

# یک روش ترکیبی پیش‌بینی احتمالاتی بلندمدت بار خالص شبکه با در نظر گرفتن اثر توان تولیدشده توسط منابع انرژی تجدیدپذیر در شبکه‌های هوشمند

محسن جهان تیغ و مجید معظمی

کمترین مربعات خطا و روش‌های بیزی می‌باشند [۲] و [۳]. مزیت این روش‌ها، سادگی و عدم نیاز به انجام محاسبات پیچیده است و مشکل این دسته از روش‌ها عدم ارائه دقت بالا در پیش‌بینی است. هم‌زمان با روش‌های محاسباتی، روش‌های مبتنی بر یادگیری ماشین معرفی شده‌اند [۴]. این دسته از روش‌ها قادر به ارائه نتایج بسیار خوبی با دقت بالا در پیش‌بینی نتایج هستند و تنها ایراد این روش‌ها را می‌توان نیاز به داده‌های زیاد با وضوح بالا دانست که در صورت نبود آن نتایج خوبی نیز حاصل نخواهد شد. مرجع [۵] روشی برای انتخاب ویژگی‌ها برای آموزش مدل‌های پیش‌بینی بار و قیمت برق ارائه داده که علاوه بر لحاظ کردن ارتباط بین ویژگی‌ها و تکرار داده‌های مشابه میان آنها، اثر متقابل ویژگی‌ها بر یکدیگر را نیز در نظر گرفته است. در [۶] به روش پیش‌بینی چندمرحله‌ای، مبتنی بر بازسازی فضای فازی و روش‌های بردار پشتیبان (SVM) برای حل مشکل واگرایی از خطای پیش‌بینی پرداخته شده است. مرجع [۷] یک روش مبتنی بر شبکه عصبی دومرحله‌ای را برای محاسبه میانگین بار و پیش‌بینی‌های پیک بار روزانه پیشنهاد داده است. همچنین [۸] بر روش بهبود شبکه عصبی با استفاده از رگرسیون چندکی تمرکز دارد که در این روش، پیش‌بینی‌های بار در یک دوره زمانی ارائه شده است. در [۹] یک روش بر اساس شبکه‌های عصبی بازگشتی و روش گردش زمانی برای پیش‌بینی ارائه شده است. در [۱۰] یک روش شبکه عصبی کانولوشن با شناخت زمان بررسی شده است. این روش ابتدا ویژگی‌های سطوح داده‌ها را استخراج کرده و برای داده‌های زمانی کدگذاری انجام می‌شود.

از دیگر روش‌هایی که در این زمینه مورد استفاده قرار گرفته‌اند می‌توان به روش‌های مبتنی بر الگوریتم‌های بهینه‌سازی اشاره کرد. در [۱۱] الگوریتم کلونی مورچگان برای پیش‌پردازش روی داده‌های آموزش و کاهش ابعاد آنها استفاده شده و پس از آن از مدل رگرسیون ماشین بردار پشتیبان برای ساختن مدل‌های پیش‌بینی استفاده شده است. در [۱۲] یک استراتژی دومرحله‌ای جدید برای پیش‌بینی کوتاه‌مدت بار پیشنهاد شده است. این روش شامل روشی برای استخراج ویژگی‌ها از داده‌های ورودی و یک پیش‌بینی کننده در سطح پایین‌تر و یک الگوریتم تکامل یافته دیفرانسیلی در سطح بالاتر برای بهینه‌سازی عملکرد پیش‌بینی کننده است. از مزایای این روش می‌توان به همگرایی سریع بین پارامترها و همچنین به حداقل رسیدن تعداد پارامترهای مورد نیاز برای پیش‌بینی اشاره کرد. از آنجا که آب و هوا یکی از عوامل تعیین‌کننده تقاضای توان است، برخی محققان تلاش کرده‌اند تا پیش‌بینی‌های بار در مناطق مختلف آب و هوایی را با یکدیگر ترکیب کنند [۱۳] و [۱۴]. در [۱۵]

چکیده: امروزه با توجه به رشد گسترده و نفوذ استفاده از منابع تولید پراکنده در شبکه‌های هوشمند، پیش‌بینی بار خالص شبکه با در نظر گرفتن اثر تولیدات پراکنده اهمیت قابل توجهی پیدا کرده است. در این مقاله یک روش بهینه‌سازی ترکیبی به منظور پیش‌بینی احتمالاتی بلندمدت بار خالص شبکه با استفاده از روش تحلیل اجزای همسایگی و حل مسأله رگرسیون به روش mini-batch-LBFGS و ترکیب پیش‌بینی‌های به دست آمده با استفاده از سیستم استنتاج عصبی- فازی تطبیقی ارائه شده است. این ساختار شامل ترکیب چندین پیش‌بینی بلندمدت از جمله پیش‌بینی بار، توان یک ایستگاه خورشیدی و توان یک مزرعه بادی با توربین‌های بادی مجهز به ژنراتور القایی دوسوتغذیه است. پیش‌بینی بار خالص و بررسی وابستگی موجود بین خطاهای پیش‌بینی بار و توان‌های خورشیدی و بادی نیز در این مقاله مورد مطالعه قرار گرفته است. نتایج شبیه‌سازی روش پیشنهادی و مقایسه آن با مدل‌های تائو و رگرسیون چندکی نشان می‌دهد که درصد میانگین مطلق خطا برای پیش‌بینی‌های بار و توان‌های خروجی ایستگاه خورشیدی و مزرعه بادی به ترتیب به میزان ۰/۹۴۷٪، ۰/۳۰۷۹٪ و ۰/۰۰۴۲٪ بهبود یافته است که کاهش خطای کلی پیش‌بینی را سبب می‌شود.

کلیدواژه: پیش‌بینی احتمالاتی بلندمدت بار، تحلیل اجزای همسایگی، سیستم استنتاج عصبی- فازی، شبکه هوشمند، تولید بادی، تولید فوتوولتائیک.

## ۱- مقدمه

پیش‌بینی بار به عنوان عاملی مهم در طرح توسعه و بهره‌برداری از سیستم‌های قدرت تلقی می‌شود و در واقع وسیله‌ای است که به کمک آن می‌توان در جهت بهبود برنامه‌ریزی آینده سیستم قدرت اقدام نمود. منظور از پیش‌بینی بار خالص میزان باری است که باید توسط سیستم قدرت تأمین شود، بدون آن که از منابع تولید توزیع‌شده استفاده گردد یا به عبارتی بار کل شبکه به جز باری که می‌تواند توسط منابع تولید توزیع‌شده که مبتنی بر انرژی‌های تجدیدپذیرند، تغذیه شود. در دو دهه اخیر روش‌های ترکیبی برای بهبود دقت پیش‌بینی بار مورد توجه واقع شده‌اند [۱]. برخی از این روش‌ها شامل میانگین‌گیری ساده، میانگین‌گیری از

این مقاله در تاریخ ۱۷ تیر ماه ۱۳۹۹ دریافت و در تاریخ ۲۴ فروردین ماه ۱۴۰۰ بازنگری شد.

محسن جهان تیغ، دانشکده مهندسی برق، واحد نجف‌آباد، دانشگاه آزاد اسلامی، نجف‌آباد، ایران، (email: mohsenjahantigh1372@gmail.com).

مجید معظمی (نویسنده مسئول)، دانشکده مهندسی برق، واحد نجف‌آباد، دانشگاه آزاد اسلامی، نجف‌آباد، ایران، (email: m\_moazzami@pel.iaun.ac.ir).

- ارائه روشی برای بررسی و مدیریت وابستگی موجود بین خطاهای پیش‌بینی بار و توان‌های خورشیدی و بادی در ادامه این مقاله، در بخش دوم روش پیشنهادی مطرح می‌شود. در بخش سوم نتایج شبیه‌سازی و در بخش پایانی نتیجه‌گیری حاصل از پژوهش ارائه خواهد شد.

## ۲- روش پیشنهادی

### ۲-۱ سیستم استنتاج عصبی- فازی تطبیقی

سیستم استنتاج عصبی- فازی تطبیقی، توانایی خودآموزی در شبکه عصبی و توانایی استنباط منطقی سیستم فازی را با یکدیگر ترکیب می‌کند که در نتیجه آن کاستی‌های شبکه عصبی و سیستم فازی رفع می‌شوند. در مقایسه با سایر شبکه‌های عصبی- فازی، اجرای سیستم استنتاج عصبی- فازی تطبیقی راحت‌تر است و راندمان بالایی دارد. بر اساس مدل سوگنو<sup>۵</sup> مرتبه اول، دو قانون if-then آن به شرح زیر است [۲۳]

$$\text{Rule}_1: \text{if } (x \rightarrow A_1) \& (y \rightarrow B_1) \text{ then } (f_1 = p_1x + q_1y + r_1) \quad (1)$$

$$\text{Rule}_2: \text{if } (x \rightarrow A_2) \& (y \rightarrow B_2) \text{ then } (f_2 = p_2x + q_2y + r_2) \quad (2)$$

در قوانین فوق  $x$  و  $y$  ورودی‌ها،  $A_i$  و  $B_i$  مجموعه‌های فازی و  $f_i$  خروجی است که توسط قوانین فازی مشخص شده است.  $p_i$ ،  $q_i$  و  $r_i$  فاکتورهای طراحی هستند که در روند آموزش تعیین می‌شوند. ساختار سیستم استنتاج عصبی- فازی که می‌تواند به این دو قانون دست یابد، در شکل ۱ نشان داده شده است [۲۴].

خروجی نهایی را می‌توان به شکل زیر بیان کرد

$$f = (\bar{w}_1 p_1)x + (\bar{w}_1 q_1)y + \bar{w}_1 r_1 + (\bar{w}_2 p_2)x + (\bar{w}_2 q_2)y + \bar{w}_2 r_2 \quad (3)$$

### ۲-۲ روش تحلیل اجزای همسایگی


اگر مجموعه  $T = \{(x_1, y_1), \dots, (x_i, y_i), \dots, (x_N, y_N)\}$  مجموعه‌ای از نمونه‌های آموزشی باشد به طوری که  $x_i$  برداری  $d$  بعدی از ویژگی‌ها،  $y_i \in \{1, 2, \dots, c\}$  بردار هدف (شامل برچسب هر دسته) مربوط به ماتریس ویژگی‌ها و  $N$  تعداد نمونه‌ها باشد، هدف یافتن یک بردار از وزن‌ها است به طوری که دسته‌بندی نزدیک‌ترین همسایه<sup>۶</sup> بهینه شود. فاصله وزنی بین دو نمونه  $x_i$  و  $x_j$  برابر است با [۲۵]

$$D_w(x_i, x_j) = \sum_{l=1}^d w_l^r |x_{il} - x_{jl}| \quad (4)$$

در اینجا  $w_l$  وزن مربوط به ویژگی  $l$ ام است.

احتمال آن که نقطه  $x_i$ ،  $x_j$  را به عنوان نقطه مرجع خود انتخاب کند برابر است با

$$p_{ij} = \begin{cases} \frac{\kappa(D_w(x_i, x_j))}{\sum_{\kappa \neq i} \kappa(D_w(x_i, x_j))}, & \text{if } i \neq j \\ \cdot, & \text{if } i = j \end{cases} \quad (5)$$



شکل ۱: ساختار سیستم استنتاج عصبی- فازی تطبیقی [۲۳].

واریانس پیش‌بینی‌های انجام‌شده و فواصل پیش‌بینی‌ها با استفاده از مجموعه داده‌های آب و هوایی تخمین زده شده است. پیش‌بینی آب و هوا شامل چندین سناریو برای یک متغیر هواشناسی است. در این مرجع از سناریوهای مختلف آب و هوایی برای تولید پیش‌بینی‌های مختلف بار استفاده شده است.

شاخه دیگری که در پیش‌بینی کوتاه‌مدت احتمالاتی بار وجود دارد، پیش‌بینی بار در فواصل زمانی با استفاده از تئوری فازی است. پژوهش انجام‌شده در [۱۶] رگرسیون تعامل فازی را برای پیش‌بینی کوتاه‌مدت بار در فواصل فازی به کار گرفته است. در این روش سه مدل، شامل دو مدل رگرسیون فازی و یک مدل رگرسیون چندگانه خطی، بدون اثرات متقابل با یکدیگر مقایسه می‌شوند. مدل توسعه داده شده روش فواصل فازی برای پیش‌بینی بار در ریزشکها نیز مورد استفاده قرار گرفته است [۱۷]. مدل‌سازی پیشنهادی، مدل‌های فواصل پیش‌بینی فازی را تولید می‌کند که عدم قطعیت‌های پیش‌بینی‌های آینده را نشان می‌دهد. مراجع [۱۸] و [۱۹] از مدل‌هایی بر اساس سیستم استنتاج عصبی- فازی تطبیقی (ANFIS) برای پیش‌بینی میان‌مدت و بلندمدت بار استفاده کرده‌اند. در [۲۰] مطالعه یک روش ترکیبی برای پیش‌بینی کوتاه‌مدت بار که شامل تجزیه حالت تجربی، بهینه‌سازی ازدحام ذرات (PSO) و سیستم‌های استنتاج فازی مبتنی بر شبکه تطبیقی (ANFIS) می‌باشد، ارائه شده است. در [۲۱] ترکیب نظریه فازی و مدل ANFIS برای پیش‌بینی ساعت- پیش به مدت یک سال انجام گرفته است.

در این مقاله یک روش بهینه‌سازی پیش‌بینی احتمالاتی بلندمدت بار خالص با استفاده از روش‌های تحلیل اجزای همسایگی و ترکیب پیش‌بینی‌های به دست آمده با استفاده از سیستم استنتاج عصبی- فازی ارائه شده است. داده‌های پیش‌بینی مربوط به دو پایگاه داده NERL<sup>۳</sup> و GEFCom2014<sup>۴</sup> [۲۲] می‌باشد که برای پیش‌بینی بلندمدت بار، توان یک ایستگاه خورشیدی و توان یک مزرعه بادی با توربین‌های بادی مجهز به ژنراتور القایی دوسو تغذیه استفاده شده است. داده‌های پیش‌بینی به زیرمجموعه‌های دارای همپوشانی برای تولید مدل‌های خواهری تقسیم می‌شوند. بدین منظور ساختاری جدید برای پیش‌بینی بار خالص با استفاده از پیش‌پردازش روی داده‌ها و ترکیب چندین مدل پیش‌بینی مبتنی بر سیستم عصبی- فازی تطبیقی ارائه می‌شود. از نوآوری‌های این مقاله می‌توان به موارد زیر اشاره کرد:

- ارائه روشی برای پیش‌بینی توان بادی
- ارائه روشی ترکیبی برای پیش‌بینی احتمالاتی بار خالص در دوره زمانی بلندمدت

1. Adaptive Network-Based Fuzzy Inference System
2. Particle Swarm Optimization
3. National Renewable Energy Laboratory
4. Global Energy Forecasting Competition

5. Sugeno

6. Nearest Neighbor Classification

جدول ۲: داده‌های مربوط به پیش‌بینی توان خورشیدی و بادی.

سال	زیرمجموعه
۲۰۰۴-۲۰۰۵	۱
۲۰۰۴-۲۰۰۶	۲
۲۰۰۶-۲۰۰۷	۳
۲۰۰۶-۲۰۰۸	۴
۲۰۰۷-۲۰۰۸	۵
۲۰۰۷-۲۰۰۹	۶
۲۰۰۸-۲۰۰۹	۷
۲۰۱۰	۸

می‌باشد که در مجموعه  $T$  ارائه شده است. یک مدل رگرسیون تصادفی را به شکل زیر در نظر بگیرید [۲۶]:

(۱) مدل رگرسیون به طور تصادفی، یک نقطه از  $T$  را به عنوان نقطه مرجع برای نقطه  $x$  انتخاب می‌کند.

(۲) مقادیر پاسخ در نقطه  $x$ ، برابر با مقادیر پاسخ در نقطه مرجع هستند. اکنون فرض کنید  $\hat{y}_i$  مقدار عددی پاسخی باشد که مدل رگرسیون تصادفی پیش‌بینی می‌کند و  $y_i$  پاسخ واقعی برای  $x_i$  باشد. در این صورت می‌توان تابع تلفات  $l: \mathbb{R}^2 \rightarrow \mathbb{R}$  را به شکلی تعریف کرد که بیانگر عدم تطابق  $y_i$  و  $\hat{y}_i$  باشد. مقدار میانگین  $l(y_i, \hat{y}_i)$  برابر است با

$$l_i = E(l(y_i, \hat{y}_i) | T^{-i}) = \sum_{j \neq i} p_{ij} l(y_i, \hat{y}_i) \quad (۱۲)$$

پس از اضافه‌کردن پارامتر تنظیم، تابع هدف به منظور بهینه‌سازی برابر است با [۲۵]

$$\xi(w) = \frac{1}{N} \sum_{i=1}^n l_i + \lambda \sum_{r=1}^p w_r^2 \quad (۱۳)$$

## ۲-۳ تولید داده

در این مقاله به منظور پیش‌بینی احتمالاتی بار، از مجموعه داده‌های مسابقات جهانی پیش‌بینی (GEFCom۲۰۱۴) و برای پیش‌بینی توان‌های خورشیدی و بادی، از داده‌های آب و هوایی مربوط به پایگاه داده NERL در بخشی از ایالت کالیفرنیا در ایالات متحده استفاده شده است. برای ساخت مدل‌های پیش‌بینی خواهری بار، داده‌ها در مرحله آموزش طبق جدول ۱ به چهار زیرمجموعه تقسیم می‌شوند. زیرمجموعه چهارم، به منظور آموزش مدل ترکیب پیش‌بینی‌ها استفاده می‌شود و مجموعه داده‌های آزمایش، داده‌های یک سال است که از ابتدای ماه دسامبر سال ۲۰۱۰ تا انتهای ماه نوامبر ۲۰۱۱ را شامل می‌شود.

همچنین داده‌های مربوط به پیش‌بینی توان‌های خروجی فوتوولتائیک و توربین بادی به هشت زیرمجموعه دارای همپوشانی طبق جدول ۲ برای تولید مدل‌های خواهری تقسیم می‌شوند. زیرمجموعه هشتم به منظور آموزش مدل ترکیب پیش‌بینی‌ها استفاده می‌گردد و مجموعه داده‌های آزمایش، داده‌های سال ۲۰۱۱ را شامل می‌شود.

## ۲-۴ محاسبه توان تولیدی پانل خورشیدی

برای محاسبه توان تولیدشده توسط پانل‌های خورشیدی، دانستن داده‌های ورودی برای محاسبه توان خروجی پانل‌ها از اهمیت بالایی برخوردار است. این داده‌ها شامل ظرفیت تولیدی پانل خورشیدی، دمای ایستگاه خورشیدی، مکان قرارگیری و زاویه شیب پانل‌ها در محاسبه دقیق توان تولیدی توسط پانل خورشیدی تأثیرگذار می‌باشند. توان‌های

جدول ۱: داده‌های مربوط به پیش‌بینی بار.

سال	زیرمجموعه
۲۰۰۶-۲۰۰۷	۱
۲۰۰۶-۲۰۰۸	۲
۲۰۰۸-۲۰۰۹	۳
۲۰۱۰ تا پایان نوامبر همین سال	۴

$$\kappa(z) = e^{-\frac{z}{\sigma}} \quad (۶)$$

که  $\kappa(z)$  یک تابع کرنل است و  $\sigma$  بیانگر اندازه کرنل و یک پارامتر ورودی است که بر احتمال انتخاب هر یک از نقاط به عنوان نقطه مرجع، تأثیر می‌گذارد. بر این اساس احتمال آن که نقطه مورد نظر  $x_i$  به درستی در دسته خود قرار گیرد برابر است با [۲۶]

$$p_i = \sum_j p_{ij} y_{ij} \quad (۷)$$

$$y_{ij} = \begin{cases} 1 & \text{if \& only if } y_i = y_j \\ 0 & \text{otherwise} \end{cases} \quad (۸)$$

در نتیجه تقریبی از دقت دسته‌بندی LOO<sup>۱</sup> را می‌توان به شکل زیر بیان کرد

$$\xi(w) = \frac{1}{N} \sum_i p_i = \frac{1}{N} \sum_i \sum_j y_{ij} p_{ij} \quad (۹)$$

به منظور انجام انتخاب ویژگی و کاهش overfit، یک پارامتر تنظیم‌کننده در قالب تابع هدفی به شکل زیر معرفی می‌شود

$$\xi(w) = \sum_i \sum_j y_{ij} p_{ij} - \lambda \sum_{i=1}^d w_i^2 \quad (۱۰)$$


که در (۱۰) پارامتر تنظیم‌کننده است که از طریق اعتبارسنجی<sup>۲</sup> متقابل قابل تنظیم است. باید توجه داشت که ضریب  $1/N$  در (۹) حذف شده و بدین معنی است که پارامتر  $\lambda$  تغییرات مربوط را ایجاد می‌کند و در بردار پاسخ نهایی تغییری ایجاد نمی‌شود.

در نتیجه تابع هدف  $\xi(w)$  مشتق‌پذیر بوده و مشتقات آن نسبت به  $w_i$  را می‌توان با استفاده از (۱۱) محاسبه نمود

$$\begin{aligned} \frac{\partial \xi(w)}{\partial w_i} &= \sum_i \sum_j y_{ij} \left[ \frac{1}{\sigma} p_{ij} \left( \sum_{k \neq i} p_{ik} |x_{il} - x_{kl}| - |x_{il} - x_{jl}| \right) w_i \right] \\ &\quad - 2\lambda w_i \\ &= \frac{1}{\sigma} \sum_i \left( p_i \sum_{k \neq i} p_{ik} |x_{il} - x_{kl}| - \sum_j y_{ij} p_{ij} |x_{il} - x_{jl}| \right) w_i \\ &\quad - 2\lambda w_i = \\ &= 2 \left( \frac{1}{\sigma} \sum_i \left( p_i \sum_{j \neq i} p_{ij} |x_{il} - x_{jl}| - \sum_j y_{ij} p_{ij} |x_{il} - x_{jl}| \right) - \lambda \right) w_i \end{aligned} \quad (۱۱)$$

یک مجموعه از نمونه مشاهدات مشابه با مجموعه  $T$  در مسأله دسته‌بندی را در نظر بگیرید. تنها تفاوتی که با مسأله دسته‌بندی وجود دارد مقادیر پاسخ‌ها  $y_i \in \mathbb{R}$  است. در اینجا هدف، پیش‌بینی پاسخ  $y$

1. Leave-One-Out
2. Cross Validation



شکل ۲: دیاگرام شماتیک ژنراتور القایی دوسو تغذیه [۲۹].

که در این رابطه،  $\phi$  عرض جغرافیایی منطقه مورد نظر و  $\delta$  زاویه حرکت خورشید است. سینوس ارتفاع خورشید  $\alpha$  با استفاده از (۱۹) محاسبه می‌شود

$$\sin \alpha = \sin \phi \sin \delta + \cos \phi \cos \delta \cos \omega \quad (۱۹)$$

در رابطه فوق،  $\omega$  بیانگر زاویه ساعت است. به طور مثال در ساعت ۱۲ ظهر برابر با صفر در نظر گرفته می‌شود و مقدار آن با استفاده از رابطه زیر محاسبه می‌گردد

$$\omega = (t - ۱۲) \times ۱۵^\circ + (\psi - D \times ۱۵^\circ) \quad (۲۰)$$

که  $D$  و  $\psi$  به ترتیب منطقه زمانی و طول جغرافیایی را نمایش می‌دهند که هر دو پارامتر را می‌توان ثابت در نظر گرفت. زاویه حرکت خورشید ( $\delta$ ) را با استفاده از رابطه زیر می‌توان محاسبه کرد

$$\delta = ۲\pi \times \frac{۲۳,۴۵^\circ}{۳۶۰^\circ} \times \sin\left(۲\pi \times \frac{۲۸۴ + N}{Y}\right) \quad (۲۱)$$

که  $Y$  تعداد کل روزهای سال (۳۶۵ یا ۳۶۶ برای سال کبیسه) و  $N$  شماره روز در سال است. با توجه به (۱۴) تا (۲۱) می‌توان با استفاده از مجموعه داده‌های NERL، تمامی پارامترهای بیان شده به غیر از ظرفیت ایستگاه خورشیدی  $C$ ، زاویه شیب  $\beta$  و آزیموت ایستگاه خورشیدی  $\gamma$  را محاسبه کرد [۲۸].

## ۲-۵ محاسبه ظرفیت تولید توان توربین بادی

شکل ۲ دیاگرام شماتیک یک ژنراتور القایی دوسو تغذیه در حالت متصل به شبکه را نشان می‌دهد. علاوه بر این توان راکتیو در فرکانس لغزش  $Q_r$  نیز سیم‌پیچ روتور را تغذیه می‌کند. زمانی که توان روتور در فرکانس لغزش  $P_r + jQ_r$  به استاتور می‌رسد، توان معادل روتور  $P_r + jQ_r$  در فرکانس ۶۰ هرتز قابل محاسبه است [۲۹]. توان مکانیکی توربین بادی با استفاده از رابطه زیر قابل محاسبه است [۲۹] و [۳۰]

$$P = \frac{1}{2} C_p (\lambda_{tip}, \beta) \rho A V_\omega^3 \quad (۲۲)$$

در رابطه فوق  $\rho$  چگالی هوا و  $V_\omega$  سرعت باد است.  $A$  ناحیه پوشش داده شده توسط پره است و برابر است با

$$A = \pi R^2 \quad (۲۳)$$

که  $C_p$  ضریب تبدیل توان توربین است که تابعی از زاویه پره  $\beta$  و نرخ سرعت نوک  $\lambda_{tip}$  است [۳۰]

محاسبه شده به عنوان ماتریس هدف در آموزش مدل‌های پیش‌بینی توان خورشیدی استفاده شده است.

توان تولیدی ایستگاه فتوولتائیک با استفاده از (۱۴) قابل محاسبه است [۲۶]

$$P_t \approx C \frac{I_{PV,t}}{1000} [1 - \mu(T_{PV,t} - ۲۵)] \quad (۱۴)$$

در رابطه فوق  $C$  بیانگر ظرفیت ایستگاه خورشیدی است و  $I_{PV,t}$  تابش خورشیدی دریافت شده در پانل فتوولتائیک را بر حسب  $W/m^2$  نشان می‌دهد.  $\mu$  ثابت دمایی ایستگاه خورشیدی می‌باشد و  $I_{PV,t}$  نشان‌دهنده دمای ایستگاه خورشیدی بر حسب  $C^\circ$  است.

دمای ایستگاه خورشیدی با استفاده از رابطه زیر قابل محاسبه است [۲۶]

$$T_{PV,t} = T_{A,t} + \frac{I_{PV,t}}{800} \times (N_{oct} - ۲۰) \quad (۱۵)$$

در (۱۵)،  $T_{A,t}$  نشان‌دهنده دمای هوای محیط بر حسب  $C^\circ$  می‌باشد و  $N_{oct}$  دمای کار نامی سلول‌های خورشیدی است و این متغیر را می‌توان ثابت در نظر گرفت. تابش خورشیدی  $I_{PV,t}$  دریافت شده در سطح ایستگاه خورشیدی با استفاده از (۱۶) محاسبه می‌شود

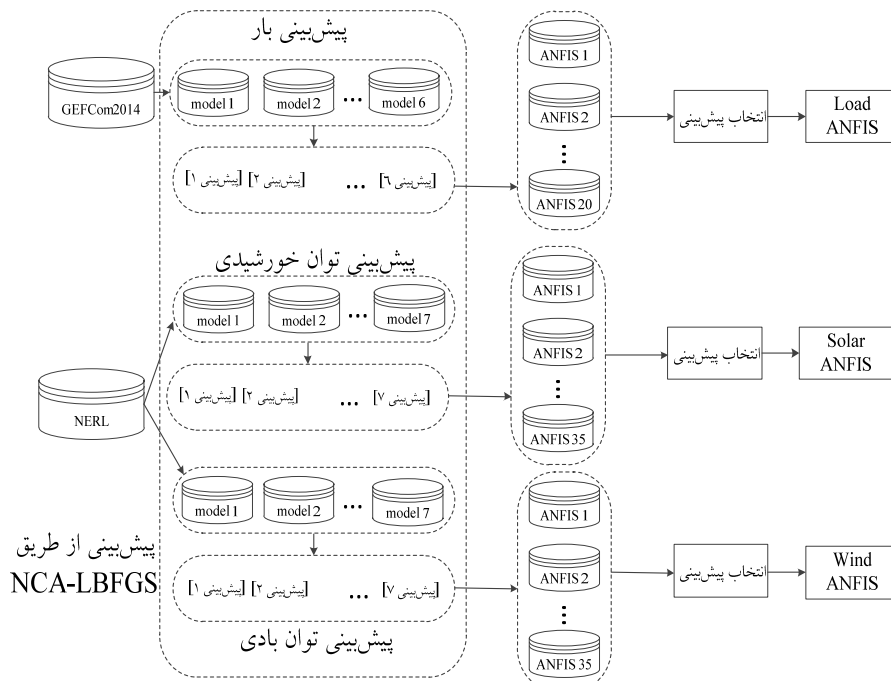
$$I_{PV,t} = I_{s,t} \tau_{b,t} (\sin \alpha \cos \beta + \cos \alpha \sin \beta (\gamma - A)) + I_{d,t} \frac{1 + \cos \beta}{2} + (I_{b,t} + I_{d,t}) \rho_t \frac{1 - \cos \beta}{2} \quad (۱۶)$$

که  $\tau_{b,t}$  ضریب شفافیت جو،  $p_t$  Surface Albedo و  $\alpha$  و  $A$  ارتفاع و آزیموت خورشید هستند.  $\alpha$  و  $A$  با دانستن طول و عرض جغرافیایی، متغیر زمان  $t$  که نشان‌دهنده ساعت در روز و روز در سال هستند،  $\beta$  زاویه شیب  $\gamma$  آزیموت ایستگاه خورشیدی،  $I_{s,t}$  نشان‌دهنده تابش نرمال مستقیم (DNI) و  $I_{d,t}$  نشان‌دهنده تابش افقی پراکنده (DHI) قابل محاسبه است.  $I_{b,t}$  تابش افقی مستقیم است که با استفاده از (۱۷) محاسبه می‌شود

$$I_{b,t} = I_{s,t} \tau_{b,t} \sin \alpha \quad (۱۷)$$

محاسبه  $I_{PV,t}$  نیازمند دانستن زوایایی است که میان خورشید و ایستگاه خورشیدی ایجاد می‌شود که در ادامه به طور خلاصه بیان می‌گردند. کسینوس آزیموت خورشید را با استفاده از (۱۸) می‌توان محاسبه کرد [۲۷]

$$\cos A = \frac{\sin \alpha \sin \phi - \sin \delta}{\cos \alpha \cos \phi} \quad (۱۸)$$



شکل ۳: دیاگرام شماتیک انتخاب پیش‌بینی‌ها و ساخت مدل ترکیب نهایی.

عصبی- فازی تطبیقی، مورد آزمایش قرار گرفته و جذر میانگین مربعات خطا برای هر یک از مدل‌ها محاسبه می‌شود. بدین طریق پیش‌بینی‌هایی که آموزش مدل با استفاده از آنها منتج به خطای کمتری شده است به عنوان ورودی‌های نهایی انتخاب می‌شوند. سپس به صورت نظارت‌شده یک مدل پیش‌بینی با استفاده از کل داده‌های پنجره تنظیمی برای ترکیب پیش‌بینی‌های اولیه و تولید پیش‌بینی نهایی آموزش داده می‌شود. شکل ۳ دیاگرام شماتیک روش پیشنهادی برای ترکیب پیش‌بینی‌ها را نمایش می‌دهد.

بدین ترتیب برای انجام پیش‌بینی بلندمدت نهایی، ابتدا پیش‌بینی‌هایی که با استفاده از مدل‌هایی که از طریق فرایند نمایش داده شده در شکل ۳ انتخاب می‌شوند، تولید می‌گردند. سپس با استفاده از مدل‌های مجزای آموزش داده شده برای ترکیب پیش‌بینی‌های بار، توان خورشیدی و توان بادی، پیش‌بینی‌های نهایی برای هر یک از مقادیر مذکور در دوره پیش‌بینی تولید می‌شوند.

در مرحله آموزش، ۷۵٪ ماتریس‌های ورودی برای آموزش مدل‌ها و ۲۵٪ آنها برای اعتبارسنجی از مدل‌های آموزش داده شده استفاده می‌شود. پس از آموزش مدل‌های پیش‌بینی توان خروجی ایستگاه خورشیدی، توربین بادی و بار، برای انتخاب مدل‌های پیش‌بینی برتر تمامی ترکیب‌های ممکن از طریق ساختن یک مدل ANFIS کوچک با استفاده از داده‌های پنجره تنظیمی و ارزیابی آن مورد آزمایش قرار می‌گیرند. پس از آن برای انجام هر یک از پیش‌بینی‌ها (بار، توان خورشیدی و توان بادی) یک مدل ANFIS دیگر با استفاده از تمامی داده‌های پنجره تنظیمی به صورت نظارت‌شده آموزش داده می‌شود. در مرحله بعدی می‌توان با استفاده از مدل پیش‌بینی نهایی، بار خالص را پیش‌بینی کرد و نتایج پیش‌بینی بار احتمالاتی را ارائه داد.

### ۳- نتایج شبیه‌سازی

در این مقاله مراحل شبیه‌سازی روش پیشنهادی برای پیش‌بینی احتمالاتی بار خالص در شبکه برق با در نظر گرفتن اثر تولید توان‌های خورشیدی و بادی توسط یک ایستگاه خورشیدی و یک مزرعه بادی با

$$C_p(\lambda_{tip}, \beta) = C_1 \left( C_2 \frac{1}{\lambda_i} - C_3 \beta - C_4 \beta^{C_5} - C_6 \right) e^{-C_7 \frac{1}{\lambda_i}} \quad (24)$$

$$\frac{1}{\lambda_i} = \frac{1}{\lambda + C_8 \beta} - \frac{C_9}{1 + \beta^r} \quad (25)$$

$$\lambda = \frac{\omega_r R}{V_\omega} \quad (26)$$

که  $R$  طول پره و  $\omega_r$  سرعت روتور است. ضرایب ثابت  $C_1$  تا  $C_9$  داده شده است [۳۱]. در یک زاویه پره ثابت، حداکثر مقدار ضریب تبدیل توان  $C_{p\_max}$  در مقدار معینی از  $\lambda$  قابل دستیابی است که  $\lambda_{opt}$  نامیده می‌شود. به منظور تعقیب حداکثر توان خروجی (MPPT)،  $\lambda$  باید در مقدار بهینه آن یعنی  $\lambda_{opt}$  باقی بماند. توان خروجی حداکثری توربین بادی را می‌توان به شکل زیر بیان کرد

$$P_{max} = \frac{1}{\rho} \rho \pi R^2 C_{p\_max} V_\omega^3 \quad (27)$$

## ۲-۶ پیش‌بینی بار خالص

در این مقاله برای ترکیب پیش‌بینی‌ها (بار، توان خورشیدی و توان بادی)، استفاده از روش استنتاج عصبی- فازی تطبیقی پیشنهاد می‌شود. بدین ترتیب که ابتدا برای مدت زمان ارائه‌شده در پنجره تنظیمی (برای مثال سال ۲۰۱۰) با استفاده از تمامی مدل‌های پیش‌بینی آموزش داده شده، مقدار بار، توان خورشیدی و توان بادی پیش‌بینی می‌شود. در نتیجه تعداد شش پیش‌بینی برای بار، هفت پیش‌بینی برای توان خورشیدی و هفت پیش‌بینی برای توان بادی در دست خواهد بود.

برای انتخاب  $n$  پیش‌بینی برتر از پیش‌بینی‌های موجود، ابتدا تمامی ترکیب‌های  $n$  تایی ممکن از مجموعه کل ترکیب‌ها از طریق آموزش یک مدل پیش‌بینی کوچک برای هر ترکیب با استفاده از روش استنتاج

جدول ۳: خطای آزمایش مدل های بار.

مدل	MAE	MAPE (%)	MSE	RMSE	R <sup>2</sup>
۱	۱۵,۴۰۵	۱۰,۰۶۲	۴۶۹,۳۷	۲۱,۶۶۵	۰,۸۲۳۵
۲	۱۸,۱۸	۱۱,۸۷۴	۶۵۵,۵	۲۵,۶۰۳	۰,۷۵۳۵۱
۳	۱۵,۹۵۵	۱۰,۴۲۱	۵۰۲,۸۸	۲۲,۴۲۵	۰,۸۱۰۹
تفکیکی ۱	۱۵,۴۰۲	۱۰,۰۵۹	۴۷۸,۴۴	۲۱,۸۷۳	۰,۸۲۰۰۹
تفکیکی ۲	۱۵,۸۲۸	۱۰,۳۳۸	۴۹۷,۴۹	۲۲,۳۰۴	۰,۸۱۲۹۳
تفکیکی ۳	۱۵,۵۸۳	۱۰,۱۷۸	۵۰۵,۶۹	۲۲,۴۸۸	۰,۸۰۹۸۴

جدول ۴: خطای آزمایش مدل های پیش بینی توان خورشیدی.

مدل	MAE	MAPE (%)	MSE	RMSE	R <sup>2</sup>
۱	۵,۸۴۱۷	۹,۲۴۷۲	۲۷۸,۴۲	۱۶,۶۸۶	۰,۹۵۳۵
۲	۹,۵۷۶۲	۱۵,۳۶	۵۵۰,۶۳	۲۳,۴۶۵	۰,۹۰۸۰۴
۳	۹,۲۹۰۳	۱۴,۹۰۲	۵۸۶,۹۸	۲۴,۲۲۸	۰,۹۰۱۹۶
۴	۶,۴۸۴۷	۱۰,۴۰۱	۴۰۵,۶۴	۲۰,۱۴۱	۰,۹۳۲۲۵
۵	۷,۰۴۱۱	۱۱,۲۹۴	۴۳۴,۹	۲۰,۸۵۴	۰,۹۲۷۳۶
۶	۶,۴۶۷۷	۱۰,۳۷۴	۳۹۱,۰۸	۱۹,۷۷۶	۰,۹۳۴۶۸
۷	۶,۴۵۳۹	۱۰,۳۵۲	۳۸۱,۳۳	۱۹,۵۲۸	۰,۹۳۴۳۱

جدول ۵: خطای آزمایش مدل های پیش بینی توان بادی.

مدل	MAE	MAPE	MSE	RMSE	R <sup>2</sup>
۱	۰,۱۰۰۰۴۶۰۷	۰,۵۷۵۹	۰,۰۰۰۳۳۸۴۱	۰,۰۱۸۳۹۶	۰,۹۹۵۵۹
۲	۰,۰۰۰۳۵۷۲۹	۰,۴۴۶۶۲	۰,۰۰۰۲۸۹۷۷	۰,۰۱۷۰۲۳	۰,۹۹۶۲۲
۳	۰,۰۰۰۳۴۳۴۵	۰,۴۲۹۳۲	۰,۰۱۰۵۷۵	۰,۰۱۰۲۸۴	۰,۸۶۲۱۱
۴	۰,۰۰۰۰۹۸۴	۰,۱۲۳۰۱	۰,۰۰۰۰۳۶۴	۰,۰۰۰۰۳۳۸	۰,۹۹۹۵۳
۵	۰,۰۰۰۰۹۱۸	۰,۱۱۴۷۸	۰,۰۰۰۰۲۵۳	۰,۰۰۰۰۲۵۹	۰,۹۹۹۶۷
۶	۰,۰۰۰۰۵۲۵	۰,۰۶۵۷۲۳	۰,۰۰۰۰۱۱۵	۰,۰۰۰۰۳۴۰۰۶	۰,۹۹۹۸۵
۷	۰,۰۰۰۰۷۸۶	۰,۰۹۸۲۹۱	۰,۰۰۰۰۱۱۳	۰,۰۰۰۰۳۳۶۷۵	۰,۹۹۹۸۵

خروجی توربین بادی مطابق آنچه در بخش ۲-۵ بیان شد، محاسبه گردیده و نتایج آن در شکل ۵ نمایش داده شده است.

### ۳-۳ نتایج آزمایش مدل ها با روش تحلیل اجزای همسایگی

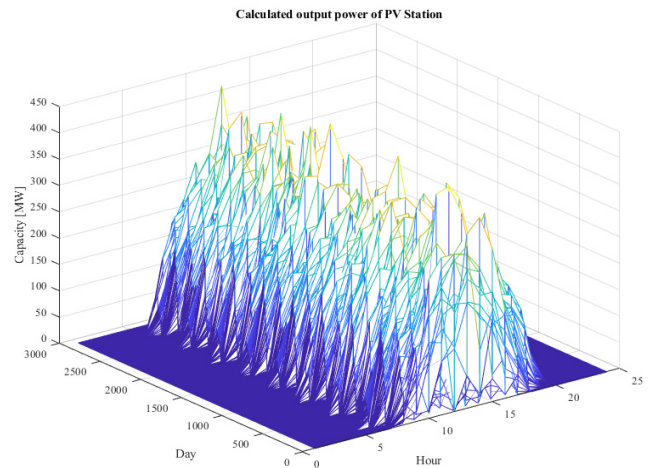
با بررسی جدول ۳ می توان مشاهده کرد که نتایج آزمایش مدل های بار ساخته شده با استفاده از زیرمجموعه داده اول با اندکی اختلاف خطای کمتری ارائه می دهند.

با توجه به جدول ۳ مشاهده می شود که به طور کلی مقدار عددی شاخص های خطای به دست آمده برای مدل های پیش بینی به جز مدل شماره ۲، نزدیک به یکدیگرند. در بخش خورشیدی با بررسی جدول ۴ مدل اول در بخش پیش بینی بلندمدت با میانگین قدر مطلق خطایی برابر با ۹,۲۴۷۲ دقت در پیش بینی را ارائه داده است.



برای قسمت بادی خطای آزمایش این مدل ها در جدول ۵ نمایش داده شده است. در میان پیش بینی های انجام شده، کمترین خطای به دست آمده مربوط به مدل ۶ با میانگین قدر مطلق درصد خطایی برابر با ۰,۰۶۵۷۲۳ است.

### ۴-۳ انتخاب پیش بینی ها و آموزش مدل پیش بینی

پس از آماده شدن داده های هدف می توان داده ها را به تعداد شش زیرمجموعه برای بار و هفت زیرمجموعه برای توان خورشیدی و توان



شکل ۴: توان خروجی محاسبه شده برای منطقه جغرافیایی تحت بررسی.



شکل ۵: سرعت باد و توان خروجی محاسبه شده برای توربین بادی.

توربین های بادی مجهز به ژنراتور القایی دوسو تغذیه به صورت مرحله به مرحله بحث و بررسی شد. روش مذکور شامل استفاده از ترکیب روش های تحلیل اجزای همسایگی و حل مسأله رگرسیون به روش mini-batch-LBFGS و ترکیب پیش بینی های به دست آمده با استفاده از سیستم استنتاج عصبی- فازی تطبیقی است.

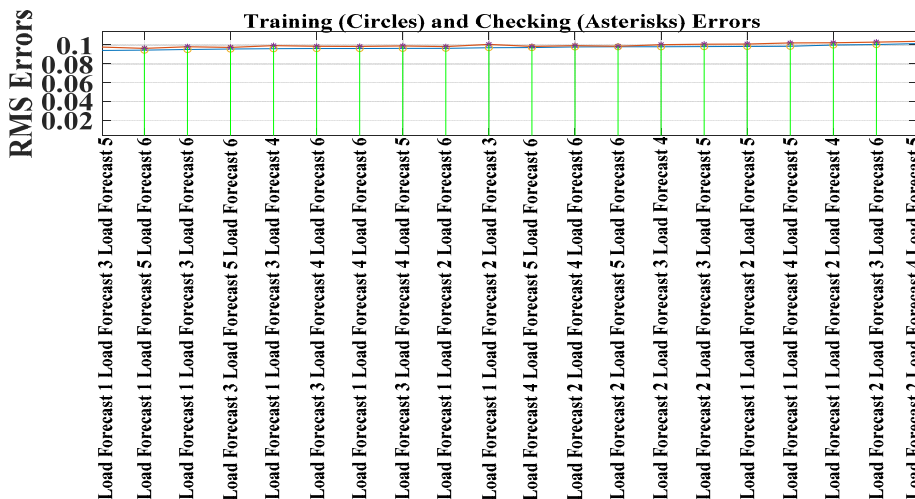
### ۳-۱ محاسبه توان خروجی ایستگاه خورشیدی

روند محاسبه توان خروجی فوتوولتائیک مطابق آنچه در بخش ۲-۴ بیان گردید، محاسبه شد و نتایج آن در شکل ۴ نمایش داده شده است. با داشتن ظرفیت ایستگاه خورشیدی  $C = 814 \text{ MW}$ ، زاویه شیب خورشیدی  $\gamma$  و با استفاده از (۱۴) تا (۲۱) می توان خروجی ایستگاه خورشیدی  $P_t$  را محاسبه کرد.



با استفاده از مقادیر محاسبه شده و روابط مذکور، توان خروجی ایستگاه خورشیدی با مشخصات ارائه شده محاسبه گردیده است. این مقادیر به عنوان داده های هدف در مرحله آموزش مدل های پیش بینی توان خروجی ایستگاه خورشیدی مورد استفاده قرار خواهد گرفت.

### ۳-۲ محاسبه توان خروجی توربین بادی

شکل ۵ سرعت باد و توان خروجی محاسبه شده برای یک توربین بادی مجهز به ژنراتور القایی دوسو تغذیه را نمایش می دهد که در پیش بینی بار خالص در این مقاله مورد استفاده قرار گرفته است. روند محاسبه توان



شکل ۶: نمودار ترکیب پیش‌بینی‌های ممکن برای بار.



شکل ۷: پیش‌بینی سال-پیش بار با استفاده از ترکیب پیش‌بینی‌های ۱، ۳ و ۵.

شکل ۸: نمودار رگرسیون پیش‌بینی سال-پیش بار با استفاده از ترکیب پیش‌بینی‌های ۱، ۳ و ۵.

جدول ۶ نتایج ارزیابی مدل‌های ترکیبی پیش‌بینی‌های بار، توان خورشیدی و توان بادی را نمایش می‌دهد. بهترین پیش‌بینی‌های انجام‌شده با استفاده از روش انتخاب ویژگی تحلیل اجزای همسایگی و حل مسأله رگرسیون به روش mini-batch-LBFGS برای بار و توان‌های خورشیدی و بادی به ترتیب دارای میانگین قدر مطلق درصد خطایی برابر با ۱۰.۶۲٪، ۹.۲۴۷۲٪ و ۰.۶۵۷۲۳٪ هستند که از طریق ترکیب پیش‌بینی‌ها با استفاده از روش پیشنهادی مبتنی بر سیستم استنتاج عصبی-فازی تطبیقی، مقدار شاخص مذکور به ترتیب به میزان ۰.۹۴۷٪، ۰.۳۰۷۹٪ و ۰.۰۴۲٪ کاهش یافته است.

### ۳-۵ مقایسه نتایج

مدل پیشنهادی در قسمت پیش‌بینی بار با مدل‌های تائو و رگرسیون چندکی که مدل‌های مرسوم برای مقایسه نتایج پیش‌بینی بار هستند مقایسه می‌شود. بدین منظور یک پیش‌بینی شش‌ماهه از ابتدای ماه جولای تا انتهای ماه دسامبر سال ۲۰۱۱ با استفاده از مدل‌های مذکور انجام گردیده است. این بخش فقط برای نمایش تفاوت نتایج به دست آمده با نتایج سایر روش‌ها در یک دوره پیش‌بینی شش‌ماهه در نظر گرفته شده است.

با توجه به جدول ۷ از بین پیش‌بینی‌های انجام‌شده، مدل ترکیبی پیشنهادی که مبتنی بر ترکیب چندین پیش‌بینی با استفاده از سیستم استنتاج عصبی-فازی تطبیقی است، کمترین شاخص‌های خطا و بیشترین شاخص  $R^2$  را ارائه داده است. منظور از QRA مدل‌های ساخته‌شده مبتنی بر روش رگرسیون چندکی و منظور از TAO مدل‌های ساخته‌شده

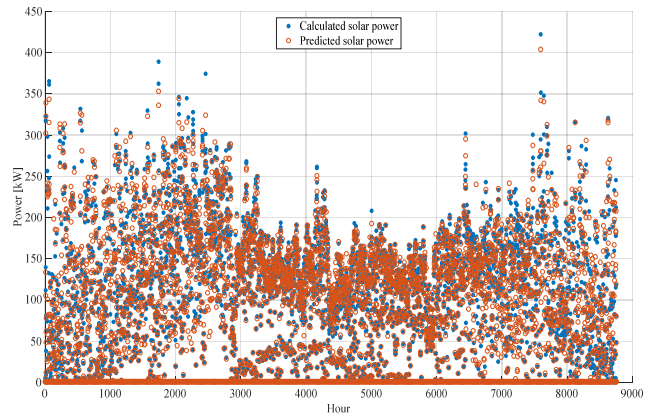

جدول ۶: ارزیابی مدل‌های ترکیب پیش‌بینی‌ها.

مدل	MAE	MAPE (%)	MSE	RMSE	R <sup>2</sup>
بار	۱۳/۹۵۶	۹/۱۱۵	۴۰۳/۴۳	۲۰/۰۸۶	۰/۸۴۸
خورشیدی	۵/۵۷۳۲	۸/۹۳۹۳	۲۶۵/۳۴	۱۶/۲۸۹	۰/۹۵۵
بادی	۰/۰۰۰۴	۰/۰۶۱۵	۰/۰۰۰۲	۰/۰۰۱۵۳	۰/۹۹۹

بادی تقسیم کرد. با استفاده از روش تحلیل اجزای همسایگی برای مسأله رگرسیون و حل مسأله رگرسیون با استفاده از روش mini-batch-LBFGS می‌توان وزن‌های مسأله رگرسیون را برای انجام پیش‌بینی‌های جدید به دست آورد.


نتایج مرحله انتخاب پیش‌بینی‌های بار و اعتبارسنجی از آنها در شکل ۶ آمده است. همان‌طور که مشاهده می‌شود ترکیب پیش‌بینی‌های ۱، ۳ و ۵ کمترین جذر میانگین مربعات خطا را ارائه داده که در نتیجه مدل ترکیب پیش‌بینی‌های بار با استفاده از داده‌های پنجره تنظیمی و پیش‌بینی‌های تولیدشده برای آن با استفاده از مدل‌های ۱، ۳ و ۵ آموزش داده می‌شود. نمودار پراکندگی پیش‌بینی بلندمدت بار که به عنوان پیش‌بینی سال-پیش بار معرفی شده است از طریق ترکیب پیش‌بینی‌های بلندمدت انجام‌شده با استفاده از مدل‌های ۱، ۳ و ۵ در شکل ۷ آمده و همچنین نمودار رگرسیون آن با استفاده از مدل‌های ۱، ۳ و ۵ در شکل ۸ نمایش داده شده است.

نتایج انتخاب پیش‌بینی‌های توان‌های خورشیدی و بادی در روندی مشابه با پیش‌بینی بار به ترتیب در شکل‌های ۹ تا ۱۴ نمایش داده شده است. مدل‌های ۴، ۶ و ۷ از مدل‌های خورشیدی و مدل‌های ۱، ۴ و ۶ از مدل‌های بادی به عنوان ترکیب برتر، کمترین میزان جذر میانگین مربعات خطا را دارند.




شکل ۹: پیش‌بینی سال- پیش بار با استفاده از ترکیب پیش‌بینی‌های ۴، ۶ و ۷.

شکل ۱۰: نمودار رگرسیون پیش‌بینی سال- پیش توان خورشیدی با استفاده ترکیب پیش‌بینی‌های ۴، ۶ و ۷.



شکل ۱۱: نمودار ترکیب پیش‌بینی‌های ممکن با استفاده از مدل‌های خورشیدی.



شکل ۱۲: نمودار ترکیب پیش‌بینی‌های ممکن با استفاده از مدل‌های بادی.


الکتریکی و پارامترهای مؤثر بر آن اشاره کرد. در این مقاله یک روش بهینه‌سازی برای پیش‌بینی بار خالص با استفاده از روش‌های تحلیل اجزای همسایگی و ترکیب پیش‌بینی‌ها با استفاده از سیستم استنتاج عصبی- فازی ارائه شده است. هدف اصلی روش پیشنهادشده، افزایش دقت پیش‌بینی بار خالص از طریق بهبود پیش‌بینی‌های نقطه‌ای است. تقسیم داده‌ها به زیرمجموعه دارای همپوشانی برای تولید مدل‌های خواهری و مقایسه آن با مدل‌های تائو و رگرسیون چندکی که مدل‌های مرسوم برای مقایسه نتایج پیش‌بینی بار هستند، کاهش خطای پیش‌بینی را سبب می‌شود. همچنین مقایسه انجام‌شده بین نتایج ارائه‌شده در این مقاله با مراجع دیگر نشان می‌دهد به ترتیب خطای MAPE برای توان بار، خورشیدی و بادی به میزان ۰٫۹۴۷٪، ۰٫۳۰۷۹٪ و ۰٫۰۰۴۲٪ بهبود

با استفاده از روش رگرسیون خطی چندگانه وانیل تائو است. شاخص‌های میانگین مطلق خطا، میانگین قدر مطلق درصد خطا، میانگین مربعات خطا و جذر میانگین مربعات خطا به ترتیب برای مدل پیشنهادی در این مقاله برابر با ۱۵٫۳۱۲، ۹٫۸۵۶۴، ۵۲٫۹۱ و ۲۳٫۰۰۲ است که کاهش شاخص‌های خطا را نسبت به بهترین مدل‌های قبل از خود نشان می‌دهند. در مورد مدل پیشنهادی، مقدار شاخص مذکور ۰٫۸۲۱۱۹ است که بیشترین مقدار محاسبه‌شده در میان پیش‌بینی‌های ارائه‌شده در بازه زمانی جولای تا دسامبر ۲۰۱۱ را نشان می‌دهد.

#### ۴- نتیجه‌گیری

از عوامل مهم در طرح توسعه انرژی الکتریکی می‌توان به پیش‌بینی بار






شکل ۱۳: پیش‌بینی سال - پیش بار با استفاده از ترکیب پیش‌بینی‌های ۱، ۴ و ۶

### مراجع

- [1] J. Armstrong, Principles of Forecasting: A Handbook for Researchers and Practitioners, Springer; 2001.
- [2] V. Genre, G. Kenny, A. Meyler, and A. Timmermann, "Combining expert forecasts: can anything beat the simple average?" *Int J. Forecast.*, vol. 29, no. 1, pp. 108-121, Jan./Mar. 2013.
- [3] K. Wallis, "Combining forecasts forty years later," *Applied Financial Economics*, vol. 21, no. 1-2, pp. 33-41, 2011.
- [4] L. Rokach, "Ensemble-based classifiers," *Artificial Intelligence Review*, vol. 33, pp. 1-39, 2010.
- [5] O. Abedinia, N. Amjadi, and H. Zareipour, "A new feature selection technique for load and price forecast of electrical power systems," *IEEE Trans. Power Syst.*, vol. 32, no. 1, pp. 62-74, Jan. 2017.
- [6] G. Li, Y. Li, and F. Roozitalab, "Midterm load forecasting: a multistep approach based on phase space reconstruction and support vector machine," *IEEE Systems Journal*, vol. 14, no. 4, pp. 4967-4977, Dec. 2020.
- [7] D. K. Ranaweera, G. G. Karady, and R. G. Farmer, "Effect of probabilistic inputs on neural network-based electric load forecasting," *IEEE Trans. Neural Network*, vol. 7, no. 6, pp. 1528-1532, Nov. 1996.
- [8] W. Zhang, H. Quan, and D. Srinivasan, "An improved quantile regression neural network for probabilistic load forecasting," *IEEE Trans. Smart Grid*, vol. 10, no. 4, pp. 4425-4434, Jul. 2019.
- [9] Z. Deng, B. Wang, Y. Xu, T. Xu, C. Liu, and Z. Zhu, "Multi-scale convolutional neural network with time-cognition for multi-step short-term load forecasting," *IEEE Access*, vol. 7, pp. 88058-88071, Jul. 2019.
- [10] Z. Yu, Z. Niu, W. Tang, and Q. Wu, "Deep learning for daily peak load forecasting-a novel gated recurrent neural network combining dynamic time warping," *IEEE Access*, vol. 7, pp. 17184-17194, Jan. 2019.
- [11] D. Niu, Y. Wang, and D. D. Wu, "Power load forecasting using support vector machine and ant colony optimization," *Elsevier Expert Systems with Applications*, vol. 37, no. 3, pp. 2531-2539, Mar. 2010.
- [12] N. Amjadi, F. Keynia, and H. Zareipour, "Short-term load forecast of microgrids by a new bilevel prediction strategy," *IEEE Trans. Smart Grid*, vol. 1, no. 3, pp. 286-294, Dec. 2010.
- [13] N. Charlton and C. Singleton, "A refined parametric model for short term load forecasting," *Int J. Forecast.*, vol. 30, no. 2, pp. 364-368, Apr./Jun. 2014.
- [14] D. Fay and J. Ringwood, "On the influence of weather forecast errors in short-term load forecasting models," *IEEE Trans. Power Syst.*, vol. 25, no. 3, pp. 1751-1758, Aug. 2010.
- [15] J. W. Taylor and R. Buizza, "Neural network load forecasting with weather ensemble predictions," *IEEE Trans. Power Syst.*, vol. 17, no. 3, pp. 626-632, Aug. 2002.
- [16] T. Hong and P. Wang, "Fuzzy interaction regression for short term load forecasting," *Fuzzy Optim. Decis. Making*, vol. 13, no. 1, pp. 91-103, Mar. 2014.
- [17] D. Saez, F. Avila, D. Olivares, C. Canizares, and L. Marin, "Fuzzy prediction interval models for forecasting renewable resources and



شکل ۱۴: نمودار رگرسیون پیش‌بینی سال - پیش توان بادی با استفاده از ترکیب پیش‌بینی‌های ۱، ۴ و ۶

جدول ۷: ارزیابی پیش‌بینی‌های شش‌ماهه برای انجام مقایسه.

مدل	MAE	MAPE	MSE	RMSE	R <sup>2</sup>
TAO1	۱۹٫۶۵	۱۲٫۶۴۸	۷۵۶٫۳۹	۲۷٫۵۰۳	۰٫۷۴۴۲۷
TAO2	۲۰٫۰۲۹	۱۲٫۸۹۳	۸۰۰٫۱۳	۲۸٫۲۸۷	۰٫۷۲۹۵۹
TAO3	۱۶٫۹۲۲	۱۰٫۸۹۲	۵۹۲٫۵۵	۲۴٫۳۴۲	۰٫۷۹۹۷۴
QRA1	۱۹٫۶۶۹	۱۲٫۶۶	۷۷۲٫۴	۲۷٫۷۹۲	۰٫۷۳۸۹۶
QRA2	۱۹٫۹۵	۱۲٫۸۴۲	۸۱۸٫۷	۲۸٫۶۱۳	۰٫۷۲۳۳۱
QRA3	۱۷٫۱۷۸	۱۱٫۰۵۷	۶۲۲٫۶۷	۲۴٫۹۵۳	۰٫۷۸۹۵۶
NCA1	۱۶٫۱۱۲	۱۰٫۳۷۱	۵۶۵٫۲۴	۲۳٫۷۷۵	۰٫۸۰۸۹۷
NCA2	۱۸٫۵۶۸	۱۱٫۹۵۲	۶۹۸٫۱۲	۲۶٫۴۲۲	۰٫۷۶۴۰۷
NCA3	۱۷٫۳۱۲	۱۱٫۱۴۴	۶۳۰٫۳۶	۲۵٫۱۰۷	۰٫۷۸۶۹۷
NCA4	۱۵٫۸۵۸	۱۰٫۲۰۸	۵۴۴٫۰۷	۲۳٫۲۲۵	۰٫۸۱۶۱۳
NCA5	۱۵٫۹۴۶	۱۰٫۲۶۴	۵۵۰٫۷۸	۲۳٫۴۶۹	۰٫۸۱۳۸۶
NCA6	۱۶٫۹۱۹	۱۰٫۸۹۱	۶۳۲٫۵۷	۲۵٫۱۵۱	۰٫۷۸۶۲۲
ANFIS	۱۵٫۳۱۲	۹٫۸۵۶۴	۵۲۹٫۱	۲۳٫۰۰۲	۰٫۸۲۱۱۹

یافته و موجب کاهش خطا در نتایج نهایی شده است. این نتایج نشان‌دهنده توانایی روش پیشنهادی در پیش‌بینی احتمالاتی بلندمدت بار خالص شبکه با در نظر گرفتن اثر تولید توان پراکنده می‌باشد.

- [28] N. Blair, et al., *System Advisor Model, SAM 2014.1. 14: General Description*, NREL Rep. No. TP-6A20-61019, Natl. Renew. Energy Lab. Golden, vol. 13, 2014.
- [29] Y. T. Weng and Y. Y. Hsu, "Reactive power control strategy for a wind farm with DFIG," *J. of Renewable Energy*, vol. 94, pp. 383-390, Aug. 2016.
- [30] J. Tian, C. Su, and Z. Chen, "Reactive power capability of the wind turbine with doubly fed induction generator," in *Proc. IECON 39th Annual Conf. of the IEEE Industrial Electronics Society*, pp. 5312-5317, Vienna, Austria, 10-13 Nov. 2013.
- [31] J. G. Slootweg, S. W. H. de Haan, H. Polinder, and W. L. Kling, "General model for representing variable speed wind turbines in power system dynamics simulations," *IEEE Trans. on Power System*, vol. 18, no. 1, pp. 144-151, Feb. 2003.
- loads in microgrids," *IEEE Trans. Smart Grid*, vol. 6, no. 2, pp. 548-556, Mar. 2015.
- [18] Y. Semero, J. Zhang, and D. Zheng, "EMD-PSO-ANFIS-based hybrid approach for short-term load forecasting in microgrids," *IET Generation, Transmission, and Distribution*, vol. 14, no. 3, pp. 470-475, Feb. 2020.
- [19] P. E. McSharry, S. Bouwman, and G. Bloemhof, "Probabilistic forecasts of the magnitude and timing of peak electricity demand," *IEEE Trans. Power Syst.*, vol. 20, no. 2, pp. 1166-1172, May 2005.
- [20] O. E. Dragomir, F. Dragomir, R. Gouriveau, and E. Minca, "Medium term load forecasting using ANFIS predictor," in *Proc. 18th Mediterranean Conf. on Control and Automation, MED'10*, pp. 23-25, Marrakech, Morocco, 23-25 Jun. 2010.
- [21] B. Akdemir and N. Cetinkaya, "Long-term load forecasting based on adaptive neural fuzzy," *Energy Procedia*, vol. 14, pp. 794-799, 2012.
- [22] B. Liu, J. Nowotarski, T. Hong, and R. Weron, "Probabilistic load forecasting via quantile regression averaging on sister forecasts," *IEEE Trans. on Smart Grid*, vol. 8, no. 2, pp. 730-737, Mar. 2017.
- [23] J. Peng, S. Gao, and A. Ding, "Study of the short-term electric load forecast based on ANFIS," in *Proc. 32nd Youth Academic Annual Conf. of Chinese Association of Automation, YAC'17*, pp. 832-836, Hefei, China, 19-21 May 2017.
- [24] I. Guler and E. D. Ubeyli, "Adaptive neuro-fuzzy inference system for classification of EEG signals using wavelet coefficients," *J. of Neuroscience Methods*, vol. 148, no. 2, pp. 113-121, 30 Oct. 2005.
- [25] W. Yang, K. Wang, and W. Zuo, "Neighborhood component feature selection for high-dimensional data," *J. of Computers*, vol. 7, no. 1, pp. 161-168, Jan. 2012.
- [26] R. Ross Jr, "Flat-plate photovoltaic array design optimization," in *Proc. 14th Photovoltaic Specialists Conf.*, vol. 1, pp. 1126-1132, San Diego, CA, USA, 7-20 Jan. 1980.
- [27] A. S. B. M. Shah, H. Yokoyama, and N. Kakimoto, "High-precision forecasting model of solar irradiance based on grid point value data analysis for an efficient photovoltaic system," *IEEE Trans. Sustainable Energy*, vol. 6, no. 2, pp. 474-481, Apr. 2015.

**محسن جهان تیغ** تحصیلات خود را در مقطع کارشناسی در دانشگاه اصفهان و کارشناسی ارشد را در رشته مهندسی برق قدرت، در دانشگاه آزاد اسلامی واحد نجفآباد به ترتیب در سال‌های ۱۳۹۶ و ۱۳۹۹ به پایان رسانده است. زمینه‌های تحقیقاتی ایشان، تولیدات پراکنده، ریزشبکه‌ها و شبکه‌های هوشمند می‌باشد.

**مجید معظمی** تحصیلات خود را در مقطع کارشناسی و کارشناسی ارشد در رشته مهندسی برق قدرت، در دانشگاه آزاد اسلامی واحد نجفآباد به ترتیب در سال‌های ۱۳۸۳ و ۱۳۸۶ به پایان رسانده است. وی تحصیلات تکمیلی خود را در مقطع دکتری در دانشگاه اصفهان ادامه داد و در سال ۱۳۹۲ موفق به اخذ مدرک دکتری در رشته مهندسی برق از این دانشگاه گردید. ایشان از سال ۱۳۸۸ به عضویت هیأت علمی دانشگاه آزاد اسلامی واحد نجفآباد درآمد و در حال حاضر استادیار برق می‌باشد. زمینه‌های تحقیقاتی ایشان، بازار برق، بهینه‌سازی در سیستم‌های قدرت و انرژی‌های نو و ریزشبکه‌ها است.