

پیش بینی توان خروجی مزارع بادی براساس الگوریتم‌های فازی با هدف کاهش تأثیر عدم قطعیت انرژی باد

نوع مطالعه: پژوهشی

محسن داودی^۱، استادیار، مهدی محمد قلیها^۲، دانشجوی دکتری

۱- دانشگاه بین المللی امام خمینی - ایران - davoudi@eng.ikiu.ac.ir

۲- دانشگاه بین المللی امام خمینی - ایران - m.mgholiha@gmail.com

چکیده: با افزایش نفوذ منابع انرژی تجدیدپذیر در سیستم های قدرت و بدنبال آن شکل گیری بازارهای برق، بهره‌برداری و کنترل سیستم‌های قدرت با چالش های مختلفی همراه خواهد بود. یکی از چالش‌های اصلی مواجهه با عدم قطعیت انرژی باد بوده که تأثیر مستقیم بر هزینه کل بهره‌برداری خواهد داشت. در این مقاله، رویکردهای مختلفی مبتنی بر منطق فازی پیشنهاد شده است تا اثربخشی آنها جهت کاهش عدم قطعیت ذکر شده از طریق پیش بینی دقیق توان تولید شده در توربین‌های بادی، نشان داده شود. برای دستیابی به این هدف، عملکرد سه روش فازی برای حل این مسئله مورد تحلیل و بررسی قرار گرفته است. ابتدا با استفاده از داده‌های تاریخی باد، الگوریتم‌های حداقل مربعات (BLS) و حداقل مربعات مجاز (RLS) اجرا می‌شوند. در ادامه، الگوریتم RLS با استفاده از تکنیک یادگیری اصلاح شده (MLFE)، تلفیق شده تا دقت پیش بینی را افزایش دهد. همچنین، شبکه های عصبی مصنوعی (ANN) به دلیل توانایی بالا در حل چنین مسائلی به منظور مقایسه و تایید نتایج بدست آمده، مورد استفاده قرار گرفته است. در نهایت آنالیز حساسیت برخی از پارامترها بر روی پیش بینی توان مزارع بادی مورد بررسی قرار گرفته است. نتایج نشان می‌دهد گرچه اکثر روش‌های فازی و ANN توانایی خوبی برای حل مسئله پیش بینی دارند، اما الگوریتم پیشنهادی (RLS-MLFE) به مراتب از دقت بهتری نسبت به دیگر روش ها برخوردار می باشد.

واژه‌های کلیدی: آنالیز فازی، عدم قطعیت توان باد، الگوریتم MLFE، شبکه های عصبی مصنوعی.

تاریخ ارسال مقاله : ۱۳۹۸/۰۵/۲۴

تاریخ پذیرش مقاله : ۱۳۹۹/۰۲/۰۷

نام نویسنده‌ی مسئول : محسن داودی

نشانی نویسنده‌ی مسئول : دانشگاه بین المللی امام خمینی - ایران

۱- مقدمه

به دلیل بحران های شدید انرژی و تغییرات آب و هوایی، منابع انرژی تجدیدپذیر در دهه های اخیر به طور گسترده ای برای تولید برق استفاده می گردند. با توجه به پاکیزگی و قابلیت دسترسی گسترده، مزارع بادی تبدیل به یکی از محبوب ترین منابع انرژی تجدید پذیر در سراسر جهان شده اند. ظرفیت نصب شده مزارع بادی در سراسر جهان در دهه گذشته حدود ۳۰ برابر افزایش یافته و تا پایان سال ۲۰۱۳ به حدود ۳۲۰ گیگاوات رسیده است [۱]. با این حال، تصادفی بودن و متناوب بودن تولید توان باد، منجر به چالش مهمی در ادغام آنها با سیستم های قدرت موجود شده است. این مشکل به طور عمده ناشی از ویژگی های ناپایدار و نامشخص سرعت باد و نیز رابطه غیر خطی بین سرعت باد و توان باد می باشد. به منظور مقابله با این چالش، پیش بینی تولید انرژی باد به عنوان یکی از راه حل های ارزان قیمت شناخته می شود [۲]. بنابراین، پیش بینی دقیق و قابل اعتماد در مورد توان باد جهت کاهش هزینه های بهره برداری، ارزیابی امنیت شبکه، بهبود قابلیت اطمینان و برنامه های کاربردی مانند بازار برق، به مدار آوردن واحدها و پخش اقتصادی بار در سیستم های قدرت با نفوذ بالای باد بسیار سودمند است.

در بسیاری از تحقیقات پیش بینی تولید توان باد با دقت بالا به کمک رویکردهای بسیار پیچیده انجام شده اند. این رویکردها را می توان به سه دسته تقسیم کرد: (۱) رویکردهای فیزیکی؛ (۲) رویکردهای آماری؛ و (۳) رویکردهای مبتنی بر هوش مصنوعی. در گروه اول، بر اساس مدل های فیزیکی روند تبدیل را شبیه سازی نموده و توان خروجی را مستقیماً محاسبه می کنند. در گروه دوم، روش های آماری براساس تحلیل سری های زمانی داده های تاریخی توان خروجی باد عمل می نمایند. در گروه سوم، روش یادگیری ماشین است که رابطه بین توان خروجی و ورودی های عددی را آموزش می دهند. بعضی از تحقیقات گذشته که رویکردهای مبتنی بر دسته بندی های ذکر شده را برای پیش بینی تولید انرژی باد آینده بکار برده اند، به صورت زیر مورد بررسی قرار می گیرند.

در [۳] یک رویکرد مبتنی بر منطق فازی برای تولید فواصل پیش بینی شرطی پیشنهاد شده است. در اینجا، از روش غیر پارامتریک برای تنظیم فواصل پیش بینی استفاده می کند. در [۴]، توزیع نرمال منطقی برای مقابله با ماهیت غیر خطی توان باد در مدل پیش بینی احتمالاتی ارائه شده، پیشنهاد شده است. در [۵]، پیش بینی احتمالاتی توان باد برای هدایت تصمیم گیری در مورد تجارت انرژی باد در بازارهای روز قبل و زمان واقعی توسعه داده شده است. پیش بینی های کمی برای هدایت تصمیمات بهینه با سطوح نامی در [۶] ارائه شده است. در [۷]، پیش بینی فاصله ای از تولید توان باد پیشنهاد شده است تا راه حلی برای ارزیابی و اندازه گیری اثرات بالقوه و خطرات سیستم در مواجهه با نفوذ باد را ارائه دهد. در [۸]، با توجه به رزرو، ساختار بازار و تغییرات زیرساخت های سیستم قدرت جهت دستیابی به تعادل بهینه انرژی در کوتاه مدت برای مقابله با عدم قطعیت انرژی باد مورد بررسی قرار گرفته است. تأثیر تغییرات توان باد در برنامه ریزی تولید در [۱۰] مورد بررسی

قرار گرفته است و نشان داده شده است که خروجی های سیستم مانند تعادل توان، رزرو و پخش توان بسیار تحت تأثیر قرار خواهد گرفت. برای این مسئله روش های مختلف پیش بینی پیشنهاد شده است. یکی از روش های اصلی در بسیاری از مطالعات، تابع چگالی احتمال (PDF) است که برای پیش بینی توان باد ارائه شده است. پیش از این، عمدتاً توزیع گاوسی [۱۱] و توزیع β [۱۲-۱۳] مورد استفاده قرار گرفته است. توزیع دیگری مانند توزیع کوشی [۱۴]، توزیع γ [۱۵] و توزیع ویبول [۱۶] مورد آزمایش قرار گرفته است. هر یک از روش های پیشنهادی به دلایلی برای پیش بینی های توان باد مناسب نیست. به عنوان مثال، توزیع گاوسی نمی تواند ویژگی دنبال کنندگی توان باد را مشخص کند و در شرایط خاص، توزیع β به اندازه کافی برای مدل سازی داده های توان باد دنبال نمی شود. در [۱۷]، توزیع α -پایدار به عنوان یک مدل تشخیص دقیق برای توصیف ویژگی های متعدد از داده های توان باد ارائه شده است.

تکنیک شبیه سازی مونت کارلو (SMCS) به طور کلی برای مدل خروجی توان تولیدی باد در سیستم های قدرت مورد استفاده قرار گرفته است [۱۸]. روش SMCS بهترین روش برای ارزیابی مطالعات انرژی باد است. با این حال، مقیاس محاسبه این روش و ضروری بودن داده های تاریخی سرعت باد، عملی بودن آن را در مقابله با شبکه های بزرگ با مشکلاتی مواجه می سازد [۱۹]. برای پوشش نقص های مربوط به روش های ذکر شده در کارهای قبلی، پیشنهاداتی در [۲۰] ارائه شده است، اما همچنان از دقت مناسبی برخوردار نمی باشند. همچنین نویسندگان در [۲۱] یک روش تحلیلی چند حالتی را براساس روش خوشه بندی فازی c-means برای پیش بینی های توان باد ارائه داده اند. ناکارآمدی این روش این است که تعداد کم حالتها دقیقاً نمیتوانند پاسخ را نشان داده و این در حالیست که اطلاعات تاریخی طولانی و زیادی نیز لازم است.

در مسئله به مدار آوردن واحدها، روشهای بهینه سازی تصادفی (SO) برای مقابله با عدم قطعیت انرژی باد پیشنهاد شده است [۲۲-۲۴]. روش SO با استفاده از سناریوهای مختلف احتمال مربوط به عدم قطعیت ها بکار گرفته می شود. دقت و بهینه بودن راه حل SO بستگی به دقت توزیع احتمالی متغیرهای عدم قطعیت و تعداد سناریوهای ارائه شده در مسأله بهینه سازی دارد. تعداد زیادی از سناریوها، اگرچه میتوانند دقت حل مسئله را بهبود دهد، اما منجر به پیچیدگی محاسبات مسئله می شود [۲۵]. در چنین مواردی، تکنیک های کاهش سناریو می توانند مقیاس روش SO را کاهش داده و حجم محاسبه را کاهش دهند [۲۶-۲۷]. برای اصلاح امنیت سیستم، روش بهینه سازی مقاوم (RO)، نوسانات انرژی باد را در یک محدوده مشخص شده در اطراف یک پیش بینی مرکزی مجاز می داند [۲۸-۳۰]. بنابراین، نتایج RO در مقایسه با SO بسیار محافظه کارانه است [۳۱]. روش بهینه سازی فاصله ای (IO) هزینه بهره برداری را در حالی که امکان انتقال در محدوده های مشخص به عنوان بازه پیش بینی شده (PI)، اطراف پیش بینی مرکزی

وجود دارد، کاهش می دهد [۳۲-۳۳]. در مقایسه با SO، IO در طرح های محافظه کارانه کارایی بیشتری دارد و حجم محاسبه کمتر را می طلبد [۳۲]. در مقایسه با RO، IO نتایجی با دقت کمتری را ارائه می کند، بنابراین RO براساس بدترین سناریو ممکن عدم قطعیت می باشد. روش های ترکیبی برای افزایش کارایی و بهبود نتایج ارائه شده است. روش ترکیبی RO و SO پیشنهاد شده تا یک روش مقاوم تر را در مقایسه با RO و با هزینه کمتر نسبت به SO در [۳۳] ایجاد کند. همچنین، مراجع [۳۴] و [۳۵] مجموعه ای از محدودیت های امنیتی را برای افزایش سرعت حل مسئله نادیده گرفته است. در [۳۶]، یک مدل بهینه سازی قابل تنظیم فاصله (AIO) برای بهبود امنیت سیستم های قدرت با نفوذ بالای مزارع بادی پیشنهاد شده است.

در [۳۷] مدل های پیش بینی کوتاه مدت، میان مدت و بلند مدت از انرژی باد با استفاده از ترکیب روش های مختلفی از جمله هوش محاسباتی، شبکه های عصبی، تکنیک ویولت و مدل آریمای ارائه شده است. این روش ها در چهار مدل مختلف برای پیش بینی سرعت باد طراحی شده اند که عبارتند از: آریمای + ویولت، شبکه های عصبی و آریمای + شبکه های عصبی. نتایج نشان داده که ترکیب برخی از روش ها در بهبود دقت پیش بینی انرژی باد موثر می باشد. بطور مثال مدل آریمای + شبکه های عصبی از دقت بالایی برخوردار بوده ولی مدل آریمای + ویولت دقت مناسبی نداشته است. در [۳۸] براساس تکنیک تبدیل موجک و روش آنالیز سری های زمانی، یک مدل کوتاه مدت برای پیش بینی انرژی باد ارائه شده است. شبیه سازی ها با داده های واقعی انجام شده و نتایج نشان می دهد که میانگین خطای نسبی در پیش بینی های چند مرحله ای در روش پیشنهادی بسیار اندک است. همچنین روش پیشنهادی در مواجهه با داده های دارای پرش مقاوم بوده و برای پیش بینی سرعت و توان انرژی باد قابل استفاده است. در [۳۹] یک شبکه عصبی ترکیب شده با تبدیل موجک با پیش پردازش داده ای ورودی نیمه پارامتری برای پیش بینی توان باد مورد استفاده قرار گرفته است. داده های سرعت باد با روش مبتنی بر پردازش نیمه پارامتری از قبل پردازش می شوند. اثر بخشی روش نیز با پیش بینی باد در طول یک سال بررسی شده است. در حالیکه هر یک از روش های ذکر شده به عنوان مدلی برای پیش بینی احتمالی توان باد مفید می باشند، اما همچنان تحقیقات برای یافتن روش های با دقت بالا ادامه دارد. نکته ای که باید به آن توجه نمود این است که تاکنون استفاده از الگوریتم های فازی برای پیش بینی انرژی باد مورد توجه قرار نگرفته است. از همین رو تمرکز اصلی این مقاله به بکارگیری الگوریتم های فازی در موضوع پیش بینی انرژی باد می باشد.

عدم قطعیت انرژی باد نشان دهنده تفاوت بین مقدار واقعی خروجی توربین بادی و مقدار پیش بینی شده است. یکی از راه های کاهش این عدم قطعیت، افزایش دقت مقدار پیش بینی شده می باشد. در این مقاله هدف اصلی کاهش اثر عدم قطعیت ناشی از انرژی باد می باشد. بنابراین، روش های تحلیل فازی برای بهبود پیش بینی توان خروجی توربین های

باد استفاده شده اند. این روش ها شامل الگوریتم های کمترین مربعات (BLS) و کمترین مربعات مجاز (RLS) می باشند. همچنین الگوریتم ترکیبی MLFE-RLS که شامل مزایای الگوریتم RLS و تکنیک MLFE است، برای پیش بینی توان خروجی توربین باد استفاده می شود. علاوه بر این، به منظور تصدیق نتایج بدست آمده با الگوریتم های فازی و مقایسه آنها از شبکه عصبی برای حل مسئله پیش بینی انرژی باد به دلیل توانایی بالا در پیش بینی مسائلی مانند پیش بینی باران، پیش بینی بار سیستم قدرت، پیش بینی قیمت و غیره استفاده شده است. همچنین آنالیز حساسیت مربوط به برخی از پارامترها بر روی مقادیر پیش بینی شده نیز مورد ارزیابی قرار گرفته است. لازم به ذکر است که هیچ کدام از روش های فوق در آثار قبلی مورد استفاده قرار نگرفته اند. نوآوری های اصلی این مطالعه بصورت خلاصه بشرح زیر می باشند:


- استفاده از استراتژی جدید مبتنی بر منطق فازی برای مقابله با عدم قطعیت انرژی باد.
- بهبود سرعت و دقت الگوریتم RLS بکمک تکنیک MLFE.

ادامه ساختار مقاله بشرح زیر می باشد: عدم قطعیت قدرت باد در بخش دوم بیان شده است. در بخش سوم ساختار الگوریتم های BLS و RLS به طور مختصر توضیح داده شده است. الگوریتم ترکیبی RLS و MLFE در بخش چهارم ارائه شده است. در بخش پنجم شبکه های عصبی شرح داده شده است. در نهایت نتایج و نتیجه گیری به دست آمده در بخش های ۶ و ۷ خلاصه شده است.

۲- عدم قطعیت انرژی باد

در سال های اخیر، اقدامات انجام شده برای مقابله با انتشار گازهای گلخانه ای عمدتاً شامل افزایش سطح نفوذ منابع تولید برق تجدید پذیر و کم کربن بوده اند، در این بین تولید انرژی بادی به عنوان یکی از منابع برتر به شمار می رود. در واقع، انرژی باد یکی از فن آوری های تولید انرژی است که می تواند کاهش انتشار CO₂ در بخش تولید انرژی الکتریکی در کشورهای صنعتی را فراهم نماید [۴۰-۴۱]. تولید توان ناشی از انرژی باد عاری از انتشار گازهای گلخانه ای بوده و برای توسعه پایدار بسیار مناسب می باشد. علاوه بر این، از لحاظ فنی، توان باد می تواند توسعه اقتصادی و رقابتی تسریع بخشد و از لحاظ ایجاد اشتغال نیز پیشرو می باشد. مزارع بادی سوخت مصرف نمی کنند، در نتیجه می توانند هزینه های بهره برداری را کاهش دهند و از نوسان قیمت انرژی جلوگیری نمایند. همچنین این نیروگاه ها دارای نرخ خروج احتمالی پایینی هستند [۴۲-۴۴].

با توجه به تصادفی بودن ذاتی پدیده طبیعی باد، قدرت باد نمی تواند به شکل سنتی تحویل داده شود. بنابراین، تولید باد متغیر و دارای عدم قطعیت است. در نتیجه، ادغام گسترده آن در یک سیستم قدرت، یک چالش منحصر به فرد برای اپراتورها و برنامه ریزان سیستم قدرت ایجاد می نماید [۴۴]. بخشی از عدم قطعیت توان باد می تواند با افزایش رزرو



شکل ۲: تابع عضویت دلتا

همچنین، تابع عضویت خروجی یک تابع دلتا است که یک تابع ضربه با عرض صفر و تنها یک مقدار با عضویت کامل در b_i قرار دارد و تمام مقادیر دیگر صفر هستند (می توانید به شکل ۲ مراجعه نمایید). الگوریتم هایی که در اینجا ارائه شده است، یک مدل براساس ضوابط را توسعه می دهند و یا از یک سری ضوابط پیش تعیین شده برای مدل سازی سیستم و پیش بینی خروجی ها با توجه به ورودی ها استفاده می کنند؛ در هر صورت، ضوابط شامل یک بند پیش فرض و نتیجه می شوند. یک مثال معمول از یک ضابطه برای سیستم چند ورودی و یک خروجی می تواند به شرح زیر باشد:

"اگر فرض ۱ و فرض ۲ برقرار باشند سپس نتیجه بدست می آید" همانطور که قبلا ذکر شد، تابع عضویت گاوسی برای توابع فرضی ورودی و دلتا برای خروجی استفاده می شود و در نتیجه معادله زیر برای پیش بینی خروجی بواسطه داده های ورودی X_i می باشد:

$$f(x|\theta) = \frac{\sum_{i=1}^R b_i \prod_{j=1}^n \exp[-\frac{1}{2}(\frac{x_j - c_j^i}{\sigma_j})^2]}{\sum_{i=1}^R \prod_{j=1}^n \exp[-\frac{1}{2}(\frac{x_j - c_j^i}{\sigma_j})^2]} \quad (1)$$

در اینجا، R تعداد ضوابط موجود و n تعداد ورودی ها در هر داده m تایی است. تعداد R برای برخی از روش ها از پیش تعیین نشده است، بلکه توسط الگوریتم ها تعیین می شود. نماد θ یک بردار است که شامل پارامترهای مربوط به توابع عضویت از جمله ضوابط، c_i ، σ_i و b_i است.

۳-۱- الگوریتم BLS

الگوریتم BLS [۴۵]، یک مدل فازی از داده های عددی را ایجاد می کند که می تواند برای پیش بینی خروجی های هر ورودی مورد استفاده قرار گیرد. بنابراین، مجموعه داده ها را می توان به عنوان یک مجموعه آموزشی برای مدل سازی سیستم مورد استفاده قرار داد. هنگام استفاده از الگوریتم BLS برای توسعه یک مدل فازی داشتن اطلاعات در مورد رفتار مجموعه داده ها به منظور ایجاد ضوابط [۴۶-۴۷] مفید می باشد. مراحل الگوریتم BLS برای پیش بینی خروجی می تواند به صورت زیر تعیین شود:


گام اول: شناسایی ورودی ها (با داده های تاریخی) برای آموزش مدل فازی. برای انجام این کار، می توانید ماتریس ها را به صورت زیر تعریف کنید:

در سیستم قدرت مدیریت شود. اما این هزینه بهره برداری را افزایش می دهد. همچنین، بخشی از این تغییرات می تواند چند ساعت یا چند روز قبل پیش بینی شوند. با افزایش دقت پیش بینی ها، نیاز به خدمات رزرو کاهش می یابد و هزینه های بهره برداری سیستم قدرت نیز کاهش می یابد. بنابراین، جهت برنامه ریزی و بهره برداری از سیستم های قدرت برای مقابله با ماهیت پیچیده توان باد بمنظور حفظ و یا حتی افزایش قابلیت اطمینان فعلی و بهبود عملکرد اقتصادی سیستم های قدرت نیازمند پیش بینی های دقیق عدم قطعیت باد هستیم.

۳- الگوریتم های BLS و RLS

اغلب دشوار یا غیرممکن است که به طور دقیق مدل فرآیند های پیچیده طبیعی یا سیستم های مهندسی شده را با استفاده از رویکرد ریاضی غیر خطی موجود با دانش قبلی مدلسازی نمود. در حالت ایده آل، محققان از اطلاعات و دانش حاصل از آزمایشات یا آزمایش های قبلی به منظور توسعه یک مدل و پیش بینی نتایج استفاده می کنند، اما برای سیستم های جدید که کمتر شناخته شده هستند یا تجزیه و تحلیل های تجربی بیش از حد پر هزینه است، دانش و اطلاعات پیشین اغلب در دسترس نیست. این فقدان اطلاعات یا عدم دسترسی دانش شناختی از سیستم، ایجاد یک مدل با استفاده از ابزارهای معمول را بسیار دشوار و اغلب غیرممکن می سازد. علاوه بر این، تشکیل حاکمیت زبان شناختی سیستم ممکن است بدون انجام مشاهدات اضافی غیر عملی باشد. خوشبختانه، در شرایطی مانند این، مدل سازی فازی بسیار عملی است و می تواند برای ایجاد یک مدل از سیستم با استفاده از اطلاعات «محدود» در دسترس مورد استفاده قرار گیرد.

توابع ورودی و خروجی ممکن است از انواع مختلفی از قبیل گاوسی، مثلثی، دوزنقه ای، L و S شکل، چهارگوش و دلتا استفاده شوند. این مقاله از توابع عضویت گاوس برای ورودی $\mu(x)$ استفاده می کند. شکل ۱ یک تابع عضویت گاوسی معمولی و پارامترهای مربوطه را نشان می دهد. که در آن، X_i متغیر ورودی i ام است، c_i مرکز i ام تابع عضویت است (در اینجا تابع عضویت حداکثر مقدار را به دست می آورد)، و σ_i ثابت است که مربوط به گسترش تابع عضویت i است.



شکل ۱: تابع عضویت گاوسی

گام سوم: برای $m = 1, 2, \dots, m$ روابط مربوط به ماتریس های $P(k)$ و $\theta(k)$ بصورت زیر است:

$$P(k) = \frac{1}{\lambda} \left[(I - P(k-1)\xi^T(x^k))(\lambda I + \xi(x^k)P(k-1)\xi^T(x^k))^{-1} \right] P(k-1) \quad (9)$$

$$\theta(k) = \theta(k-1) + P(k)\xi^T(x^k)[Y - \xi(x^k)\theta(k-1)] \quad (10)$$

در اینجا λ فاکتور وزنی از ۰ تا ۱ است. برای این مسئله، ما از $\lambda = 1$ استفاده کنیم تا همه اطلاعات آموزشی را به طور مساوی وزن کنیم.
گام چهارم: تشکیل ماتریس RLS با استفاده از فرمول زیر:

$$RLS = \begin{bmatrix} F_1 \\ F_2 \\ \vdots \\ F_k \end{bmatrix} \quad (11)$$

نکته ۲: مشابه الگوریتم BLS، دقت مدل فازی که با استفاده از RLS گسترش می یابد، عمدتاً به قواعد مشخص شده در ضوابط و مجموعه داده های مورد استفاده برای آموزش مدل فازی بستگی دارد.

۴- الگوریتم ترکیبی (هیبرید)

همانطور که قبلاً ذکر شد، دقت الگوریتم RLS به شدت وابسته به ضوابط مشخص شده است، بنابراین اگر محقق به اندازه کافی اطلاعات از سیستم برای مشخص کردن پارامترهای مورد نیاز برای تعریف ضوابط پایه نداشته باشد، او می تواند با استفاده از الگوریتم های مانند MLFE این کار را انجام دهد. در واقع، ویژگی اصلی الگوریتم MLFE توانایی تعیین دقیق ضوابط است. به همین دلیل، برخی از الگوریتم ها می توانند برای توسعه بهتر یک مدل ترکیب شوند. به عنوان مثال، در این مقاله، MLFE با RLS برای توسعه موثرتر یک مدل استفاده می شود. هنگامی که پارامترهای توابع عضویت مربوط به ضوابط توسط MLFE مشخص شوند، الگوریتم RLS برای پیش بینی خروجی با توجه به ورودی مورد استفاده قرار می گیرند. فلوجارت الگوریتم ترکیبی در شکل ۳ نشان داده شده است (جزئیات در [۴۶] ارائه شده است). نکته ای که باید توجه کرد این است که تعداد ضوابط پایه می تواند تا m افزایش یابد ($R = m$).

۵- شبکه های عصبی

شبکه های عصبی تکنیکهایی هستند که به دنبال ایجاد برنامه های هوشمند می باشند. در واقع، شبکه عصبی مصنوعی یک سیستم پردازش داده ها است که براساس مغز انسان عمل می نماید. این ایده منجر به نوعی پردازش داده ها در فرآیند ها می شود تا نوروں های مصنوعی متصل شده را در یک شبکه موازی با یکدیگر برای حل مسائل ایجاد کنند [۵۱-۵۰]. اجزای شبکه عصبی لایه ها و ضرایب وزنی هستند. رفتار شبکه نیز بستگی به ارتباط بین اعضا دارد. به طور کلی، سه نوع لایه در شبکه عصبی وجود دارد [۵۰].

$$X = []_{m \times n}, \quad Y = []_{m \times 1} \quad (2)$$

در اینجا، X و Y بترتیب متغیرهای ورودی و خروجی هستند. n تعداد متغیرهای ورودی و m تعداد داده های هر ورودی می باشند.

گام دوم: تعیین تعداد ضوابط و ماتریس های C_{ji} و σ_{ji} و b_i مرتبط با توابع عضویت.

گام سوم: محاسبه بردار رگرسیون $\hat{y}$ به صورت زیر و قرار دادن آن در یک ماتریس Φ .

$$\xi_i(x^k) = \frac{\prod_{j=1}^n \exp \left[-\frac{1}{2} \left(\frac{x_j - c_j^i}{\sigma_j} \right)^2 \right]}{\sum_{i=1}^R \prod_{j=1}^n \exp \left[-\frac{1}{2} \left(\frac{x_j - c_j^i}{\sigma_j} \right)^2 \right]} \quad \text{for } i = 1, 2, \dots, n \text{ and } k = 1, 2, \dots, m \quad (3)$$

$$\varphi = \begin{bmatrix} \xi^T(x^1) \\ \xi^T(x^2) \\ \vdots \\ \xi^T(x^m) \end{bmatrix} \quad (4)$$

گام چهارم: محاسبه ماتریس $\theta(0)$ از طریق معادله زیر:

$$\theta(0) = (\varphi^T \varphi)^{-1} Y \quad (5)$$

گام پنجم: تشکیل ماتریس BLS با استفاده از فرمول زیر:

$$F_K = \theta_{(0)}^T \cdot \xi_{(x^k)}^T \quad (6)$$

$$BLS = \begin{bmatrix} F_1 \\ F_2 \\ \vdots \\ F_k \end{bmatrix} \quad (7)$$

نکته ۱: دقت مدل فازی که با استفاده از الگوریتم BLS گسترش می یابد، عمدتاً به قواعد مشخص شده در ضوابط و مجموعه داده ها برای آموزش مدل فازی بستگی دارد.

۲-۳ الگوریتم RLS

الگوریتم RLS [۴۲] دارای شباهت زیادی به الگوریتم BLS است؛ با این حال، الگوریتم RLS به روزرسانی ماتریس θ را بسیار ساده تر انجام می دهد. الگوریتم RLS یک نسخه بازگشتی از روش BLS است. این کار بدون استفاده از تمام داده های آموزشی و مهمتر از آن بدون نیاز به محاسبه معکوس $\Phi^T \Phi$ در هر بار به روز رسانی θ انجام می شود [۴۶]. [۴۸] و [۴۹]. الگوریتم RLS نیاز دارد که ضوابط تعیین شود (به عنوان مثال تعداد ضوابط، مرکز توابع عضویت ورودی، عرض نسبی توابع عضویت ورودی و مرکز توابع عضویت خروجی). مجموعه داده های آموزشی باید شامل یک زیر مجموعه ای از اطلاعات مناسب باشند. مراحل الگوریتم RLS برای پیش بینی خروجی به صورت زیر می باشند:

گام اول: ابتدا گام های ۱ تا ۴ الگوریتم BLS انجام می شود.

گام دوم: محاسبه ماتریس $P(0)$ بصورت زیر:

$$P(0) = \alpha * I_{R \times R} \quad (8)$$


مقدار پارامتر α باید بزرگتر از صفر باشد. در اینجا مقدار $\alpha = 2000$ در نظر گرفته شده است. ماتریس I یک ماتریس واحد $R \times R$ می باشد.

خروجی مزرعه باد در این مقاله استفاده شده اند [۵۲]. داده های مربوط به سرعت باد طی بازه های زمانی ده دقیقه ای در تاریخ ۱۰ ژانویه ۲۰۱۷ به عنوان داده های آموزشی برای مدل سازی توربین های بادی در الگوریتم پیشنهادی مورد استفاده قرار گرفته اند. همانطور که قبلا ذکر شد، انتظار می رود الگوریتم های فازی با دقت قابل قبولی داده های آموزشی را نگاشت نمایند. علاوه بر این داده های ۱۳ ژانویه ۲۰۱۷ به عنوان یک مجموعه آزمایشی انتخاب شده اند. شبیه سازی ها در سه بخش انجام شده است. روند ارزیابی الگوریتم پیشنهادی بدین صورت خواهد بود که با استفاده از داده های آموزشی ابتدا نسبت به آموزش الگوریتم های فازی اقدام نموده و پس از تعیین پارامترها و ضوابط مورد نیاز نسبت پیش بینی مقادیر آزمایشی اقدام می نماییم. بنابراین معیار بررسی الگوریتم پیشنهادی به اختلاف بین مقادیر پیش بینی شده توسط الگوریتم های فازی و داده های واقعی آزمایشی (داده های ۱۳ ژانویه ۲۰۱۷) بستگی دارد. درواقع هرچه مقادیر پیش بینی شده به مقادیر واقعی نزدیکتر باشند، می توان ادعا نمود الگوریتم پیشنهادی عملکرد قابل قبولی دارد. همچنین با توجه به اینکه در اینجا از داده های واقعی مربوط به یک مزرعه بادی استفاده شده است، با تایید عملکرد الگوریتم پیشنهادی می توانیم به قابلیت استفاده از این الگوریتم در سیستم های واقعی جهت بهبود تصمیم های بهره بردار سیستم قدرت پی ببریم.

نکته ای که در زمینه شبیه سازی های انجام شده در این مقاله جهت تایید عملکرد الگوریتم پیشنهادی باید بدان توجه نمود این است که به منظور نشان دادن توانایی تعمیم پذیری الگوریتم پیشنهادی در پیش بینی خروجی انرژی باد سعی بر این بود که از داده های مربوط به مزارع باد در کشور ایران استفاده شود تا براحتی بتوان نسبت به کیفیت پیش بینی ها نظر داد. اما بدلیل محدودیت های موجود امکان دسترسی به این اطلاعات محیا نبوده و از این رو داده های مربوط به مزرعه بادی ذکر شده در کشور اسپانیا مورد استفاده قرار گرفت.

۱-۶- الگوریتم های BLS و RLS

در این بخش، توانایی الگوریتم های BLS و RLS در پیش بینی انرژی باد مورد ارزیابی قرار گرفته است. برای این منظور ابتدا مدل توربین بادی با استفاده از داده های آموزشی به دست آمده و سپس توان خروجی مزرعه باد با استفاده از مجموعه آزمایشی تعیین شده است. در این الگوریتم ها یکی از مهمترین پارامترهایی که بر روی دقت پیش بینی انرژی باد اثرگذار است، تعداد ضوابط پایه می باشد. از طرفی روش مشخصی برای تعیین تعداد این ضوابط در الگوریتم های BLS و RLS وجود ندارد و بنابراین کاربر بایستی با استفاده از روش آزمون و خطا تعداد ضوابط را تعیین نماید. اما نکته ای که در این زمینه باید به آن توجه نمود سرعت همگرایی الگوریتم ها می باشد که با افزایش تعداد ضوابط رابطه مستقیم داشته و در نتیجه در سیستم های آنلاین کارآمد نخواهد بود. پس تعیین تعداد مناسب ضوابط که علاوه بر دقت، سرعت همگرایی الگوریتم ها را نیز در شرایط معقول حفظ نماید ضروری می



شکل ۳: فلوچارت الگوریتم ترکیبی

لایه ورودی: داده های خام را دریافت و شبکه را تغذیه می نماید.

لایه های پنهان: عملکرد این لایه به وسیله ضرایب وزنی ورودی و ارتباط بین آنها و لایه های مخفی تعیین می شود.

لایه خروجی: بسته به فعالیت و وزن لایه مخفی، عملکرد لایه خروجی به ارتباط بین لایه های مخفی و خروجی وابسته است. در این مقاله، از یک ساختار چند لایه شبکه عصبی استفاده شده است.


۶- شبیه سازی

در این بخش به منظور تایید عملکرد و ارزیابی الگوریتم پیشنهادی پیش بینی انرژی باد یک مزرعه باد واقعی بنام Sotavento Galicia در کشور اسپانیا مورد مطالعه قرار گرفته است. این مزرعه بادی شامل ۲۴ توربین بادی با قدرت ۱۷،۵۶ مگاوات و متوسط تولید سالانه ۳۳،۳۶۴ مگاوات می باشد. داده های تاریخی مزرعه باد که توسط شرکت Sotavento Galicia اندازه گیری و ذخیره شده، برای پیش بینی

باشد. نتایج شبیه سازی با الگوریتم های BLS و RLS در شکل های ۴ و ۵ نشان داده شده است. این نتایج از دو بخش تشکیل شده اند. یابد. حدی بهبود می یابد اما در طرف مقابل سرعت همگرایی آن کاهش می یابد.

پارامترهای ورودی				پارامتر رگرسیون
C_1	C_2	σ_1	σ_2	θ
۷,۷۸	۲۸,۳	۰,۶۵	۰,۷۵	۵
۷,۱۴	۲۸	۰,۷۳	۰,۳	۵
۷,۰۸	۲۶,۸	۰,۰۶	۱,۲	۵
۶,۳۹	۲۶,۹	۰,۶۹	۰,۱	۵
۷,۷۳	۲۷,۴	۰,۱۴	۰,۵	۵
۷,۶۳	۲۶,۹	۰,۱	۰,۲	۵
۷,۱۴	۲۶,۲	۰,۰۵	۰,۶	۵
۷,۶۱	۲۷,۶	۰,۰۵	۰,۲	۵
۹,۱۸	۲۸,۵	۱,۳۱	۰,۲	۵
۹,۵	۲۸,۷	۰,۳۲	۰,۲	۵
۱۰,۲۳	۳۰,۶	۰,۷۳	۰,۲	۵
۸,۴۱	۳۰	۰,۶۴	۱,۹	۵
۱۰,۶۹	۳۱,۲	۰,۴۶	۰,۶	۵
۸,۷۲	۳۱	۰,۳۱	۰,۸	۵
۱۰,۴۲	۳۲,۳	۰,۱۹	۰,۲	۵
۸,۰۷	۳۱,۳	۰,۲	۱,۱	۵
۸,۴۹	۳۱,۴	۰,۰۷	۰,۳	۵
۹,۲۸	۳۲,۹	۰,۲۲	۰,۱	۵
۷,۲۸	۳۱,۷	۰,۱۴	۰,۷	۵
۷,۹۷	۳۲,۵	۰,۱	۰,۳	۵
۶,۴۶	۳۱,۴	۰,۳۲	۰,۲	۵
۷,۱۷	۳۲	۰,۰۹	۰,۱	۵
۸,۵۴	۳۱,۳	۰,۰۶	۰,۳	۵
۷,۵۹	۳۲	۰,۱۴	۰,۲	۵
۷,۵۹	۳۲,۶	۰,۱۴	۰,۲	۵
۸,۸۴	۳۲,۹	۰,۱۲	۰,۱	۵
۹,۳۱	۳۱,۸	۰,۰۵	۰,۰۵	۵
۶,۷۶	۳۲,۵	۰,۰۵	۰,۰۵	۵
۸,۳۱	۳۲,۲	۰,۱۹	۰,۰۵	۵
۶,۹۸	۳۲,۲	۰,۲۳	۰,۲	۵
۹,۳۹	۳۲,۵	۰,۰۸	۰,۱	۵
۸,۱۳	۳۳,۳	۰,۰۷	۰,۰۵	۵
۱۰,۳۴	۳۲,۸	۰,۰۸	۰,۴	۵
۶,۷۴	۳۳,۲	۰,۰۵	۰,۱	۵
۸,۳۱	۳۳	۰,۰۵	۰,۱	۵
۶,۶۱	۳۳,۲	۰,۱۵	۰,۲	۵
۵,۸۸	۳۲,۹	۰,۷۳	۰,۰۵	۵

جدول ۱: پارامترهای ضوابط مربوط به الگوریتم RLS




شکل ۴: پیش بینی داده های آزمایشی توسط الگوریتم BLS


همچنین نتایج مربوط به عملکرد الگوریتم RLS با در نظر گرفتن دو حالت مختلف برای تعداد ضوابط پایه در شکل ۵ ارائه شده است. نتایج نشان می دهد که دقت الگوریتم RLS کمی بهتر از الگوریتم BLS است. ساختار الگوریتم RLS بسیار شباهت به الگوریتم BLS دارد. اما

بخش اول مربوط به هدف مقاله یعنی پیش بینی توان خروجی مزرعه بادی می باشد. بخش دوم مربوط به آنالیز حساسیت توان خروجی مزرعه بادی نسبت به تغییر تعداد ضوابط پایه است. با توجه به اهمیت تعداد ضوابط پایه، در این بخش پیش بینی مقادیر تحت دو حالت با تعداد ۳ و ۵ ضابطه پایه صورت گرفته است. عملکرد الگوریتم BLS تحت دو حالت مختلف در شکل ۴ نمایش داده شده است. الگوریتم BLS مستلزم آن است که ضوابط مشخص شود (یعنی تعداد ضوابط، مرکز توابع عضویت ورودی، عرض نسبی تابع عضویت ورودی و مرکز توابع عضویت خروجی). همچنین، الگوریتم BLS به روز رسانی مقادیر خروجی پیش بینی را نمی تواند انجام دهد. همانطور که در شکل ۴ نشان داده شده است، با توجه به دلایل ذکر شده، الگوریتم BLS یک خطای پیش بینی بالایی در حدود ۳۳٪ دارد. اما سرعت همگرایی الگوریتم بسیار بالا است. بنابراین الگوریتم BLS را می توان در سیستم هایی که نیاز به سرعت و دقت متوسط دارند مورد استفاده قرار داد. از طرفی آنالیز حساسیت صورت گرفته نشان می دهد که با افزایش ضوابط پایه دقت الگوریتم تا

RLS-MLFE در حالت θ برابر ۵ حدود ۸۱٫۸٪ است، در شرایط θ برابر ۱۰ تقریباً به حدود ۷۶٪ کاهش پیدا می نماید.



شکل ۵: پیش بینی داده های آزمایشی توسط الگوریتم RLS



شکل ۶: پیش بینی داده های آزمایشی توسط الگوریتم ترکیبی

بنابراین می توان نتیجه گرفت که صرفاً افزایش یا کاهش پارامتر θ دلیل مناسبی برای بهبود دقت الگوریتم نمی باشد. بلکه بایستی با تنظیم مناسب θ دقت مقادیر پیش بینی شده را بهبود بخشید. لازم به ذکر است که ترکیبی از دو الگوریتم نرخ همگرایی را کاهش می دهد. اما با وجود دقت بالا، میزان همگرایی می تواند نادیده گرفته شود.

۳-۶- شبکه های عصبی مصنوعی

الگوریتم شبکه های عصبی از داده های آموزشی برای آموزش شبکه عصبی و داده های آزمایشی برای پیش بینی خروجی استفاده می کند. برای سیستمهایی که دارای ماهیت پویا هستند، تابع عضویت فازی بایستی بارها و بارها به روز شود. برای این نوع سیستم ها، استفاده از شبکه های عصبی مفید است زیرا شبکه می تواند خود را تغییر داده تا بتواند تغییرات را نشان دهد. در این مقاله ساختار شبکه ی عصبی پیاده سازی شده دارای سه لایه ورودی، ۱۵ لایه مخفی و یک لایه خروجی است. نتایج پیش بینی شده از مجموعه داده های آزمایشی در شکل ۷ نشان داده شده است. نتایج شبیه سازی همانگونه که انتظار می رفت،


این الگوریتم یک نسخه بازگشتی از روش BLS است. بر اساس نتایج نشان داده شده در شکل ۵، ویژگی به روز رسانی مقادیر خروجی پیش بینی شده با الگوریتم RLS، دقت و خطای پیش بینی نسبت به الگوریتم BLS را کاهش می دهد. همانطور که قبلاً ذکر شد، با انتخاب ضوابط مناسب می توان نتایج را بهبود بخشید. آنالیز حساسیت صورت گرفته برای الگوریتم RLS نشانگر همین موضوع می باشد. زیرا در حالت دوم که تعداد ضوابط پایه ۵ انتخاب می شود، عملکرد الگوریتم بهبود یافته و اختلاف مقادیر پیش بینی شده و مقادیر واقعی کاهش می یابد. در عوض همانند الگوریتم BLS در اینجا نیز سرعت همگرایی کاهش یافته که در برخی شرایط بهره بردار شاید چندان مناسب نباشد. البته ذکر این نکته ضروری است که در سیستم هایی که بصورت آفلاین مورد بهره برداری قرار می گیرند با افزایش تعداد ضوابط پایه می توان به نتایج بسیار بهتری دست یافت.

۲-۶- الگوریتم ترکیبی (هیبرید)

به منظور بهبود کارایی الگوریتم RLS، الگوریتم MLFE برای تعیین ضوابط سیستم فازی استفاده شده است. برای انجام این کار یکی از مجموعه داده های آموزشی استفاده شده است. ضریب وزنی (w) با مقدار ۲٫۱ انتخاب شده و ضریب آزمون (ε) روی ۰٫۴۵ تنظیم شده است. ضوابط مشخص شده توسط الگوریتم MLFE که در الگوریتم RLS مورد استفاده قرار می گیرد، در جدول ۱ نشان داده شده است. علاوه بر این، دو مجموعه داده آموزشی با θ اولیه ۵٫۰ در نظر گرفته شده است. رگرسیون حداقل مربعات وزنی، یعنی $\lambda = 2$ و $\alpha = 2000$ و چرخه آموزش مربوطه، به روی ۲۰۰ تنظیم شده است. با استفاده از پارامترهای ذکر شده، مدل فازی توسعه یافته است. نکته ای که باید یادآور شد این است که تمامی مقادیر مربوط به پارامترهای ذکر شده برای ورودی الگوریتم MLFE جهت تولید ضوابط پایه از طریق روش آزمون و خطا انتخاب و تنظیم شده اند. برای این منظور شبیه سازی های مختلفی با مقادیر متعدد صورت گرفته تا خروجی الگوریتم ترکیبی (RLS-MLFE) از نظر دقت و سرعت همگرایی در وضعیت مناسب قرار داشته باشد. لذا به جهت سادگی نتایج مربوط به پارامترهای ورودی مختلف آورده نشده است. در این میان و برای ارزیابی آنالیز حساسیت و با توجه به اهمیت پارامتر θ ، نتایج الگوریتم ترکیبی تحت دو مقدار مختلف ۵ و ۱۰ بدست آورده شده اند. شکل ۶ مقادیر پیش بینی شده خروجی مزرعه بادی توسط الگوریتم ترکیبی را نشان می دهد.

همانطور که در شکل ۶ دیده می شود، داده های واقعی با دقت بالا توسط الگوریتم RLS-MLFE پیش بینی شده است. تغییر پارامترهای توابع عضویت ورودی با استفاده از الگوریتم دیگر مانند MLFE، نتایج الگوریتم RLS-MLFE را در مقایسه با BLS و RLS بهبود می بخشد. آنالیز حساسیت انجام شده بر روی پارامتر θ نشان می دهد که در حالتی که مقدار پارامتر θ بر روی ۱۰ تنظیم می شود، دقت الگوریتم کاهش می یابد. در حالی که دقت مقادیر پیش بینی شده توسط روش

نشان می دهد که شبکه های عصبی دارای توانایی بالا در حل مسائل مربوط به پیش بینی می باشند.



شکل ۷: پیش بینی داده های آزمایشی توسط شبکه عصبی مصنوعی

۷- نتیجه

خطای نتایج پیش بینی شده توسط الگوریتم های مختلف در جدول ۲ ارائه شده است. همانگونه که مشاهده می شود، بیشترین و کمترین دقت بترتیب مربوط به شبکه های عصبی و الگوریتم BLS است. پس الگوریتم MLFE-RLS بسیار نزدیک به شبکه عصبی می باشد. می توان نتیجه گرفت که الگوریتم پیشنهادی بمانند شبکه های عصبی برای حل مسائل مربوط به پیش بینی علی الخصوص برای حل مسئله پیش بینی توان خروجی توربین بادی مناسب می باشد.

جدول ۲: خطای پیش بینی روش های مختلف

روش	BLS	RLS	MLFE-RLS	شبکه عصبی
خطا	۲۳.۶۳۴۹٪	۲۹.۷۴۲۸٪	۱۷.۶۸۰۶٪	۱۷.۵۷۲۴٪

کاهش اثرات عدم قطعیت انرژی باد یکی از چالش های اصلی طراحان سیستم های قدرت برای آینده است. در این مقاله، تعدادی از روش های فازی برای مقابله با این موضوع معرفی شده اند. این روش ها شامل الگوریتم های BLS، RLS، MLFE-RLS هستند. با توجه به اینکه الگوریتم BLS، یک روش بدون تکرار بوده و از دقت کمی در نتایج برخوردار است، بنابراین، برای حل مشکل پیش بینی، الگوریتم RLS که بهبود یافته الگوریتم BLS است، استفاده شده است. مشکل برورسانی در الگوریتم RLS حل شده است، اما الگوریتم RLS مشابه الگوریتم BLS نمیتواند به طور قابل توجهی عدم قطعیت توان خروجی توربین بادی را کاهش دهد. در نتیجه، برای بهبود دقت پیش بینی ها، الگوریتم ترکیبی (RLS-MLFE) پیاده سازی گردید. ویژگی های اصلی الگوریتم ترکیبی، ترکیب مناسب ضوابط پایه مطابق با شرایط مسئله می باشد که در این مطالعه مورد توجه قرار گرفته است. آنالیز حساسیت انجام شده بر روی پارامتر θ نشان داد که صرفاً افزایش آن نمی تواند در بهبود دقت الگوریتم پیشنهادی موثر باشد. بلکه یک انتخاب مناسب در بهبود شرایط بسیار تاثیرگذار خواهد بود. همچنین شبکه های عصبی که توانایی بسیار خوبی برای حل مسائل مهندسی بسیاری دارند، جهت تایید نتایج بدست آمده استفاده شده است. مقایسه نتایج نشان می دهد که الگوریتم های BLS و RLS عملکرد خوبی در حل مشکل دارند، اما دقت آنها بسیار پایین تر از الگوریتم ترکیبی و شبکه های عصبی است. شبکه های عصبی و الگوریتم ترکیبی نتایج تقریباً یکسان دارند و می توانند شرایط مطلوب برای کاهش هزینه های بهره برداری در سیستم های قدرت آینده ارائه دهند. البته باید یادآور شد که سرعت همگرایی بالای الگوریتم پیشنهادی می تواند به برتری این روش نسبت به شبکه های عصبی دلالت داشته باشد.

به طور کلی نوآوری های این مقاله بشرح زیر می باشند:

(۱) استفاده از روش های فازی (الگوریتم های BLS و RLS) برای حل مسئله پیش بینی انرژی باد.

همانطور که در شکل ۷ دیده می شود، شبکه های عصبی دارای توانایی بالا در حل مسائل پیش بینی هستند. دقت مقادیر پیش بینی شده حدود ۸۲٪ است که بسیار بهتر از الگوریتم های BLS، RLS می باشند. اما در مقایسه با الگوریتم RLS-MLFE دارای دقت تقریباً مشابهی است. بنابراین می توان گفت الگوریتم پیشنهادی در این مقاله از کیفیت لازم جهت پیش بینی توان خروجی توربین های بادی برخوردار می باشد. لازم بذکر است که با افزایش پارامترهای مانند تعداد لایه های ورودی و پنهان و مجموعه داده های آموزشی، می توان دقت شبکه های عصبی را افزایش داد. البته این تغییرات در کنار آثار مثبتی که بر روی دقت پیش بینی انجام شده دارند، می توانند تاثیر منفی بر روی زمان محاسباتی گذاشته و زمان همگرایی مدل را افزایش دهند که این خود در سیستم هایی که به صورت آنلاین نسبت به پیش بینی توان باد اقدام می نمایند یک پوئن منفی بحساب می آید.

از لحاظ زمان محاسباتی، الگوریتم های BLS و RLS در مقایسه با الگوریتم MLFE-RLS و شبکه های عصبی دارای زمان پاسخ بهتر (حدود دو سوم زمان مورد نیاز MLFE-RLS) هستند. زیرا زمان بیشتری برای تعیین ضوابط در الگوریتم MLFE-RLS و آموزش شبکه های عصبی مورد نیاز است. با این حال، از آنجا که دقت نتایج به دست آمده از الگوریتم MLFE-RLS و شبکه های عصبی بهتر از الگوریتم های BLS و RLS، عامل زمان می تواند در مقایسه با روش های فوق نادیده گرفته شود. اما بین دو روش شبکه های عصبی و الگوریتم پیشنهادی که دارای دقت تقریباً مشابهی هستند، عامل زمان می تواند بر روی تصمیماتی که بهره بردار سیستم قدرت قرار است در زمان واقعی اتخاذ نماید بسیار تاثیر گذار باشد. به عنوان مثال بهره بردار باید در لحظه به هر کدام از واحدهای تولیدی جهت تولید یا قطع توان الکتریکی فرمان دهد و در صورتی که از پیش بینی توان باد به سرعت با خبر گردد با دقت بالاتری می تواند نسبت به برقراری تعادل توان بین تولید و مصرف اقدام نموده که در نهایت از تحمیل هزینه های اضافی به مصرف کنندگان برق جلوگیری می شود.

- 4th Conf. Energy Econ. Technol., Dresden, Germany, 2009, pp. 1–6.
- [17] K. Bruninx and E. Delarue, "A Statistical Description of the Error on Wind Power Forecasts for Probabilistic Reserve Sizing" *IEEE Trans. Sustain. Energy*, VOL. 5, NO. 3, JULY 2014.
- [18] R. Billinton and G. Bai, Multistate wind energy conversion system models for adequacy assessment of generating systems incorporating wind energy, *IEEE Trans Energy Convers* 23(1) (2008), 163–170.
- [19] R. Billinton and W. Wangdee, Reliability-based transmission reinforcement planning associated with large-scale wind farms, *IEEE Trans Power Syst* 22(1) (2007), 34–41.
- [20] S. Riahinia, A. Abbaspour, M. Fotuhi-Firuzabad and M. Moeini-Aghaie, A Neural Network-Based Model for Wind Farm Output in Probabilistic Studies of Power Systems, 21st Iranian Conference on Electrical Engineering (ICEE), 2013.
- [21] S. Riahinia, A. Abbaspour, M. Fotuhi-Firuzabad and M. Moeini-Aghaie, "Developing a stochastic framework to determine the static reserve requirements of high-wind penetrated power systems" *Journal of Intelligent & Fuzzy Systems* 29 (2015) 2039–2046.
- [22] F. Bouffard and F. D. Galiana, "Stochastic security for operations planning with significant wind power generation," *IEEE Trans. Power Syst.*, vol. 23, no. 2, pp. 306–316, 2008.
- [23] J. M. Morales, A. J. Conejo, and J. Perez-Ruiz, "Economic valuation of reserves in power systems with high penetration of windpower," *IEEE Trans. Power Syst.*, vol. 24, no. 2, pp. 900–910, 2009.
- [24] A. Papavasiliou, S. S. Oren, and R. P. O'Neill, "Reserve requirements for wind power integration: A scenario-based stochastic programming framework," *IEEE Trans. Power Syst.*, vol. 26, no. 4, pp. 2197–2206, 2011.
- [25] A. Papavasiliou, S. S. Oren, and B. Rountree, "Applying high performance Computing to Transmission-Constrained Stochastic Unit Commitment for Renewable Energy Integration," *IEEE Trans. Power. Syst.*, vol. 30, no. 3, pp. 1109–1120, 2015.
- [26] J. M. Morales, S. Pineda, A. J. Conejo, and M. Carrion, "Scenario reduction for futures market trading in electricity markets," *IEEE Trans. Power Syst.*, vol. 24, no. 2, p. 878–888, 2009.
- [27] M. Kaut and S. W. Wallace, "Evaluation of scenario-generation methods for stochastic programming," *Stochastic Program.*, vol. 3, no. 2, p. 257–271, 2007.
- [28] B. Hu and L. Wu, "Robust SCUC considering continuous/discrete uncertainties and quick-start units: a two-stage robust optimization with mixed-integer recourse," *IEEE Trans. Power Syst.*, vol. 31, no. 2, pp. 1407–1419, 2016.
- [29] Y. Guan and J. Wang, "Uncertainty sets for robust unit commitment," *IEEE Trans. Power Syst.*, vol. 29, no. 3, pp. 1439–1440, 2014.
- [30] W. Wei, F. Liu, S. Mei, and Y. Hou, "Robust Energy and Reserve Dispatch under Variable Renewable Generation," *IEEE Trans. Smart Grid*, vol. 6, no. 1, pp. 369–380, 2015.
- [31] C. Zhao and Y. Guan, "Unified Stochastic and Robust Unit Commitment," *IEEE Trans. Power Syst.*, vol. 28, no. 3, p. 3353–3361, 2013.
- [32] L. Wu, M. Shahidehpour, and Z. Li, "Comparison of scenario-based and interval optimization approaches to stochastic SCUC," *IEEE Trans. Power Syst.*, vol. 27, no. 2, p. 913–921, 2012.
- [33] Y. Yu, P. B. Luh, E. Litvinov, T. Zheng, J. Zhao, and F. Zhao, "Grid integration of distributed wind generation: hybrid markovian and interval unit commitment," *IEEE Trans. Smart Grid*, vol. 6, no. 6, pp. 3061–3072, 2015.
- [34] R. Madani, J. Lavaei, and R. Baldick, "Constraint screening for security analysis of power networks," Preprint 2015, [Online]. Available:

(۲) ترکیب الگوریتم های RLS و MLFE برای افزایش دقت پیش بینی و کاهش خطاها.

(۳) آنالیز حساسیت صورت گرفته جهت بررسی اثر پارامترهای مختلف بر روی مقادیر پیش بینی شده توسط الگوریتم های فازی

مراجع

- [1] M. Bilgili, A. Ozbek, B. Sahin, and A. Kahraman, "An overview of renewable electric power capacity and progress in new technologies in the world," *Renew. Sustain. Energy Rev.*, vol. 49, pp. 323–334, Sep. 2015.
- [2] M. Lange, "Analysis of the uncertainty of wind power predictions," Ph.D. dissertation, Fakultät Mathematik und Naturwissenschaften, Carl von Ossietzky Universität Oldenburg, Oldenburg, Germany, 2003.
- [3] P. Pinson and G. Kariniotakis, "Conditional prediction intervals of wind power generation," *IEEE Trans. Power Syst.*, vol. 25, no. 4, pp. 1845–1856, Nov. 2010.
- [4] P. Pinson, "Very-short-term probabilistic forecasting of wind power with generalized logitnormal distributions," *J. Roy. Stat. Soc. C, App.*, vol. 61, no. 4, pp. 555–576, Aug. 2012.
- [5] A. Botterud, Z. Zhou, J. Wang, R. J. Bessa, H. Keko, J. Sumaili, and V. Miranda, "Wind Power Trading Under Uncertainty in LMP Markets," *IEEE Trans. Power Syst.*, vol. 27, no. 2, pp. 894–903, May 2012.
- [6] J. M. Morales, A. Conejo, H. Madsen, P. Pinson, and M. Zugno, *Integrating Renewables in Electricity Markets: Operational Problems*, Int. Series in Operations Research and Management Science. New York, NY, USA: Springer, 2014.
- [7] C. Wan, Z. Xu, P. Pinson, Z. Y. Dong, and K. P. Wong, "Optimal Prediction Intervals of Wind Power Generation," *IEEE Trans. Power Syst.*, vol. 29, no. 3, pp. 1166–1174, May 2014.
- [8] J. Kiviluoma et al., "Short-term energy balancing with increasing levels of wind energy," *IEEE Trans. Sustain. Energy*, vol. 3, no. 4, pp. 769–776, Oct. 2012.
- [9] C. Lowery and M. O'Malley, "Impact of wind forecast error statistics upon unit commitment," *IEEE Trans. Sustain. Energy*, vol. 3, no. 4, pp. 760–768, Oct. 2012.
- [10] A. Shortt, J. Kiviluoma, and M. O'Malley, "Accommodating variability in generation planning," *IEEE Trans. Power Syst.*, vol. 28, no. 1, pp. 158–169, Feb. 2013.
- [11] R. Doherty and M. O'Malley, "A new approach to quantify reserve demand in systems with significant installed wind capacity," *IEEE Trans. Power Syst.*, vol. 20, no. 2, pp. 587–595, May 2005.
- [12] A. Fabbri, T. Gomez San Roman, J. Rivier Abbad, and V. Mendez Quezada, "Assessment of the cost associated with wind generation prediction errors in a liberalized electricity market," *IEEE Trans. Power Syst.*, vol. 20, no. 3, pp. 1440–1446, Aug. 2005.
- [13] H. Bludszweit, J. Dominguez-Navarro, and A. Llombart, "Statistical analysis of wind power forecast error," *IEEE Trans. Power Syst.*, vol. 23, no. 3, pp. 983–991, Aug. 2008.
- [14] B.-M. Hodge and M. Milligan, "Wind power forecasting error distributions over multiple timescales," in *Proc. IEEE Power & Energy Soc. General Meet.*, Detroit, MI, USA, 2011, pp. 1–8.
- [15] N. Menemenlis, M. Huneault, and A. Robitaille, "Computation of dynamic operating balancing reserve for wind power integration for the time-horizon 1–48 hours," *IEEE Trans. Sustain. Energy*, vol. 3, no. 4, pp. 692–702, Oct. 2012.
- [16] K. Dietrich, J. M. Latorre, L. Olmos, A. Ramos, and J. P. Ignacio, "Stochastic unit commitment considering uncertain wind production in an isolated system," in *Proc.*

- <http://www.ieor.berkeley.edu/~lavaei/SC-Screening2015.pdf>.
- [35] A.J.Ardakani and F.Bouffard, "Identification of Umbrella Constraints in DC-Based Security-Constrained Optimal Power Flow," IEEE Trans. Power Syst., vol. 28, no. 4, p. 3924–3934, 2013.
- [36] M.Doostizadeh, F.Aminifar, H.Ghasemi and H.Lesani, "Energy and Reserve Scheduling under Wind Power Uncertainty : An Adjustable Interval Approach" IEEE Trans. Smart Grid, 1949-3053 (c) 2016.
- [37] D. Babosa, C. de Mattos and at all, " Different Models for Forecasting Wind Power Generation: Case Study", Energies journal, 10, 2017.
- [38] HuiLiu; Hong-QiTian; ChaoChen; Yan-feiLi, " A hybrid statistical method to predict wind speed and wind power", Renewable Energy, 35(8):1857-1861, 2010.
- [39] Bonanno, F.; Capizzi, G.; Sciuto, L.; Napoli, C. Wavelet recurrent neural network with semi-parametric input data preprocessing for micro-wind power forecasting in integrated generation Systems. In Proceedings of the 2015 International Conference on Clean Electrical Power (ICCEP), Taormina, Italy, 16–18 June 2015.
- [40] E. Denny and M. O'Malley. Wind generation, power system operation, and emissions reduction. IEEE Transactions on Power Systems, 21(1):341–347, 2006.
- [41] H. A. Gil and G. Joos. Generalized estimation of average displaced emissions by wind generation. IEEE Transactions on Power Systems, 22(3):1035–1043, 2007.
- [42] T. Ackermann, J. Rivier Abbad, I. M. Dudurich, I. Erlich, H. Holttinen, J. Runge Kristoffersen, and Ejnar Sørensen. European Balancing Act. IEEE power & energy magazine, 5(6):91–103, 2007.
- [43] E. A. DeMeo, W. Grant, M. R. Milligan, and M. J. Schuerger. Wind plant integration. IEEE power & energy magazine, 3(6):38–46, 2005.
- [44] E. A. DeMeo, G. A. Jordan, C. Kalich, J. King, M. R. Milligan, C. Murley, B. Oakleak, and M. J. Schuerger. Accommodating wind's natural behavior. IEEE power & energy magazine, 5(6):68–77, 2007.
- [45] Passino, K. and Yurkovich, S. (1998). Fuzzy Control, Addison Wesley Longman, Menlo Park, CA.
- [46] Timothy J Ross, " Fuzzy Logic with Engineering Applications , Second Edition " 2004 John Wiley & Sons, Ltd, ISBNs: 0-470-86074-X (HB); 0-470-86075-8 (PB)
- [47] H.Aling, " A batch least squares lattice algorithm" IEEE conference on decision and control, 1992, 3709 - 3710 vol.4.
- [48] P.Monsurrò, A.Trifiletti "Faster, Stabler and Simpler-A Recursive Least Squares Algorithm Exploiting the Frisch-Waugh-Lovell Theorem" IEEE Trans,circuits and systems., vol.64,issue:3,march 2017.
- [49] L.R.Vega, H.Rey, J.Benesty and S.Tressens, " A Fast Robust Recursive Least Squares Algorithm " IEEE Trans,vol.57, issue:3, march 2009.
- [50] L.fausett,"fundamental of Neural Network: Architecture, Algrithms and applications",Prentice Hall, 1994
- [51] G.Mitchison,"Learning Algorithms And Network of Neurons",Reading,Ma:Addison-wily, 1989.
- [52] The wind speed historical statistics in Spain. [Online]. Available: <http://www.sotaventogalicia.com>.