انرژی بادی در ۲۴ ساعت آینده، رویکرد چندگام به جلو به صورت ۲۴ گام در نظر گرفته شده است. همانگونه که در تکنیک‌های سری زمانی همچون ARIMA بیان می‌شود، مقادیر گذشته سری زمانی حاوی اطلاعات لازم برای پیش‌بینی روند آتی آن است. در این مطالعه نیز به منظور پیش‌بینی انرژی بادی از مقادیر گذشته این سری زمانی استفاده شده است. همچنین با توجه به تأثیر انکارناپذیر سرعت و جهت باد در تولید انرژی بادی و دسترسی به داده‌های آنان، این دو متغیر همراه با وقفه‌های آن نیز در مدلسازی استفاده شده‌اند. داده‌های استفاده شده در این مطالعه از مزرعه بادی سوتاونتو^{۱۶} در ایالت گلسیای اسپانیا استخراج شده‌اند.

به منظور ارزیابی قدرت پیش‌بینی تکنیک‌های مختلف در این مطالعات مختلف از معیارهای گوناگونی استفاده می‌شود. با وجود این، دو معیار ریشه میانگین مربع

پیش‌بینی توان تولیدی واحدهای بادی با استفاده از یک موتور پیش‌بینی ترکیبی بر مبنای آنالیز اطلاعات ...



شکل (۴): فرآیند پیش‌بینی انرژی بادی

مؤثر انتخاب می‌شوند که تابع هزینه آن آنتروپی متقابل به صورت رابطه (۱۴) است.

جدول (۱): ویژگی‌های شبکه عصبی RBF

ماه	نوامبر	اوت	می	فوریه
Spread	۳/۳	۳/۹	۳/۹	۴/۵
حداکثر نرون	۱۰	۱۰	۳	۸

در این مرحله افزایش بیش از حد تعداد متغیرها، که موجب افزایش حشو می‌شود، بهبود چشمگیری در تابع هزینه نداشته و حتی ممکن است موجب افزایش آن شود؛ بنابراین تعداد متغیرها نیز می‌باید به صورت هوشمند انتخاب شوند. بدین منظور لازم است الگوریتم ترکیبی دو دسته پاسخ محتمل ایجاد کند؛ یک دسته جهت انتخاب شماره متغیرهای کاندید (در اینجا ترکیب‌های محتمل در بازه ۱ تا ۱۵۲) و یک دسته جهت انتخاب تعداد متغیرها که بدین منظور پس از ارائه پاسخ احتمالی از سوی الگوریتم در بازه ۰ تا ۱ این عدد به صورت عدد صحیح متناسب با فضای جستجو (۱ تا ۱۵۲) تبدیل می‌شود (رابطه زیر).

$$M = \text{round}(x(N-1)+1) \quad (29)$$

در رابطه فوق با توجه به اینکه مقادیر محتمل پاسخ تولیدشده x بین ۰ تا ۱ است، نتیجه رابطه یک عدد صحیح در بازه ۱ تا N (برابر با تعداد متغیرهای کاندید) خواهد بود. در گام دوم و پس از تعیین متغیرهای مؤثر به کمک آنها به آموزش شبکه‌های عصبی مختلف پرداخته می‌شود. رویکرد استفاده‌شده در این مرحله، استفاده از داده‌های ۸۰ روزه ساعتی است؛ به گونه‌ای که این داده‌ها به سه دسته داده‌های آموزشی، صحت‌سنجی و تست تقسیم می‌شوند که از داده‌های ۴۹ روز نخست برای آموزش و از داده‌های روز

$$MMAPE = \frac{1}{N} \sum_{i=1}^N \frac{|WP_i^{ACT} - WP_i^{FOR}|}{WP_i^{AVE-ACT}} \times 100, \quad (27)$$

$$WP_i^{AVE-ACT} = \frac{1}{N} \sum_{i=1}^N WP_i^{ACT}$$

همان‌گونه که گفته شد در این مطالعه به منظور پیش‌بینی انرژی بادی از داده‌های سری انرژی بادی، سرعت و جهت همراه با ۵۰ وقفه آنها استفاده شده است (رابطه زیر).

$$WP_t = f \left(\begin{matrix} WP_{t-1, t-2, \dots, t-50}, \\ S_{t-0, t-1, \dots, t-50}, \\ D_{t-0, t-1, \dots, t-50} \end{matrix} \right) \quad (28)$$

همان‌گونه که مشاهده می‌شود متغیرهای توضیحی مدل، شامل ۵۰ وقفه انرژی بادی (WP)، سرعت (S) و جهت باد (D) و همچنین سرعت و جهت باد در زمان t به منظور پیش‌بینی انرژی بادی در این زمان (t) است. با توجه به اینکه وقفه‌های متغیرهای توضیحی استفاده‌شده موجب افزایش بیش از حد اطلاعات ورودی شبکه می‌شود، لازم است از میان آنها تنها تعداد محدودی با اطلاعات مفید و مؤثر انتخاب شوند. بدین منظور مکانیزم پیشنهادی این مطالعه برای پیش‌بینی انرژی بادی شامل دو مرحله خواهد بود که در مرحله نخست، به کمک معیار آنتروپی متقابل که در بخش دوم به تشریح آن پرداخته شد، متغیرهای مؤثر از میان ۱۵۲ متغیر کاندید (۱۵۰ متغیر شامل ۵۰ وقفه سه متغیر انرژی بادی، سرعت و جهت باد و ۲ متغیر سرعت و جهت باد در زمان پیش‌بینی t)، انتخاب و سپس در گام بعدی این متغیرهای در موتور پیش‌بینی استفاده شده‌اند.

شکل (۴) فرآیند پیش‌بینی انرژی بادی در این مطالعه را نشان می‌دهد. در گام نخست با استفاده از الگوریتم ترکیبی ژنتیک و انبوه ذرات بهبودیافته (EPSO-GA) متغیرهای

جدول (۲): ارزیابی نتایج پیش‌بینی در افق ۱ گام به جلو

روش	GMDH		MLP		RBF		ARIMA	
	MMAPE	RMSE	MMAPE	RMSE	MMAPE	RMSE	MMAPE	RMSE
فوریه	0.1594	1.172	0.2034	1.1537	0.2174	1.1285	0.2505	1.3062
مه	0.2023	0.8769	0.2891	1.1743	0.2545	1.1311	0.2635	1.1674
آگوست	0.1651	0.553	0.1838	0.6626	0.2199	0.7397	0.3005	0.9883
نوامبر	0.1907	1.2671	0.2532	1.6077	0.2249	1.2427	0.2323	1.2580
زمان حل (ثانیه)	4		12		90		45	

جدول (۳): ارزیابی نتایج پیش‌بینی در افق ۲۴ گام به جلو

روش	GMDH		MLP		RBF		ARIMA	
	MMAPE	RMSE	MMAPE	RMSE	MMAPE	RMSE	MMAPE	RMSE
فوریه	0.2666	1.4437	0.3491	2.0706	0.4212	2.1438	0.6771	3.2243
مه	0.2990	1.3371	0.4738	1.8911	0.3885	1.7437	0.6438	2.5743
آگوست	0.2546	0.8051	0.2598	0.9402	0.3330	1.1492	0.7110	2.1536
نوامبر	0.2668	1.5977	0.4034	2.3780	0.3634	1.9468	0.6186	2.9914
زمان حل (ثانیه)	5		37		93		47	

به جلو) از داده‌های واقعی یک ساعت گذشته استفاده می‌شود؛ ولی در افق ۲۴ ساعت (چندگام به جلو)، پس از ساعت اول برای ساعات بعدی تا ۲۴ ساعت از مقادیر پیش‌بینی شده به‌عنوان ورودی شبکه استفاده می‌شود.

همچنین در این مرحله به منظور بررسی بهتر نتایج، از ماه‌های فوریه، می، اوت و نوامبر به ترتیب به‌عنوان نماینده فصول مختلف سال و ماه‌های تست شبکه پس از آموزش آن استفاده شده است.

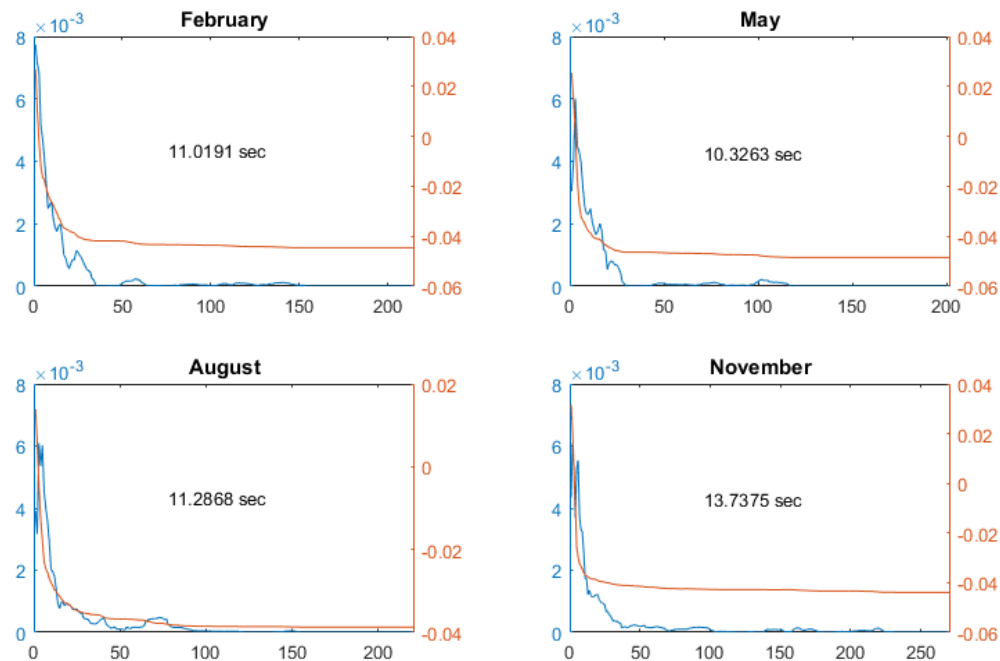
در روش ARIMA به منظور تعیین وقفه بهینه علاوه بر استفاده از متد باکس-جنکینز از معیار آکائیک بیزین استفاده شد است [۴۳] و [۴۴]. در شبکه MLP پس از آزمون و خطا از تابع فعال‌سازی Logsig و خطی به ترتیب در نرون‌های لایه پنهان و خروجی، استفاده و در شبکه RBF مقادیر حداکثر نرون و Spread برای ماه‌های مختلف به صورت جدول (۱) انتخاب شده است. نتایج پیش‌بینی در افق ۱ و ۲۴ گام به جلو برای متدهای مختلف به ترتیب در جداول ۲ و ۳ ارائه شده‌اند. در جدول ۲ و ۳ سطر آخر نشان‌دهنده مدت زمان آموزش و پیش‌بینی شبکه است که شبکه عصبی GMDH در هر دو افق پیش‌بینی کمترین زمان

۵۰ام برای صحت‌سنجی و از داده‌های ۳۰ روز پایانی برای تست مدل استفاده می‌شود.

همچنین پس از آزمون و خطا تعداد جمعیت الگوریتم‌ها ۵۰، میزان حداکثر تکرار ۵۰۰، معیار توقف بهبود نیافتن بعد از ۵۰ تکرار و نرخ جهش^{۱۷} و همبری^{۱۸} به ترتیب ۰٫۷ و ۰٫۱ و نیز پارامترهای یادگیری (c1 و c2) برای PSO هر دو ۱٫۴۹۶۲ انتخاب شدند. کلیه برنامه‌ها در فضای متلب و در یک سیستم با پردازنده corei5 و حافظه ۴ گیگ اجرا شده است. با توجه به شکل (۵)، علاوه بر زمان اجرای شبکه، که در جدول (۲) و (۳) به آن اشاره شده است، می‌باید زمان صرف‌شده در مرحله انتخاب متغیرهای مؤثر نیز در نظر گرفته شود که این زمان برای ماه‌های مختلف بین ۱۰ تا ۱۳ ثانیه متغیر است. شایان توجه است با وجود افزودن این زمان، کل زمان صرف‌شده در تکنیک GMDH همچنان کمتر از تکنیک‌های رقیب خواهد بود.

پس از آموزش و صحت‌سنجی شبکه‌های مختلف برای اطمینان از جامعیت آن براساس دو افق پیش‌بینی مختلف به پیش‌بینی مقادیر ۳۰ روز پایانی پرداخته می‌شود؛ افق ۱ ساعت و افق ۲۴ ساعت که در افق یک ساعت (یک گام

پیش‌بینی توان تولیدی واحدهای بادی با استفاده از یک موتور پیش‌بینی ترکیبی بر مبنای آنالیز اطلاعات ...



شکل (۵): متوسط (محور سمت راست) و انحراف معیار (محور سمت چپ) برازندگی اعضاء جمعیت و زمان بهینه‌یابی

بین داده‌های متعدد ورودی است. نتایج حاصل از شبیه‌سازی روی داده‌های واقعی مزرعه بادی سوتاونتو در اسپانیا حاکی از دقت، سرعت و توانایی زیاد مدل پیشنهادی است.

را داشته است. همچنین ارزیابی قدرت پیش‌بینی این شبکه بر اساس هردو معیار $RMSE$ و $MMAPE$ با سایر تکنیک‌ها نیز نشان‌دهنده قدرت پیش‌بینی بیشتر آن است.

۶- نتیجه‌گیری

انرژی بادی، یکی از منابع انرژی تجدیدپذیر است که منبع جایگزین سوخت‌های فسیلی است و شایان توجه و تأکید است. با توجه به وابستگی شدید تولید انرژی بادی به تغییرات جوی و روند پرنوسان آن برای عرضه مطمئن آن در شبکه‌های توزیع، پیش‌بینی دقیق روند آتی آن اهمیت فراوانی دارد. با توجه به روند به‌شدت نوسانی و غیرخطی توان تولیدی واحدهای بادی، در این مطالعه سیستم هوشمند ابتکاری برای پیش‌بینی مقادیر آینده تولید توان واحدهای بادی ارائه شد. در این الگوریتم ابتدا به کمک نظریه اطلاعات، متغیرهای مؤثر همراه با وقفه‌های بهینه شناسایی شدند و سپس به کمک آن شبکه عصبی خودسازمانده موسوم به $GMDH$ آموزش داده شد. شبکه عصبی $GMDH$ به زمان اندکی برای آموزش نیاز داشت و ویژگی برجسته آن امکان تعیین ورودی‌های مؤثر در پیش‌بینی از

مراجع

- [1] E. Vine, "Breaking down the silos: the integration of energy efficiency, renewable energy, demand response and climate change," *Energy Efficiency*, vol. 1, no. 1, pp. 49-63, 2008.
- [2] W. Zhou, C. Lou, Z. Li, L. Lu, and H. Yang, "Current status of research on optimum sizing of stand-alone hybrid solar-wind power generation systems," *Applied Energy*, Vol. 87, No. 2, pp. 380-389, 2010.
- [3] A. Strupczewski, "Accident risks in nuclear-power plants," *Applied Energy*, Vol. 75, No. 1-2, pp. 79-86, 2003.
- [4] A. Skoglund, M. Leijon, A. Rehn, M. Lindahl, and R. Waters, "On the physics of power, energy and economics of renewable electric energy sources - Part II," *Renewable Energy*, Vol. 35, No. 8, pp. 1735-1740, 2010.
- [5] A. Evans, V. Strezov, and T. J. Evans, "Assessment of sustainability indicators for renewable energy technologies," *Renewable and Sustainable Energy Reviews*, Vol. 13, No. 5, pp. 1082-1088, 2009.
- [6] J. Lerner, M. Grundmeyer, and M. Garvert, "The importance of wind forecasting,"

- [20] R. J. May, G. C. Dandy, H. R. Maier, and J. B. Nixon, "Application of partial mutual information variable selection to ANN forecasting of water quality in water distribution systems," *Environmental Modelling & Software*, Vol. 23, No. 10–11, pp. 1289-1299, 2008.
- [21] N. Amjady and A. Daraeepour, "Design of input vector for day-ahead price forecasting of electricity markets," *Expert Systems with Applications*, Vol. 36, No. 10, pp. 12281-12294, 2009.
- [22] N. Amjady and F. Keynia, "A new prediction strategy for price spike forecasting of day-ahead electricity markets," *Applied Soft Computing*, vol. 11, no. 6, pp. 4246-4256, 2011.
- [23] N. Amjady, F. Keynia, and H. Zareipour, "Short-term wind power forecasting using ridgelet neural network," *Electric Power Systems Research*, Vol. 81, No. 12 pp, 2099-2107, 2011.
- [24] A. Kazem, E. Sharifi, F. K. Hussain, M. Saberi, and O. K. Hussain, "Support vector regression with chaos-based firefly algorithm for stock market price forecasting," *Applied Soft Computing*, Vol. 13, No. 2, pp. 947-958, 2013.
- [25] S. Guiaşu, *Information theory with applications*. New York: McGraw-Hill, 1976.
- [26] O. Ludwig, U. Nunes, R. Araújo, L. Schnitman, and H. A. Lepikson, "Applications of information theory, genetic algorithms, and neural models to predict oil flow," *Communications in Nonlinear Science and Numerical Simulation*, Vol. 14, No. 7, pp. 2870-2885, 2009/07/01/ 2009.
- [27] J. Dougherty, R. Kohavi, and M. Sahami, "Supervised and Unsupervised Discretization of Continuous Features," presented at the ICML, 1995. Available: <http://dblp.uni-trier.de/db/conf/icml/icml1995.html#DoughertyKS95>
- [28] H. Liu, J. Sun, L. Liu, and H. Zhang, "Feature selection with dynamic mutual information," *Pattern Recognition*, Vol. 42, No. 7, pp. 1330-1339, 7// 2009.
- [29] J. D. Hamilton, *Time Series Analysis*. Princeton University Press, 1994.
- [30] H. Peng, L. Fulmi, and C. Ding, "Feature selection based on mutual information criteria of max-dependency, max-relevance, and min-redundancy," *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, Vol. 27, No. 8, pp. 1226-1238, 2005.
- [31] J. Kennedy and R. Eberhart, "Particle swarm optimization," in *Neural Networks, 1995. Proceedings., IEEE International Conference on*, 1995, Vol. 4, pp. 1942-1948 vol.4.
- [32] R. F. Abdel-Kader, "Hybrid discrete PSO with GA operators for efficient QoS-multicast routing," *Ain Shams Engineering Journal*, Vol. 2, No. 1, pp. 21-31, 2011.
- [33] R. Eberhart and Y. Shi, "Comparison between genetic algorithms and particle swarm optimization," in *Evolutionary Programming VII*, vol. 1447, V. W. Porto, N. Saravanan, D. Waagen, and A. E. Eiben, Eds. (Lecture Notes *Renewable Energy Focus*, Vol. 10, No. 2, pp. 64-66, 2009.
- [7] J. Lujano-Rojas, J. Bernal-Agustín, R. Dufolópez, and J. Domínguez-Navarro, "Forecast of Hourly Average Wind Speed Using ARMA Model with Discrete Probability Transformation," in *Electrical Engineering and Control*, vol. 98, M. Zhu, Ed. (Lecture Notes in Electrical Engineering: Springer Berlin Heidelberg, 2011, pp. 1003-1010.
- [8] H. Liu, J. Shi, and E. Erdem, "Prediction of wind speed time series using modified Taylor Kriging method," *Energy*, vol. 35, no. 12, pp. 48 2010, 4879-70.
- [9] G. N. Kariniotakis, G. S. Stavrakakis, and E. F. Nogaret, "Wind power forecasting using advanced neural networks models," *Energy Conversion, IEEE Transactions on*, Vol. 11, No. 4, pp. 762-767, 1996.
- [10] M. C. Alexiadis, P. S. Dokopoulos, H. S. Sahsamanoglou, and I. M. Manousaridis, "Short-term forecasting of wind speed and related electrical power," *Solar Energy*, Vol. 63, No. 1, pp. 61-68, 1998.
- [11] J. Zhou, J. Shi, and G. Li, "Fine tuning support vector machines for short-term wind speed forecasting," *Energy Conversion and Management*, Vol. 52, No. 4, pp. 1990-1998, 2011.
- [12] P. Johnson, M. Negnevitsky, and K. M. Muttaqi, "Short term wind power forecasting using adaptive neuro-fuzzy inference systems," in *Power Engineering Conference, 2007. AUPEC 2007. Australasian Universities*, 2007, pp. 1-6.
- [13] A. M. Foley, P. G. Leahy, A. Marvuglia, and E. J. McKeogh, "Current methods and advances in forecasting of wind power generation," *Renewable Energy*, Vol. 37, No. 1, pp. 1-8, 2012.
- [14] A. Costa, A. Crespo, J. Navarro, G. Lizcano, H. Madsen, and E. Feitosa, "A review on the young history of the wind power short-term prediction," *Renewable and Sustainable Energy Reviews*, Vol. 12, No. 6, pp. 1725-1744, 2008.
- [15] X. Wang, P. Guo, and X. Huang, "A Review of Wind Power Forecasting Models," *Energy Procedia*, Vol. 12, No. 0, pp. 770-778, 2011.
- [16] S. S. Soman, H. Zareipour, O. Malik, and P. Mandal, "A review of wind power and wind speed forecasting methods with different time horizons," 2010, pp. 1-8.
- [17] F. M. Reza, *An Introduction to Information Theory*. Dover, 1994.
- [18] G. Simon and M. Verleysen, "High-dimensional delay selection for regression models with mutual information and distance-to-diagonal criteria," *Neurocomputing*, vol. 70, no. 7–9, pp. 1265-1275, 2007.
- [19] D. François, F. Rossi, V. Wertz, and M. Verleysen, "Resampling methods for parameter-free and robust feature selection with mutual information," *Neurocomputing*, Vol. 70, No. 7–9, pp. 1276-1288, 2007.

- multimodal functions," *Applied Soft Computing*, Vol. 8, No. 2, pp. 849-857, 2008.
- [39] A. G. Ivakhnenko, D. Wunsch, and G. A. Ivakhnenko, "Inductive sorting-out GMDH algorithms with polynomial complexity for active neurons of neural network," in *Neural Networks, 1999. IJCNN '99. International Joint Conference on*, 1999, Vol. 2, pp. 1169-1173 vol.2.
- [40] R. W. Brockett, "Volterra series and geometric control theory," *Automatica*, vol. 12, no. 2, pp. 167-176, 1976/03/01 1976.
- [41] A. G. Ivakhnenko, "Polynomial Theory of Complex Systems," *IEEE Transactions on Systems, Man, and Cybernetics*, Vol. SMC-1, No. 4, pp. 364-378, 1971.
- [42] N. Amjadi, F. Keynia, and H. Zareipour, "Wind Power Prediction by a New Forecast Engine Composed of Modified Hybrid Neural Network and Enhanced Particle Swarm Optimization," *IEEE Transactions on Sustainable Energy*, Vol. 2, No. 3, pp. 265-276, 2011.
- [43] W. Vandaele, *Applied time series and Box-Jenkins models*. Academic Press, 1983.
- [44] R. A. Yaffee and M. McGee, *An Introduction to Time Series Analysis and Forecasting: With Applications of SAS® and SPSS®*. Elsevier Science, 2000.
- in Computer Science: Springer Berlin Heidelberg, 1998, pp. 611-616.
- [34] P. Angeline, "Evolutionary optimization versus particle swarm optimization: Philosophy and performance differences," 1998, pp. 601-610.
- [35] A. Mohammadi and M. Jazaeri, "A hybrid particle swarm optimization-genetic algorithm for optimal location of svc devices in power system planning," in *Universities Power Engineering Conference, 2007. UPEC 2007. 42nd International*, 2007, pp. 1175-1181.
- [36] J. Robinson, S. Sinton, and Y. Rahmat-Samii, "Particle swarm, genetic algorithm, and their hybrids: optimization of a profiled corrugated horn antenna," in *Antennas and Propagation Society International Symposium, 2002. IEEE*, Vol. 1, pp. 314-317, 2002.
- [37] E. Alfassio Grimaldi, F. Grimaccia, M. Mussetta, P. Pirinoli, and R. E. Zich, "A new hybrid genetical-swarm algorithm for electromagnetic optimization," in *Computational Electromagnetics and Its Applications, 2004. Proceedings. ICCEA 2004. 2004 3rd International Conference on*, 2004, pp. 157-160.
- [38] Y.-T. Kao and E. Zahara, "A hybrid genetic algorithm and particle swarm optimization for

-
- ¹ Sustainability
 - ² Global Wind Energy Council (GWEC)
 - ³ External Criterion
 - ⁴ Cross correlation
 - ⁵ Redundancy
 - ⁶ Mutual Information (MI)
 - ⁷ Forward feature selection
 - ⁸ Quartile Discretization
 - ⁹ Conditional Entropy
 - ¹⁰ Complicated, Conflicting and Multitasking
 - ¹¹ Insertion
 - ¹² Swapping
 - ¹³ Reversion
 - ¹⁴ Relocating
 - ¹⁵ Voltra
 - ¹⁶ Sotavento
 - ¹⁷ Mutation
 - ¹⁸ Cross Over