



Computational Intelligence in Electrical Engineering
Vol. 11, No. 2, 2020
Research Paper

Probabilistic mid-term net load forecasting considering the effect of solar power using extreme learning machine

Jaber Sohrabi¹, Majid Moazami²

¹ Department of Electrical Engineering, Najafabad Branch, Islamic Azad University, Najafabad, Iran
jaber.sohrabi67@yahoo.com

² Smart Microgrid Research Center, Najafabad Branch, Islamic Azad University, Najafabad, Iran
m_moazzami@pel.iaun.ac.ir

Abstract:

The increase in power generated by using solar energy increases the uncertainty in the power grid, since the majority of meters measure only the net load of a grid regardless of the output of distributed generations. This paper proposes a framework for probabilistic mid-term net load forecasting in a power grid based on separate forecasts of the load and output power of a solar station using the combination of principal components analysis and the extreme learning machine methods. The data used in this paper is related to the NERL and GEFCom2014 data bases and the matrix of scores is extracted by the use of principal component analysis. The prediction models are trained using ORELM model and evaluated in three sections: training, validation and mid-term prediction. The main objective of the proposed method is to increase the precision of net load forecasting by improving point forecasts. The comparison between the results presented in this thesis with other references shows that the MAPE error of predicted load, and predicted output power of the solar station improved to 1.1333 and 0.3118, respectively, which will reduce overall forecast error.

Keywords: principal components analysis, mid-term net load forecasting, mid-term forecast of Solar Station output power, matrix of scores, extreme learning machine, mean absolute percentage error.



2252-083X/ © 2020 The Authors. Published by University of Isfahan

This is an open access article under the CC BY-NC-ND/4.0/ License (<https://creativecommons.org/licenses/by-nc-nd/4.0/>).



<http://dx.doi.org/10.22108/isee.2019.119079.1276>

پیش‌بینی احتمالاتی میان‌مدت بار خالص شبکه با در نظر گرفتن اثر تولید توان خورشیدی

با استفاده از ماشین یادگیری شدید

جابر سهرابی^۱، مجید معظمی^{۱ و ۲}

۱- دانشکده مهندسی برق، واحد نجف‌آباد، دانشگاه آزاد اسلامی، نجف‌آباد، ایران

jaber.sohrabi67@yahoo.com

۲- مرکز تحقیقات ریزشبکه‌های هوشمند، واحد نجف‌آباد، دانشگاه آزاد اسلامی، نجف‌آباد، ایران

m_moazzami@pel.iaun.ac.ir

چکیده: افزایش میزان نفوذ توان تولیدشده با استفاده از انرژی خورشیدی، افزایش عدم قطعیت را در شبکه قدرت موجب می‌شود؛ زیرا بیشتر ادوات اندازه‌گیری، بار خالص شبکه را بدون در نظر گرفتن خروجی تولیدات پراکنده اندازه‌گیری می‌کنند. این مقاله روشی را برای پیش‌بینی احتمالاتی میان‌مدت بار خالص در شبکه برق براساس پیش‌بینی‌های مجزای بار و توان خروجی یک ایستگاه خورشیدی با استفاده از ترکیب روش‌های تحلیل اجزای اصلی و روش ماشین یادگیری شدید پیشنهاد می‌دهد. داده‌های پیش‌بینی مربوط به دو پایگاه داده NERL و GEFCom2014 برای آموزش مدل‌ها استفاده شده‌اند و با روش تحلیل اجزای اصلی ماتریس نمرات از این مجموعه داده‌ها، استخراج و با مدل ماشین یادگیری شدید ORELM مدل‌های پیش‌بینی آموزش داده می‌شوند و در سه بخش آموزش، اعتبارسنجی و پیش‌بینی میان‌مدت ارزیابی می‌شوند. هدف اصلی روش پیشنهادشده افزایش دقت پیش‌بینی بار خالص از طریق بهبود پیش‌بینی‌های نقطه‌ای است. مقایسه انجام‌شده بین نتایج ارائه‌شده در این مقاله با مراجع دیگر نشان می‌دهد خطای میانگین مطلق خطای پیش‌بینی‌های بار و توان خروجی ایستگاه خورشیدی به ترتیب به میزان ۱/۱۳۳۳ و ۰/۳۱۱۸ بهبود یافته است که کاهش خطای کلی پیش‌بینی را سبب می‌شود.

واژه‌های کلیدی: تحلیل اجزای اصلی، پیش‌بینی میان‌مدت بار خالص، پیش‌بینی میان‌مدت توان خروجی ایستگاه خورشیدی، ماتریس نمرات، ماشین یادگیری شدید، میانگین مطلق درصد خطا

۱- مقدمه

خورشیدی، در دهه گذشته با سرعت چشمگیری افزایش یافته‌اند. باید توجه داشت افزایش میزان نفوذ توان تولیدشده با استفاده از انرژی خورشیدی، افزایش عدم قطعیت در شبکه قدرت را موجب می‌شود؛ زیرا بیشتر ادوات اندازه‌گیری، بار خالص شبکه را بدون در نظر گرفتن خروجی تولیدات پراکنده اندازه‌گیری می‌کنند. در نتیجه، این تولیدات برای خرده‌فروشان و اپراتور سیستم توزیع قابل رؤیت نخواهد بود. مرجع [۱] روشی برای انتخاب ویژگی‌ها برای آموزش مدل‌های پیش‌بینی بار و قیمت برق ارائه داده است که علاوه بر لحاظ کردن ارتباط بین ویژگی‌ها و تکرار داده‌های مشابه میان آنها، اثر متقابل ویژگی‌ها بر یکدیگر را در نظر گرفته

برنامه‌ریزی در سیستم‌های قدرت با پیش‌بینی بار الکتریکی آغاز می‌شود. پیش‌بینی بار را می‌توان مؤثرترین عامل در مدیریت اقتصادی سیستم قدرت دانست. همچنین، تأسیسات تولید پراکنده توان الکتریکی از جمله پانل‌های

^۱ تاریخ ارسال مقاله: ۱۳۹۸/۰۶/۱۶

تاریخ پذیرش مقاله: ۱۳۹۸/۰۹/۱۹

نام نویسنده مسئول: مجید معظمی

نشانی نویسنده مسئول: ایران - اصفهان - نجف آباد - دانشگاه آزاد اسلامی - واحد نجف‌آباد - دانشکده مهندسی برق

است. در مرجع [۲] روشی متشکل از چهار بخش برای پیش‌بینی بار و قیمت برق پیشنهاد شده است. در بخش اول از تبدیل موجک گسسته برای ریزسازی سیگنال اصلی با حفظ اطلاعات باارزش استفاده شده است. بخش دوم از مدل الگوریتم انتخاباتی فازی برای انتخاب بهترین داده‌ها با بیشترین ارتباط و کمترین تکرار بهره می‌گیرد و بخش سوم، یک موتور پیش‌بینی‌کننده براساس سیستم چند ورودی - چند خروجی بردار پشتیبان است. درنهایت، بخش چهارم با توجه به تابع هدفی متشکل از خطای ناشی از پیش‌بینی و روش بهبودیافته کلسونی مصنوعی زنبورعسل، تنظیم شاخص‌های شبکه بردار پشتیبان پیشنهادی را بررسی می‌کند.

الگوریتم بهینه‌سازی توده ذرات^۱ یکی از روش‌هایی است که برای به دست آوردن مقادیر بهینه ماشین‌های بردار پشتیبان در ساختن مدل پیش‌بینی بار به کار گرفته شده است [۳]. در مرجع [۴]، این الگوریتم با الگوریتم بهینه‌سازی گذار شبکه^۲ ترکیب شده است. روش ارائه‌شده در این مرجع شامل دو مرحله است. ابتدا از الگوریتم گذار شبکه برای محدودکردن منطقه جستجو به منظور یافتن مقادیر بهینه استفاده می‌شود و پس از الگوریتم بهینه‌سازی توده ذرات وارد عمل می‌شود تا در منطقه انتخاب‌شده مقادیر بهینه ماشین بردار پشتیبان را بیابد. از نظریه آزمون قائم^۳ برای یافتن مقادیر بهینه مدل رگرسیون بردار پشتیبان در [۵] استفاده شده است. در مراجع [۶،۷] چندین روش با یکدیگر ترکیب شده‌اند تا مدل پیش‌بینی تولید شود. مرجع [۶] روشی ارائه می‌دهد که روش میانگین رگرسیون چندکی را به صورت چشمگیری گسترش می‌دهد و از تجزیه و تحلیل مؤلفه‌های اصلی برای خودکارسازی روند انتخاب از میان مجموعه‌ای بزرگ از مدل‌های پیش‌بینی استفاده می‌کند که برای محاسبه در دسترس‌اند. این روش برای قیمت‌گذاری از طریق داده‌ها بسیار کارآمد است. یکی از روش‌های پیش‌بینی، استفاده از روش میانگین رگرسیون چندکی است که در پیش‌بینی قیمت برق استفاده شده است. بیشتر روش‌های ارائه‌شده در میحث پیش‌بینی بار، به صورت نقطه‌ای بوده است که مقدار مورد انتظار بار را در هر نقطه ارائه می‌دهد. در شبکه‌های هوشمند، میزان تقاضای برق

افزایش یافته و پیش‌بینی را مشکل‌تر کرده است؛ در نتیجه، پیش‌بینی بار احتمالاتی، اطلاعات بیشتری را درباره متغیربودن و عدم اطمینان مقادیر بار در آینده ارائه می‌دهد و برای برنامه‌ریزی و عملیات در سیستم‌های قدرت بسیار اهمیت دارد. این روش، یک روش عملی برای تولید پیش‌بینی بار احتمالاتی را با استفاده از میانگین رگرسیون چندکی بر روی مجموعه‌ای از پیش‌بینی‌های نقطه‌ای پیشنهاد می‌کند [۷]. در مرجع [۸] روش‌هایی شامل ترکیب فازی وزن‌ها، استفاده از الگوریتم خفاش^۴ برای به دست آوردن مقادیر بهینه پارامترهای ماشین بردار پشتیبان و فیلتر کالمن با یکدیگر ترکیب شده‌اند. در مرجع [۹] ابتدا یک شبکه توپولوژیکی روزبه‌روز^۵ برای یافتن شباهت میان روزها ساخته می‌شود. سپس الگوریتم پیاده‌روی تصادفی همراه با شروع مجدد^۶ روی شبکه تولیدشده در مرحله قبل اعمال می‌شود تا از این طریق مجموعه آموزش، تولید و با استفاده از مدل رگرسیون ماشین بردار پشتیبان مدل پیش‌بینی آموزش داده شود.

در [۱۰، ۱۱]، تمرکز روی پیش‌بینی بار خانگی است و برای انجام این کار از یادگیری عمیق استفاده شده است. در [۱۰]، یک مدل شبکه عصبی بازگشتی پیشنهاد شده و سعی شده است با افزایش تعداد و تنوع داده‌های ورودی مدل، مشکل overfit کنترل شود. در [۱۱] نیز مدل جدید دیگری براساس شبکه حافظه کوتاه - مدت بلند برای پیش‌بینی بار مناطق مسکونی ارائه شده است. در [۱۲] نیز یک شبکه عصبی مبتنی بر روشی اصلاح‌شده از الگوریتم لونبرگ - مارکوارت به منظور پیش‌بینی بار ارائه شده است.

در [۱۳] روشی ترکیبی برای پیش‌بینی احتمالاتی بار براساس ترکیب ماشین یادگیری شدید تعمیم‌یافته، شبکه عصبی موجک و بوت‌استرپ ارائه شده است و مدل ارائه‌شده با استفاده از داده‌های بازارهای اونتاریو و استرالیا آزمایش شده است. تمرکز مطالعه انجام‌شده در [۱۴]، بر بهبود شبکه عصبی مبتنی بر رگرسیون چندکی است. در این مطالعه، پیش‌بینی‌های احتمالاتی بار در دوره‌های زمانی ارائه شده‌اند. در [۱۵]، یک مدل ترکیبی مبتنی بر شبکه‌های عصبی بازگشتی و روش گردش پویای زمان برای پیش‌بینی پیک بار روزانه پیشنهاد شده است. الگوریتم پیشنهادی روی

ماشین یادگیری شدید (ORELM^۷) برای انجام آموزش نظارت شده استفاده می شود. این مدل برای کار با داده های خارج از محدوده است. در این پژوهش، داده های پیش بینی مربوط به دو پایگاه داده [۲۱] NERL و [۲۲] GEFCOM2014، برای آموزش مدل ها استفاده می شوند. برای سنجش دقت روش ارائه شده در این مقاله، نتایج شبیه سازی ابتدا با سه مدل ماشین یادگیری شدید دیگر و سپس با نتایج به دست آمده از روش ارائه شده در مرجع [۲۰] مقایسه می شوند.

در بخش ۲ روش پیشنهادی ارائه می شود. در بخش ۳ نتایج شبیه سازی و در نهایت، در بخش چهارم نتایج پژوهش انجام شده ارائه می شوند.

۲- روش پیشنهادی

در این مقاله، روش پیشنهادی برای پیش بینی میان مدت احتمالاتی بار خالص، با در نظر گرفتن اثر تولیدات توان خورشیدی شامل مراحل پیش پردازش، آموزش و اعتبارسنجی مدل های پیش بینی و پس پردازش است. فلوچارت روش مذکور در شکل (۱) نمایش داده شده است. این روش ترکیبی از روش های تحلیل اجزای اصلی و ماشین یادگیری شدید قدرتمند در کار با داده های خارج از محدوده (ORLEM) است.

در بخش اول، داده های خام از مجموعه داده های NERL استخراج می شوند. ماتریس هدف در مرحله آموزش مدل پیش بینی بار داده های بار، موجود در مجموعه داده GEFCOM 2014 است؛ اما ماتریس هدف در مرحله آموزش مدل پیش بینی توان خروجی ایستگاه خورشیدی باید ابتدا محاسبه شود. شایان ذکر است به منظور نرمال سازی و کاهش خطای پیش بینی از ماتریس های هدف، لگاریتم طبیعی (ln) گرفته می شود.

در مرحله بعدی روی ماتریس های ورودی مدل های آموزش روش تحلیل اجزای اصلی انجام می گیرد و ماتریس های نمرات تولید شده به عنوان ماتریس های ورودی در مرحله آموزش استفاده می شوند. در مرحله آموزش، ۷۵٪ ماتریس های ورودی، برای آموزش مدل ها و ۲۵٪ آنها برای اعتبارسنجی از مدل های آموزش داده شده استفاده می شود.

پلت فرم یادگیری عمیق (Theano) پیاده سازی شده و روی مجموعه داده های بار شبکه اروپایی در فناوری های هوشمند آزمایش شده است. در [۱۶]، تخمین چگالی کرنل و روش میانگین وفقی برای جمع آوری پروفیل و چگالی بار به کار گرفته شده و از اتوانکدرهای متصل به هم برای پیش بینی کمیت های نامشخص بار بهره گرفته شده است. در این روش، بارهای مناطقی که در همسایگی یکدیگرند، برای تخمین بار مناطق وسیع تر با روشی مبتنی بر خوشه بندی پروفیل بار با یکدیگر جمع می شوند.

در [۱۷]، یک روش داده محور مبتنی بر یادگیری عمیق برای پیش بینی کوتاه مدت بار ارائه شده است. در این مطالعه داده ها با استفاده از تبدیل Box-Cox پردازش می شوند و وابستگی میان قیمت برق، دما و بار با استفاده از مدل های پارامتری کاپولا و محاسبه آستانه پیک بار تحلیل می شود. در [۱۸]، روشی مبتنی بر شبکه های عمیق باقی مانده ارائه شده است. این روش شامل یک استراتژی دو مرحله ای به منظور بهبود قابلیت تعمیم شبکه مذکور است. همچنین، برای انجام پیش بینی احتمالاتی بار از روش مونت کارلو استفاده شده است. در مرجع [۱۹]، یک مدل شبکه عصبی کانولوشن چند مقیاسی با شناخت زمان پیشنهاد شده است. در ابتدا، یک مدل شبکه عصبی کانولوشن عمیق، ویژگی های سطوح متفاوت داده ها را استخراج می کند. علاوه بر این، یک کدگذاری زمان ارائه شده است.

در مرجع [۲۰]، روشی مبتنی بر شبکه های عصبی برای پیش بینی احتمالاتی بار خالص در شبکه برق با در نظر گرفتن اثر تولیدات توان خورشیدی ارائه شده است.

در این مقاله، روشی ترکیبی به منظور پیش بینی احتمالاتی میان مدت بار خالص در شبکه برق ارائه می شود. روش مذکور مبتنی بر اجرای دو پیش بینی مجزا برای بار و توان خروجی یک ایستگاه خورشیدی است. به این معنی که بار خالص برابر با اختلاف میان توان تولیدی پیش بینی شده برای ایستگاه خورشیدی و بار تخمین زده شده در شبکه برق است. روش پیشنهادی برای ساخت مدل های پیش بینی، استفاده از ماتریس نمرات استخراج شده از ماتریس خام داده ها است. ماتریس های نمرات به عنوان ورودی مدل ها در آموزش نظارت شده به کار گرفته می شوند. در این مقاله،

داده‌های مذکور است که هر سطر آن نشان‌دهنده یک ساعت است.

در آموزش نظارت‌شده، نمونه‌های آموزش شامل ورودی‌ها و مقدار مطلوب برای آنها است. ماتریس مقادیر مطلوب یا به عبارتی ماتریس هدف در مدل پیش‌بینی بار، بارهای استخراج‌شده از داده‌های 2014 GEFCom و ماتریس هدف در مدل‌های پیش‌بینی توان خورشیدی، توان خروجی محاسبه‌شده برای ایستگاه خورشیدی است که نحوه محاسبه آن در ادامه بیان خواهد شد.

۲-۲- محاسبه توان خروجی پانل خورشیدی


برای تخمین توان تولیدشده با پانل‌های خورشیدی نیاز است ابتدا مقدار توان خروجی این پانل‌ها با توجه به داده‌های در دسترس محاسبه شود. ماتریس (بردار) توان‌های محاسبه‌شده، ماتریس هدف در آموزش نظارت‌شده برای ساختن مدل‌های پیش‌بینی توان خورشیدی است.

پانل‌های خورشیدی در مکان‌های مختلف و با تنظیمات مختلفی نصب می‌شوند (با زاویه شیب و آزمون‌های متفاوت). بدون داشتن داده‌هایی که به‌صورت دقیق اندازه‌گیری شده‌اند، محاسبه زاویه شیب و ظرفیت تولید ایستگاه خورشیدی امکان‌پذیر نیست؛ درحالی‌که زاویه شیب‌های پانل‌های خورشیدی موجود در یک منطقه ممکن است با یکدیگر متفاوت باشند. این زوایا به‌طور کلی مشابه عرض جغرافیایی اند که در آن، توان خورشیدی با پانل حداکثر تولید می‌شود [۲۰]. با دانستن ظرفیت تولید برای ایستگاه خورشیدی، زاویه شیب نصب و آزمون آن، توان خروجی ایستگاه خورشیدی تخمین زده می‌شود [۲۳].

$$P_t \approx C \frac{I_{PV,t}}{1000} [1 - \mu(T_{PV,t} - 25)] \quad (1)$$

در رابطه بالا C بیان‌کننده ظرفیت ایستگاه خورشیدی، تابش خورشیدی دریافت‌شده در پانل خورشیدی برحسب (W/m^2) ، μ ثابت دمایی ایستگاه خورشیدی و $T_{PV,t}$ دمای ایستگاه خورشیدی برحسب (C°) است. عوامل تعیین‌کننده دمای ایستگاه خورشیدی $T_{PV,t}$ ، جنس مواد سازنده سلول‌های خورشیدی، دمای محیط و اثر انباشته تابش خورشیدی‌اند [۲۳]. با صرف‌نظر کردن از تغییرات اثر

در مرحله بعدی با استفاده از مدل پیش‌بینی بار خالص، باقی‌مانده‌ها پیش‌بینی می‌شوند و نتایج پیش‌بینی بار احتمالاتی و پیش‌بینی احتمالاتی توان خروجی ایستگاه خورشیدی ارائه می‌شوند. در ادامه، بخش‌های مختلف روش پیشنهادی به تفصیل بیان می‌شوند.



شکل (۱) فلوچارت روش پیشنهادی

۲-۱- تولید داده‌ها

برای آموزش مدل‌های پیش‌بینی و آزمایش آنها، نیاز است داده‌ها به‌صورت ماتریسی تولید شوند؛ به‌صورتی که هر سطر ماتریس مربوط به داده‌های یک مشاهده خاص است. در روش پیشنهادی این مقاله، ماتریس ورودی برای آموزش مدل‌های پیش‌بینی با استفاده از داده‌های پایگاه داده NERL ساخته می‌شود. بخش اول ماتریس داده‌ها برای مدل‌های پیش‌بینی بار و توان تولیدی توسط پانل‌های خورشیدی، داده‌های مربوط به تاریخ‌های اندازه‌گیری، شامل شماره ماه در سال، روز در ماه و ساعت در روز است. بخش دوم داده‌ها شامل تابش نرمال مستقیم^۹ (DNI)، تابش افقی پراکنده^۹ (DHI)، (Surface Albedo) و دما است. ماتریس ورودی مدل‌های پیش‌بینی شامل هفت ستون از

در رابطه بالا ω بیان کننده زاویه ساعت است که در ظهر (ساعت ۱۲) برابر با صفر در نظر گرفته می شود و مقدار آن با استفاده از رابطه زیر محاسبه می شود:

$$\omega = (t-12) \times 15^\circ + (\psi - D \times 15^\circ) \quad (۷)$$

ψ و D به ترتیب طول جغرافیایی و منطقه زمانی را نمایش می دهند که مقدار هر دو پارامتر را می توان ثابت در نظر گرفت. زاویه حرکت خورشید δ با استفاده از رابطه زیر محاسبه می شود:

$$\delta = 2\pi \times \frac{23.45^\circ}{360^\circ} \times \sin(2\pi \times \frac{284+N}{Y}) \quad (۸)$$

N شماره روز در سال و Y تعداد کل روزهای سال است. با توجه به روابط بالا تمامی پارامترهای بیان شده، به غیر از ظرفیت ایستگاه خورشیدی C ، زاویه شیب و آزمون ایستگاه خورشیدی را می توان با استفاده از مجموعه داده های NERL محاسبه یا تخمین زد [۲۵]. با داشتن ظرفیت ایستگاه خورشیدی C ، زاویه شیب و آزمون ایستگاه خورشیدی، خروجی ایستگاه خورشیدی با استفاده از روابط (۱) تا (۸) محاسبه می شود.

۲-۳- پیش پردازش

روش پیشنهادی در این مقاله شامل بخش پیش پردازش است که با استفاده از روش تحلیل اجزای اصلی انجام می گیرد. نخستین جزء اصلی از مجموعه ویژگی های $X_1, X_2, \dots, X_p$ ترکیب خطی نرمال شده از ویژگی هاست که بالاترین واریانس را دارند [۲۶]:

$$Z_1 = \phi_{11}X_1 + \phi_{21}X_2 + \dots + \phi_{p1}X_p \quad (۹)$$

$$\sum_{j=1}^p \phi_{j1}^2 = 1 \quad (۱۰)$$

رابطه (۲) نشان دهنده نرمال سازی است. عناصر $\phi_{11}, \dots, \phi_{p1}$ با نام بارگذاری های نخستین جزء اصلی شناخته می شوند که بردار بارگذاری جزء اصلی را می سازند:

$$\phi_1 = [\phi_{11}, \phi_{21}, \dots, \phi_{p1}] \quad (۱۱)$$

انباشتگی تابش خورشیدی در زمان، دمای ایستگاه خورشیدی با استفاده از رابطه زیر محاسبه می شود [۲۳]:

$$T_{PV,t} = T_{A,t} + \frac{I_{PV,t}}{800} \times (N_{oct} - 20) \quad (۲)$$

در رابطه (۲) $T_{A,t}$ نشان دهنده دمای هوای محیط بر حسب (C°) و N_{oct} دمای کار نامی سلول های خورشیدی است و می توان این متغیر را ثابت در نظر گرفت. تابش خورشیدی دریافت شده در سطح ایستگاه خورشیدی، مجموع تابش های مستقیم، پراکنده و بازتابی است.

$$I_{PV,t} = I_{0,t} \tau_{b,t} (\sin \alpha \cos \beta + \cos \alpha \sin \beta (\gamma - A)) + I_{d,t} \left(\frac{1 + \cos \beta}{2} + (I_{b,t} + I_{d,t}) \rho_l \left(\frac{1 - \cos \beta}{2} \right) \right) \quad (۳)$$

$\tau_{b,t}$ نشان دهنده ضریب شفافیت جو و ρ_l نشان دهنده Surface Albedo است. α و A ارتفاع و آزمون خورشیدند. α و A را می توان با استفاده از طول و عرض جغرافیایی، ساعت در روز و روز در سال محاسبه کرد که نشان دهنده متغیر زمان t هستند. β زاویه شیب γ آزمون ایستگاه خورشیدی، $I_{0,t}$ تابش نرمال مستقیم (DNI) و $I_{d,t}$ تابش افقی پراکنده (DHI) است. $I_{b,t}$ تابش افقی مستقیم است و با استفاده از رابطه زیر محاسبه می شود:

$$I_{b,t} = I_{0,t} \tau_{b,t} \sin \alpha \quad (۴)$$

محاسبه $I_{PV,t}$ شامل محاسبه زوایای بسیاری است که میان خورشید و ایستگاه خورشیدی ایجاد می شوند و به طور خلاصه به صورت زیر تعریف می شود. کسینوس آزمون خورشید با استفاده از رابطه زیر محاسبه می شود [۲۴]:

$$\cos A = \frac{\sin \alpha \sin \phi - \sin \delta}{\cos \alpha \cos \phi} \quad (۵)$$

در رابطه بالا ϕ عرض جغرافیایی منطقه مطالعه شده و δ زاویه حرکت خورشید است. سینوس ارتفاع خورشید α برابر است با:

$$\sin \alpha = \sin \phi \sin \delta + \cos \phi \cos \delta \cos \omega \quad (۶)$$

[۲۷]؛ در نتیجه، مسئله بهینه‌سازی برای مدل ORLEM به صورت زیر تعریف می‌شود:

$$\min_{\beta} C \|e\|_0 + \|\beta\|_2^2 \quad \text{subject to } y - H\beta = e \quad (۱۶)$$

رابطه بالا یک مسئله برنامه‌ریزی غیرمحدب است. یک راه حل ساده، نامحدودسازی مسئله به یک مسئله محدب بدون در نظر گرفتن ویژگی پراکندگی است. بنا بر نظریه حساسیت فشاری و روش تحلیل اجزای اصلی، بخشی از رابطه که مربوط به پراکندگی است، با استفاده از نرم l_1 بیان می‌شود.

استفاده از نرم l_1 در رابطه (۱۶) هم موجب مدل‌سازی پراکندگی می‌شود و هم به حداقل شدن تحدب در مسئله منجر می‌شود؛ در نتیجه، مسئله ارائه شده را می‌توان به یک مسئله محدب تبدیل کرد:

$$\min_{\beta} \|e\|_1 + \frac{1}{C} \|\beta\|_2^2 \quad \text{subject to } y - H\beta = e \quad (۱۷)$$

رابطه بالا یک مسئله بهینه‌سازی محدب و مقید است و روش ضرایب لاگرانژ تکمیلی (l_1 ALM) را می‌توان روی آن پیاده کرد. تابع لاگرانژ تکمیلی رابطه (۱۷) به شکل زیر بیان می‌شود:

$$L_{\mu}(e, \beta, \lambda) = \|e\|_1 + \frac{1}{C} \|\beta\|_2^2 + \lambda^T (y - H\beta - e) + \frac{\mu}{2} \|y - H\beta - e\|_2^2 \quad (۱۸)$$

در رابطه (۱۸) $\lambda \in \mathbb{R}^n$ بردار ضرایب لاگرانژ و μ پارامتر جریمه است. با توجه به مرجع [۲۸]، در روش پیشنهادی در این مقاله پارامتر جریمه برابر است با:

$$\mu = \frac{2N}{\|y\|_1} \quad (۱۹)$$

الگوریتم ALM حل بهینه (β, e) و ضریب لاگرانژ λ را از طریق مینیمم کردن تابع لاگرانژ تکمیلی ممکن می‌کند. به اختصار با داشتن (μ, λ_k) طرح الگوریتم ALM به شکل زیر بیان می‌شود:

$$\begin{cases} (e_{k+1}, \beta_{k+1}) = \arg \min_{e, \beta} L_{\mu}(e, \beta, \lambda_k) & (a) \\ \lambda_{k+1} = \lambda_k + \mu(y - H\beta_{k+1} - e_{k+1}) & (b) \end{cases} \quad (۲۰)$$

مقادیر بارگذاری به شکلی انتخاب می‌شوند که مجموع مربعات آنها برابر با ۱ باشد؛ زیرا در غیر این صورت، تنظیم این عناصر به صورت دلخواه می‌تواند به واریانس بزرگ منجر شود. اکنون یک مجموعه داده مانند X با ابعاد $n \times p$ را در نظر بگیرید. از آنجا که در این روش، تمرکز بر واریانس است، فرض می‌شود میانگین مقادیر موجود در هر ستون از X صفر شود. آنگاه ترکیبی خطی از ویژگی‌هایی مطلوب است که بالاترین واریانس را در شرایط $\sum_{j=1}^p \phi_{j1}^2 = 1$ داشته باشند:

$$Z_{i1} = \phi_{11}x_{i1} + \phi_{31}x_{i2} + \dots + \phi_{p1}x_{ip} \quad (۱۲)$$

به عبارت دیگر، بردار بارگذاری نخستین جزء اصلی با حل مسئله بهینه‌سازی زیر ممکن می‌شود:

$$\max \left\{ \frac{1}{n} \sum_{i=1}^n \left(\sum_{j=1}^p \phi_{j1}x_{ij} \right)^2 \right\} \quad \text{subject to } \sum_{j=1}^p \phi_{j1}^2 = 1 \quad (۱۳)$$

بردارهای بارگذاری و بردارهای نمرات M جزء اصلی اول یک مجموعه داده، بهترین تخمین M -بعدی از مشاهده i ام $x_{i,j}$ هستند.

$$x_{ij} \approx \sum_{m=1}^M Z_{im} \phi_{jm} \quad (۱۴)$$

به عبارت دیگر، بردارهای نمرات و بردارهای بارگذاری M جزء اصلی، زمانی تخمین درستی از داده‌های اصلی ارائه می‌کنند که M به اندازه کافی بزرگ باشد [۲۶].

$$M = \min(n-1, p), \quad x_{ij} = \sum_{m=1}^M Z_{im} \phi_{jm} \quad (۱۵)$$

۲-۴- آموزش مدل‌های پیش‌بینی

۲-۴-۱- ماشین یادگیری شدید مقاوم در کار با داده‌های خارج از محدوده (ORLEM)

به طور کلی، داده‌های خارج از محدوده، بخش کوچکی از نمونه‌های آموزشی را دربرمی‌گیرند. برای خطای مرحله آموزش e ، داده‌های خارج از محدوده به کمک پراکندگی^{۱۰} توصیف می‌شوند. نتایج پژوهش‌های انجام شده نشان می‌دهند نرم l_1 بهتر از نرم l_2 اثر پراکندگی را نشان می‌دهد

استفاده از مجموعه داده‌ای با داده‌های خارج از محدوده است. برای ساده‌تر شدن اجرای این روش، زمانی الگوریتم به پایان می‌رسد که تعداد تکرارها به تعداد مشخصی برسد. همچنین، معیارهای دیگری برای توقف الگوریتم وجود دارد که در مراجع [۳۲،۳۳] در دسترس است.

۳- نتایج شبیه‌سازی

همان‌طور که گفته شد داده‌های استفاده‌شده در این پژوهش، داده‌های آب‌وهوایی مربوط به پایگاه داده NERL در بخشی از ایالت کالیفرنیا در ایالات متحده با کد شناسایی ۸۳۲۵۷۲، عرض جغرافیایی ۲۹/۷۷ و طول جغرافیایی ۹۰/۷ است. داده‌های بار مربوط به مسابقات جهانی پیش‌بینی است. ۲۰۱۴ است.

برای آموزش مدل پیش‌بینی بار و توان خورشیدی، بازه زمانی مدنظر برای آموزش، با استفاده از روش سعی و خطا انتخاب شده است که بازه مذکور به سال‌های ۲۰۰۶-۲۰۰۷ مربوط است. مجموعه داده‌های آزمایش شامل شش ماه و شامل داده‌های ابتدای ماه ژانویه سال ۲۰۱۱ تا انتهای ماه ژوئن همین سال است. برای پیش‌بینی توان خروجی ایستگاه خورشیدی داده‌های اولیه همان داده‌های پایگاه داده NERL است. این داده‌ها شامل بخشی برای تعیین تاریخ اندازه‌گیری انجام‌شده (سال، ماه، روز، ساعت و دقیقه اندازه‌گیری)، تابش نرمال مستقیم (DNI)، تابش افقی پراکنده (DHI)، نقطه شبنم، Surface Albedo، سرعت باد، دما و فشارند که به‌صورت ساعتی اندازه‌گیری شده و در مجموعه داده‌ها ثبت شده‌اند.

ماتریس داده‌های ورودی (چه برای پیش‌بینی بار و چه برای پیش‌بینی توان خروجی ایستگاه خورشیدی) از مجموعه داده‌های NERL استخراج شده است. از میان داده‌های ارائه‌شده در مجموعه داده مذکور، در این پژوهش، داده‌های تاریخ اندازه‌گیری شامل ماه، روز و ساعت و از میان داده‌های اندازه‌گیری شده تابش نرمال مستقیم (DNI)، تابش افقی پراکنده (DHI)، Surface Albedo و دما به‌دلیل تأثیر مستقیم بر توان خروجی ایستگاه خورشیدی و مصرف بار به‌عنوان داده‌های اولیه انتخاب شده‌اند. ماتریس‌های (بردارها) هدف سه زیرمجموعه داده برای پیش‌بینی بار از

روند بهینه‌سازی در بخش اول رابطه بالا (۲۰-ا) با استفاده از الگوریتم تکراری^{۱۲} (ALM) از طریق تکنیک جهت متناوب پیاده‌سازی می‌شود که دو مجهول مسئله، یعنی e و β را به‌طور پیاپی به‌روز می‌کند. درواقع، به کمک الگوریتم ALM مسائل زیر به‌منظور تولید تکرار جدید حل می‌شوند:

$$\begin{cases} \beta_{k+1} = \arg \min_{\beta} L_{\mu}(e_k, \beta, \mu_k) \\ e_{k+1} = \arg \min_e L_{\mu}(e, \beta_{k+1}, \lambda_k) \\ \lambda_{k+1} = \lambda_k + \mu(y - H\beta_{k+1} - e_{k+1}) \end{cases} \quad (a) \quad (21)$$

مطابق با مرجع [۲۹]، β_{k+1} حل صریح زیر را تأیید می‌کند:

$$\beta_{k+1} = (H^T H + \frac{2}{C\mu I})^{-1} H^T (y - e_k \frac{\lambda_k}{\mu}) \quad (22)$$

و e_{k+1} برابر است با:

$$e_{k+1} = \text{shrink}(y - H\beta_{k+1} + \frac{\lambda_k}{\mu}, \frac{1}{\mu}) \square \max \left\{ \left| y - H\beta_{k+1} + \frac{\lambda_k}{\mu} \right| - \frac{1}{\mu}, 0 \right\} \cdot \text{sign}(y - H\beta_{k+1} + \frac{\lambda_k}{\mu}) \quad (23)$$

مشاهده می‌شود مدت زمان هر تکرار اساساً صرف حل معکوس $H^T H + \frac{2}{C\mu I}$ می‌شود. خوشبختانه در هر تکرار ماتریس $(H^T H + \frac{2}{C\mu I})^{-1} H^T$ حاصل می‌شود که به‌طور کلی قبل از شروع تکرارها حاصل آن را می‌توان محاسبه کرد که انجام بسیار سریع محاسبات در تکرارها را موجب می‌شود. باید متذکر شد استفاده از یک تکنیک که موجب تغییر μ شود، همگرایی سریع‌تر در تعداد تکرارهای کمتر را ممکن می‌کند [۳۰،۳۱]؛ اگرچه استفاده از چنین تکنیکی به محاسبات مقادیر متفاوتی از ماتریس $(H^T H + \frac{2}{C\mu I})^{-1} H^T$ نیازمند است که به انجام محاسبات بسیاری منجر خواهد شد.

گفتنی است این روش تکراری الزاماً سریع‌ترین روش در دستیابی به دقتی بالا (در زمان استفاده از مجموعه داده‌ای بدون داده‌های خارج از محدوده) نیست؛ اما مسلماً مؤثرترین روش در حصول بالاترین دقت ممکن در زمان

داده‌های مسابقات جهانی GEFCom2014 استخراج شده‌اند؛ اما ماتریس‌های هدف زیرمجموعه داده‌های پیش‌بینی توان خروجی ایستگاه خورشیدی باید محاسبه شوند.

با داشتن ظرفیت ایستگاه خورشیدی $C = 814 \text{ MW}$ ، زاویه شیب $\beta = 45^\circ$ ، $\mu = 0.05$ ، $\tau_{b,e} = 0.2$ و با محاسبه آزمون ایستگاه خورشیدی γ و با استفاده از روابط ۸-۱، خروجی ایستگاه خورشیدی P_t محاسبه می‌شود که در شکل (۲) نمایش داده شده است.



شکل (۴) نمودار کانتور نمرات مجموعه آموزش خورشیدی

محور x در شکل‌های (۳) تا (۵) زمان‌های اندازه‌گیری، محور y ویژگی و محور z مقدار عددی ویژگی‌ها را نمایش می‌دهد. باید توجه داشت در روش پیشنهادی در این مقاله، از داده‌های تقویمی برای آموزش و آزمایش مدل‌های پیش‌بینی توان خروجی ایستگاه خورشیدی استفاده نمی‌شود؛ زیرا در شبیه‌سازی‌های انجام‌شده، حذف داده‌های مذکور کاهش خطای پیش‌بینی را موجب شده است. در نتیجه، ورودی مدل پیش‌بینی خورشیدی در بخش آزمایش، ویژگی‌های چهارم تا هفتم ارائه‌شده در شکل (۵) خواهد بود.



شکل (۲) توان خروجی ایستگاه خورشیدی برای سال‌های ۲۰۰۶-۲۰۰۷

پس از آماده‌شدن داده‌های آموزش، نوبت به اجرای روش تحلیل اجزای اصلی روی ماتریس‌های ورودی مدل‌های آموزش و آزمایش است. شکل‌های (۳) تا (۵) نمودارهای کانتور ماتریس نمرات استخراج‌شده برای مجموعه‌های آموزش و آزمایش را نمایش می‌دهند.



شکل (۵) نمودار کانتور نمرات مجموعه آزمایش

ممکن است در طول فرایند آموزش مدل‌های پیش‌بینی، مدل‌ها به‌جای یادگیری رابطه ورودی‌ها و خروجی مطلوب فقط داده‌ها را حفظ کنند که در این صورت گفته می‌شود overfit رخ داده است و مدل پیش‌بینی قابلیت تعمیم برای داده‌های جدید را نخواهد داشت. به این دلیل، ۲۵٪ از داده‌های آموزش در ابتدا کنار گذاشته شده‌اند تا با استفاده از



شکل (۳) نمودار کانتور نمرات مجموعه آموزش بار

جدول (۱): نتایج آموزش و اعتبارسنجی مدل‌های بار و توان خورشیدی

مدل	بار (آموزش)	بار	توان خورشیدی (آموزش)	توان خورشیدی
MSE	۱۰۷/۷۴	۱۰۶/۱۳	۳۷/۱۹	۳۴/۳۵۳
RMSE	۱۰/۳۸	۱۰/۳۰۲	۶/۰۹۸۴	۵/۸۶۱۱
R ²	۰/۹۴۷۷۸	۰/۹۴۷۲	۰/۹۹۳۸۱	۰/۹۹۴۱۷
MAE[MW]	۷/۴۱۸۵	۷/۳۵۲۵	۲/۹۵۰۲	۲/۸۴۵
MAPE	۵/۰۷۴۸	۵/۰۸۲۷	۴/۷۱۸۴	۴/۵۹۱۲

نتایج جدول‌های (۱) و (۲) نشان می‌دهند روش ORELM خطای کمتری نسبت به روش‌های دیگر ماشین یادگیری شدید ارائه داده است. درصد میانگین مطلق خطا در مرحله اعتبارسنجی در پیش‌بینی بار برای روش اصلی ماشین یادگیری شدید کمتر از دو روش دیگر و برابر با ۵/۱۲۸ است که به میزان ۰/۰۴۵۳ بیشتر از خطای به‌دست‌آمده با استفاده از روش ORELM است. درصد میانگین مطلق خطا در مرحله اعتبارسنجی در پیش‌بینی توان خروجی ایستگاه خورشیدی برای روش WRELM کمتر از دو روش دیگر و برابر با ۵/۵۶۴ است که به میزان ۰/۹۷۲۸ بیشتر از خطای به‌دست‌آمده با استفاده از روش ORELM است.

جدول (۲): نتایج آموزش و اعتبارسنجی مدل‌های مقایسه بار و توان خورشیدی (MAPE)

مدل	مرحله	ELM	RELM	WRELM
بار	آموزش	۵/۱۰۵۸	۵/۱۴۴۴	۵/۲۴۵۸
	اعتبارسنجی	۵/۱۲۸	۵/۱۳۵۴	۵/۱۴۹
توان	آموزش	۶/۰۸۵۳	۵/۹۲۸۲	۵/۸۰۶۷
	اعتبارسنجی	۵/۸۳۹۷	۵/۷۸۶۸	۵/۵۶۴


نتایج پیش‌بینی میان‌مدت بار و توان خروجی ایستگاه خورشیدی در شکل‌های (۸) و (۹) ارائه شده‌اند. جدول (۳)، میانگین مطلق درصد خطای به‌دست‌آمده با استفاده از روش‌های مختلف ماشین یادگیری شدید را نمایش می‌دهد. مقایسه نتایج به‌دست‌آمده با بررسی این جدول امکان‌پذیر است.

آنها میزان خطای مدل‌های پیش‌بینی تعیین شود و به همین دلیل این مرحله اعتبارسنجی نامیده می‌شود. نتیجه آموزش و اعتبارسنجی مدل‌های پیش‌بینی بار و توان خورشید در شکل‌های (۶) و (۷) و جدول (۱) نمایش داده شده است. هریک از شکل‌های (۶) و (۷) شامل دو نمودار است. نمودار سمت چپ آزمایش مدل ساخته‌شده با استفاده از داده‌هایی است که مدل با استفاده از آنها ساخته شده است و نمودار سمت راست حاصل اعتبارسنجی مدل‌ها با استفاده از بخش ۲۵٪ مجموعه اعتبارسنجی است.

نتایج ارائه‌شده در جدول (۱)، عملکرد خوب مدل‌های پیش‌بینی بار و توان خورشیدی را در مراحل آموزش و آزمایش نشان می‌دهند؛ اما بدون مقایسه با روش‌های دیگر نمی‌توان نتیجه‌گیری قطعی ارائه داد؛ از این رو، روش پیشنهادی با استفاده از سه روش دیگر در ماشین یادگیری شدید که عبارت‌اند از روش اصلی ماشین یادگیری شدید^{۱۳} (ELM)، ماشین یادگیری شدید تنظیم‌شده^{۱۴} (RELM) و ماشین یادگیری شدید تنظیم‌شده و وزندار^{۱۵} (WRELM) انجام گرفته است و نتایج آن در جداول (۲) و (۳) ارائه شده‌اند.



شکل (۶): نمودارهای آموزش و اعتبارسنجی مدل بار




شکل (۷): نمودارهای آموزش و اعتبارسنجی مدل توان

خورشیدی

پیش‌بینی شده برای بار با در نظر گرفتن توان تولیدشده با ایستگاه خورشیدی. در این مقاله، پیش‌بینی احتمالاتی عبارت است از پیش‌بینی بار خالص با در نظر گرفتن میزان نفوذ توان تولیدشده با ایستگاه خورشیدی در شبکه برق. نتایج پیش‌بینی بار خالص با در نظر گرفتن چهار مقدار 5% ، 10% ، 15% و 20% برای نفوذ توان خورشیدی در شبکه برق در شکل (۱۰) نمایش داده شده‌اند.


نکته درخور توجه دیگر، مقایسه نتایج پژوهش انجام‌شده در این مقاله با دیگر مقالات است. بازه زمانی هفتم تا چهاردهم فوریه برای پیش‌بینی بار خالص و مقایسه با روش ارائه‌شده در مرجع [۲۰] استفاده شده است و نتایج آن در شکل (۱۱) و جدول (۴) نمایش داده شده‌اند.



شکل (۱۰): نمودار بار خالص با در نظر گرفتن 5% ، 10% ، 15% و 20% نفوذ توان خورشیدی


در نتایج ارائه‌شده، PM روش پیشنهادی در این مقاله و PMC نشان‌دهنده روش ارائه‌شده در مرجع [۲۰] است. همان‌طور که نتایج ارائه‌شده در جدول (۴) و شکل (۱۱)

نتایج نشان می‌دهند در بخش پیش‌بینی میان‌مدت نیز مدل ORELM خطای کمتری در پیش‌بینی نقطه‌ای ارائه داده است. استفاده از مدل مذکور برای بار به ترتیب نسبت به مدل‌های ELM، RELM و WRELM به میزان 0.31% ، 0.696% و 0.171% خطای کمتری ارائه داده است. برای مدل پیش‌بینی توان خورشیدی نیز استفاده از مدل ORELM به ترتیب به میزان 1.3669% ، 1.2098% و 1.0892% میانگین مطلق درصد خطای کمتری ارائه داده است.



شکل (۸): پیش‌بینی میان‌مدت بار با استفاده از مدل ORELM

برای شش ماه اول سال ۲۰۱۱



شکل (۹): پیش‌بینی میان‌مدت توان خورشیدی با استفاده از

مدل ORELM برای شش ماه اول سال ۲۰۱۱

جدول (۳): نتایج پیش‌بینی میان‌مدت مدل‌های بار و توان خورشیدی (MAPE)

مدل	ELM	RELM	WRELM	ORELM
بار	۵/۱۰۵۸	۵/۱۴۴۴	۵/۲۴۵۸	۵/۰۷۴۸
توان خورشیدی	۶/۰۸۵۳	۵/۹۲۸۲	۵/۸۰۶۷	۴/۷۱۸۴

برای پیش‌بینی احتمالاتی بار خالص، میزان نفوذ توان تولیدشده با ایستگاه خورشیدی باید در نظر گرفته شود. پیش‌بینی بار خالص عبارت است از تفاوت مقدار

۴- نتیجه گیری

یکی از مهم ترین مراحل در طراحی سیستم های توزیع انرژی الکتریکی، پیش بینی بار و سیر تغییرات آن است. افزایش میزان نفوذ توان تولید شده با استفاده از انرژی خورشیدی، افزایش عدم قطعیت در شبکه قدرت را موجب می شود؛ زیرا بیشتر ادوات اندازه گیری بار خالص شبکه را بدون در نظر گرفتن خروجی تولیدات پراکنده اندازه گیری می کند.

در این مقاله، روشی ترکیبی برای پیش بینی میان مدت بار خالص در شبکه برق با در نظر گرفتن اثر تولید توان خورشیدی ارائه شده است. به این منظور، ماتریس نمرات داده های ورودی مدل ها با استفاده از روش تحلیل اجزای اصلی محاسبه شد. سپس در مرحله آموزش، مدل ها از طریق ماشین یادگیری شدید ORELM ساخته و ارزیابی شده اند. داده های GEFCom2014 و NERL در این مطالعه استفاده شده و نتایج به دست آمده با مدل های دیگر ماشین یادگیری شدید مقایسه شده اند. به منظور ارزیابی روش پیشنهادی در این مقاله، نتایج شبیه سازی با نتایج به دست آمده با بهره گیری از روش ارائه شده در مرجع [۱۹] مقایسه شده اند.

هدف اصلی روش پیشنهاد شده، افزایش دقت پیش بینی بار خالص از طریق بهبود پیش بینی های نقطه ای است. مقایسه انجام شده بین نتایج ارائه شده در این مقاله با مراجع دیگر نشان می دهد MAPE پیش بینی های بار و توان خروجی ایستگاه خورشیدی به ترتیب به میزان ۱/۱۳۳۳ و ۰/۳۱۱۸ بهبود یافته است که کاهش خطای کلی پیش بینی را سبب می شود.

مراجع


- [1] O. Abedinia, N. Amjady, 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.
- [2] H. Shayeghi, A. Ghasemi, "Modeling of Multi input Multi Output based LSSVM for Electricity Price and Load Forecasting in Smart Grid with Considering Demand Side Management", Computational Intelligence in Electrical Engineering, Vol. 6, No. 4, 2016.

نشان می دهند MAPE پیش بینی های بار و توان خروجی ایستگاه خورشیدی به ترتیب به میزان ۱/۱۳۳۳ و ۰/۳۱۱۸ با استفاده از روش پیشنهادی در این مقاله نسبت به روش ارائه شده در مرجع [۲۰] بهبود یافته اند که باعث کاهش خطای کلی پیش بینی می شوند.

جدول (۴): خطای آزمایش مدل های پیش بینی بار و توان خروجی ایستگاه خورشیدی

مدل	MAE	MAPE	MSE	RMSE	R ²
PM Load	۷/۳۳۶۷	۴/۳۲۶۷	۹۰/۲۱۶	۹/۴۹۸۲	۰/۹۲۱۳۹
PMC Load	۹/۲۵۸۵	۵/۴۶	۱۴۸/۴۳	۱۲/۱۸۳	۰/۸۷۰۶۷
PM Solar	۲/۴۶۶۳	۴/۹۵۲۴	۲۲/۲۴۱	۴/۷۱۶	۰/۹۹۵۷۸
PMC Solar	۲/۶۰۰۳	۵/۲۶۴۲	۲۶/۷۸۷	۵/۱۷۵۶	۰/۹۹۴۲۹

عملکرد روش پیشنهادی در مراحل آموزش، اعتبارسنجی، پیش بینی میان مدت احتمالاتی و در نهایت، در بخش مقایسه خوب بوده است و می توان روش ترکیبی پیشنهاد شده در این مقاله را روشی مناسب و با خطای کم برای پیش بینی احتمالاتی میان مدت بار خالص در شبکه برق در نظر گرفت.



شکل (۱۱) مقایسه پیش بینی بار خالص

- Transactions on Smart Grid, Vol. 10, No. 4, pp. 4425 - 4434, July 2019.
- [15] Z. Yu, Z. Niu, W. Tang, 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, 29 January 2019.
- [16] C. Ye, Y. Ding, P. Wang, Z. Lin, "A Data-Driven Bottom-Up Approach for Spatial and Temporal Electric Load Forecasting", IEEE Transactions on Power Systems, Vol. 34, No. 3, pp. 1966 – 1979, May 2019.
- [17] T. Ouyang, Y. He, H. Li, Z. Sun, S. Baek , "Modeling and Forecasting Short-Term Power Load With Copula Model and Deep Belief Network", IEEE Transactions on Emerging Topics in Computational Intelligence, Vol. 3, No. 2, pp. 127 - 136, April 2019.
- [18] K. Chen, K. Chen, Q. Wang, Z. He, J. Hu, J. He, "Short-Term Load Forecasting With Deep Residual Networks", IEEE Transactions on Smart Grid, Vol. 10, No. 4, pp. 3943 - 3952, July 2019.
- [19] Z. Deng, B. Wang, Y. Xu, T. Xu, C. Liu, Z. Zhu, "Multi-Scale Convolutional Neural Network With Time-Cognition for Multi-Step Short-Term Load Forecasting", IEEE Access, Vol. 7, pp. 88058 – 88071, 01 July 2019.
- [20] Y. Wang, N. Zhang, Q. Chen, D. S. Kirschen, P. Li, Q. Xia, "Data-Driven Probabilistic Net Load Forecasting With High Penetration of Behind-the-Meter PV", IEEE Transactions on Power Systems, Vol. 33, No. 3, pp. 3255 - 3264, May 2018)
- [21] N. Blair, A. Dobos, J. Freeman, T. Neises, M. Wagner, T. Ferguson, P. Gilman, and S. Janzou, "System advisor model, sam 2014.1. 14: General description", NREL Rep. No. TP-6A20-61019, Natl. Renew. Energy Lab. Golden, CO, vol. 13, 2014.
- [22] T. Hong, P. Pinson, S. Fan, H. Zareipour, A. Troccoli, and R. J. Hyndman, "Probabilistic energy forecasting: Global energy forecasting competition 2014 and beyond", International Journal of Forecasting, Vol. 32, No. 3, pp. 896– 913, 2016.
- [23] R. Ross Jr, "Flat-plate photovoltaic array design optimization", in 14th Photovoltaic Specialists Conference, Vol. 1, pp. 1126–1132, 1980.
- [24] 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, 2015.
- [25] N. Blair, A. Dobos, J. Freeman, T. Neises, M. Wagner, T. Ferguson, P. Gilman, and S. Janzou, "System advisor model, sam 2014.1. 14: General description", NREL Rep. No. TP-6A20-61019, Natl. Renew. Energy Lab. Golden, CO, Vol. 13, 2014.
- [26] Gareth, J., Witten, D., Hastie, T., Tibshirani, R., "An Introduction to Statistical Learning: with Application in R", Springer, February 2013.
- [27] K. Zhang, M. Luo, "Outlier-robust extreme learning machine for regression problems", [3] W. M. Lin, C. S. Tu, R. F. Yang, M. T. Tsai, "Particle swarm optimization aided least square support vector machine for load forecast with spikes", IET Generation, Transmission & Distribution., Vol. 10, No. 5, pp- 1145–1153, April 2016.
- [4] H. Jiang, Y. Zhang, E. Muljadi, J. J. Zhang, D. W. Gao, "A Short-Term and High-Resolution Distribution System Load Forecasting Approach Using Support Vector Regression with Hybrid Parameters Optimization", IEEE Transactions on Smart Grid, Vol. 9, No. 4, pp- 3341–3350, July 2018.
- [5] Y. Liu, Y. Sun, D. Infield, Y. Zhao, S. Han, J. Yan, "A hybrid forecasting method for wind power ramp based on orthogonal test and support vector machine (OT-SVM)", IEEE Transactions on Sustainable Energy, Vol. 8, No. 2, pp- 451–457, April 2017.
- [6] Jakub Nowotarski, R. Weron, "Computing electricity spot price prediction intervals using quantile regression and forecast averaging", Springer Computational Statistics Journal", Vol. 30, No. 3, pp- 791-803, September 2015.
- [7] B. Liu, J. Nowotarski, T. Hong, and R. Weron, "Probabilistic Load Forecasting via Quantile Regression Averaging on Sister Forecasts", IEEE Transaction on Smart Grid, Vol. 8, No. 2, pp-730-737, March 2017.
- [8] Q. Liu, Y. Shen, L. Wu, J. Li, L. Zhuang, S. Wang, "A Hybrid FCW-EMD and KF-BA-SVM Based Model for Short-term Load Forecasting", CSEE Journal of Power and Energy Systems, Vol. 4, No. 2, pp- 226–237, June 2018.
- [9] P. Zeng, M. Jin, "Peak load forecasting based on multi-source data and day-to-day topological network", IET Generation, Transmission & Distribution., Vol. 12, No. 6, pp- 1374–1381, March 2018.
- [10] H. Shi , M. Xu, R. Li, "Deep Learning for Household Load Forecasting A Novel Pooling Deep RNN", IEEE Transactions on Smart Grid, Vol. 9 , No. 5, pp. 5271 - 5280, Sept. 2018.
- [11] W. Kong, Z. Y. Dong, Y. Jia, D. J. Hill, Y. Xu, Y. Zhang, "Short-Term Residential Load Forecasting Based on LSTM Recurrent Neural Network", IEEE Transactions on Smart Grid, Vol. 10 , No. 1, pp. 841 - 851, Jan. 2019.
- [12] F. Y. Xu, X. Cun, M. Yan, H. Yuan, Y. Wang, L. L. Lai, "Power Market Load Forecasting on Neural Network with Beneficial Correlated Regularization", IEEE Transactions on Industrial Informatics, Vol. 14, No. 11, pp. 5050 - 5059, Nov. 2018.
- [13] M. Rafiei, T. Niknam, J. Aghaei, M. Shafie-Khah, J. P. S. Catalão, "Probabilistic Load Forecasting Using an Improved Wavelet Neural Network Trained by Generalized Extreme Learning Machine", IEEE Transactions on Smart Grid, Vol. 9, No. 6 , pp. 6961 - 6971, Nov. 2018.
- [14] W. Zhang, H. Quan, D. Srinivasan, "An Improved Quantile Regression Neural Network for Probabilistic Load Forecasting", IEEE

- [31] W. Zuo, D. Meng, L. Zhang, X. Feng, D. Zhang, "A generalized iterated shrinkage algorithm for non-convex sparse coding", in: The IEEE International Conference on Computer Vision (ICCV), pp.217–224, 2013.
- [32] D.L. Donoho, Y. Tsaig, "Fast solution of ℓ_1 -norm minimization problems when the solution maybe sparse", IEEETrans.Inf.Theory 54 4789–4812, 2008.
- [33] M. A. Figueiredo, R. D. Nowak, S. J. Wright, "Gradient projection for sparse reconstruction: application to compressed sensing and other inverse problems", IEEEJ.Sel.Top.SignalProcess.1, pp. 586–597, 2007.
- Elsevier Neurocomputing, Vol. 151, No. 3, pp. 1519-1527, 2015.
- [28] J. Yang, Y. Zhang, "Alternating direction algorithms for ℓ_1 -problems incompressive sensing", SIAMJ.Sci.Comput.33(2011) 250–278.
- [29] L. Zhang, M. Yang, X. Feng, Y. Ma, D. Zhang, "Collaborative representation based classification for face recognition", CoRR(2012), abs/1204.2358.
- [30] Z. Lin, M. Chen, Y. Ma, "The augmented Lagrange multiplier method for exact recovery of corrupted low-rank matrices", arXiv preprint arXiv:1009.5055 2010.

¹ Particle Swarm Optimization

² Grid traverse algorithm

³ Orthogonal test theory

⁴ Bat algorithm

⁵ Day to day topological network

⁶ Random walk with restart algorithm

⁷ Outlier-robust extreme learning machine

⁸ Direct Normal Insolation

⁹ Direct Horizontal Insolation

¹⁰ Sparsity

¹¹ Augmented lagrange multiplier

¹² Iterative

¹³ Extreme Learning Machine

¹⁴ Regularized Extreme Learning Machine

¹⁵ Weighted regularized extreme learning machine

