

پیش بینی کوتاه مدت بار الکتریکی بر پایه شبکه عصبی عمیق و تبدیل موجک و انتخاب ورودی

غلامرضا معمارزاده^۱، دانشجوی دکتری، فرشید کی نیا^۲، استادیار،

۱- دانشکده مهندسی برق و کامپیوتر - دانشگاه تحصیلات تکمیلی صنعتی و فناوری پیشرفته کرمان - ایران -

reza.meamarzadeh@gmail.com

۲- گروه مدیریت و بهینه سازی انرژی، پژوهشگاه علوم و تکنولوژی پیشرفته و علوم محیطی، دانشگاه تحصیلات تکمیلی صنعتی و

فناوری پیشرفته کرمان - ایران - F.keynia@kgut.ac.ir

چکیده: پیش بینی تقاضای الکتریکی یکی از مهمترین عوامل در برنامه ریزی، طراحی و بهره برداری از سیستم های الکتریکی رقابتی است. اما بیش تر روش های پیش بینی بار دارای دقت مناسبی نمی باشند، از این رو در این مقاله جهت افزایش دقت پیش بینی کوتاه مدت بار الکتریکی به ارائه یک روش ترکیبی جهت پیش بینی بار الکتریکی بر پایه شبکه عصبی عمیق با تبدیل موجک و انتخاب ورودی^۱ بر مبنای تابع آنتروپی پرداخته شده است. همچنین برای نشان دادن قدرت روش پیشنهادی، بر روی داده های بار الکتریکی سال ۲۰۰۶ میلادی بازار برق PJM و پست کرمان در سال ۱۳۹۵ پیش بینی صورت پذیرفته است که نتایج آن تأکیدی بر کارایی روش پیشنهادی در پیش بینی بار الکتریکی برای برنامه ریزی تولید و توزیع می باشد.

واژه های کلیدی: پیش بینی بار، شبکه ی عصبی عمیق، تبدیل موجک، انتخاب ورودی، آنتروپی.

تاریخ ارسال مقاله : ۱۳۹۷/۱۰/۱۶

تاریخ پذیرش مقاله : ۱۳۹۸/۰۵/۱۶

نام نویسنده ی مسئول : فرشید کی نیا

نشانی نویسنده ی مسئول : ایران - کرمان - بلوار هفت باغ علوی - دانشگاه تحصیلات تکمیلی صنعتی و فناوری پیشرفته کرمان - پژوهشگاه علوم و تکنولوژی پیشرفته و علوم محیطی.

۱- مقدمه

پیش بینی پارامترهای مهم سیستم قدرت از جمله بار و قیمت یکی از مهمترین مسائل در بهره برداری بهینه از سیستم های قدرت در بازار رقابتی است [۱]. پیش بینی دقیق بار تولید کنندگان الکتریسیته را برای حضور موفق تر در بازار برق کمک می کند. به همین شکل بهره بردار شبکه نیز نیاز به داشتن اطلاعات دقیقی از بار پیش رو جهت بهره برداری دقیق و ایمن از شبکه دارد. علاوه بر این پیش بینی کوتاه مدت بار در مدیریت و بهره برداری از منابع انرژی در ریز شبکه ها نقش بسیار مهمی دارد.

سری زمانی بار به طور معمول رفتار پیچیده ای دارد. از جمله پیچیدگی های نمودار بار روزانه رفتار غیرخطی و متغیر آن است. به دلیل اهمیت پیش بینی بار و پیچیدگی های سری زمانی آن تحقیقات زیادی در سال های اخیر به این موضوع پرداخته اند [۲، ۳]. از جمله این تحقیقات ارائه روش های استاتیکی مختلف برای پیش بینی بار است. به طور مثال روش های پرداخت نمایی^۲ [۴]، فیلترهای کالمن^۳ [۵] و سری های زمانی^۴ [۶] جز روش های استاتیکی هستند. این روش ها به دلیل اینکه قابلیت تفسیر مشخصات فیزیکی اجزا را دارند، بسیار جذاب هستند. اما توانایی تشخیص رفتارهای غیر خطی سیگنال های بار را ندارند. این در حالیست که روش های مبتنی بر هوش مصنوعی مانند شبکه های عصبی مصنوعی^۵، بردار پشتیبان ماشین^۶ و منطق فازی^۷ در این زمینه موفق تر هستند. به خصوص شبکه های عصبی مصنوعی قابلیت بهتری در این گونه مدل سازی دارند. از همین رو توانسته است توجه زیادی را به خود جلب کند [۱۰-۷]. این در حالیست که در بین شبکه های عصبی، شبکه های عصبی عمیق^۸ در زمینه پیش بینی بار بسیار کارا تر هستند [۱۳-۱۱]. این شبکه ها عصبی به صورت قابل ملاحظه ای دقت در پیش بینی پارامترهای مختلف مانند بار الکتریکی، قیمت بازار و انرژی تولیدی نیروگاه بادی دارد. حال اگر بتوان با انتخاب ورودی های مناسب و مؤثر بخش زیادی از داده های غیر مرتبط را حذف کرد قدرت الگوریتم پیش بینی بهتر می گردد. از جمله روش های انتخاب ورودی می توان آنالیز هبستگی^۹ [۱۶-۱۴] و آنالیز حساسیت عددی^{۱۱} [۱۷، ۱۸] را نام برد که همگی جز روش های خطی انتخاب ورودی هستند در حالیکه داده های بار دارای خاصیت غیرخطی هستند. بنابراین روش های انتخاب ورودی مبتنی بر اطلاعات متقابل^{۱۱} (MI) کارایی قابل قبول تری خواهند داشت [۱۹]. این روش فقط به محاسبه میزان شباهت^{۱۲}

داده های ورودی و خروجی می پردازد. برای بهبود عملکرد روش انتخاب ورودی ارائه شده دو روش در مراجع [۲۱-۱۹] ارائه شده اند که به محاسبه میزان شباهت دو ورودی بخصوص با خروجی می پردازند.

در این مقاله یک مدل ترکیبی بر پایه شبکه عصبی عمیق ارائه شده است. دو مسئله بسیار مهمی که همواره در مسائل پیش بینی بار باعث کاهش دقت عملکرد الگوریتم می شود، شامل رفتارهای متغیر سری زمانی بار و داده های غیر مرتبط ورودی با هدف پیش بینی هستند. به همین منظور ابتدا با انتخاب ورودی مناسب از بین داده های نامزد شده با روش میتنی بر آنتروپی، داده های مناسب جهت پیش بینی انتخاب شده اند. سپس برای از بین بردن رفتارهای متغیر سری زمانی بار از تبدیل موجک که یک روش بسیار مناسب جهت انجام این مهم است استفاده شده است [۲۵-۲۲]. در نهایت خروجی های تبدیل موجک به عنوان خروجی شبکه عصبی عمیق استفاده شده است و پیش بینی توسط آن صورت پذیرفته است. روش ارائه شده در این مقاله بر روی داده های بار بازار برق PJM سال ۲۰۰۶ و یک پست برق در استان کرمان در سال ۱۳۹۵ پیاده سازی شده است. قسمت های مختلف ارائه شده در این مقاله به این صورت است که در بخش دوم به توضیح روش انتخاب ورودی پرداخته شده است. در بخش سوم و چهارم به ترتیب تبدیل موجک و شبکه های عصبی عمیق مورد بررسی قرار گرفته است. شبیه سازی، بحث در مورد نتایج و نتیجه گیری در بخش های ۵ و ۶ آمده است.

۲- انتخاب ورودی

در این بخش روش ارائه شده جهت اعمال فیلتر دو مرحله ای ورودی برای انتخاب بهترین ورودیها بیان شده است.

الف) فیلتر مرتبط بودن^{۱۳}: میزان شباهت داده های ورودی و خروجی یک عامل مهم برای انتخاب ورودی است. میزان MI بین خروجی و ورودی یک روش کارا جهت محاسبه این شباهت است. MI بین ورودی و خروجی با $I(x; y)$ نشان داده می شود که بر اساس محاسبه توزیع احتمالی مشترک $P(x, y)$ و توزیع احتمالی مستقل $P(x)$ و $P(y)$ است [۲۱، ۲۶]. فرض کنید که:

$$SC = \{x_1, x_2, \dots, x_M\} \quad (1)$$


مجموعه ای از ورودی ها و خروجی است که بایستی پیش بینی شود. مرتبط بودن خروجی y و با هریک از x_i ها $D(x_i)$ نامیده شده است و برابر است با:

$$D(x_i) = I(x_i, y) \quad (2)$$

ب) فیلتر مشابه بودن^{۱۴}: در بیش تر تحقیقات گذشته مانند [۲۹-۲۷] تمامی اطلاعات مشترک بین دو ورودی برای محاسبه مشابه بودن

۴- شبکه عصبی عمیق

یادگیری عمیق، یک روش یادگیری ماشین است که از شبکه های عصبی عمیق استفاده می کند. همانطور که می دانیم، شبکه عصبی عمیق یک شبکه عصبی چند لایه است که چندین لایه مخفی دارد. شکل ۱ مفهوم یادگیری عمیق و رابطه آن با یادگیری ماشین را نشان می دهد.



شکل (۱): مفهوم یادگیری عمیق و رابطه آن با یادگیری ماشین

با توجه به شکل شبکه عصبی عمیق در جایگاه نهایی یادگیری ماشین قرار دارد وقانون یادگیری، الگوریتمی است که مدل شبکه عصبی عمیق را از داده های آموزش استخراج می کند. زمانی که به کمک قانون یادگیری مناسب و شبکه عصبی عمیق به کمک داده های آموزش مدل را بدست آوردیم سپس برای داده های واقعی از آن استفاده می کنیم. مسیر عمودی در شکل ۱ نشان دهنده فرآیند یادگیری است و شبکه عصبی عمیق نیز، خروجی را با استفاده از ورودی بدست می آورد. ایده ی اولیه شبکه عصبی عمیق مربوط به تقریباً ۳۰ سال پیش است. اما علت اینکه استفاده از آن این مدت زمان طول کشید، یافت نشدن قانون یادگیری مناسب بود. تا اینکه با معرفی الگوریتم پس انتشار این نقیصه تا حدودی رفع شد. برای بهبود یادگیری این شبکه عصبی از تابع واحد یکسوساز شده خطی^{۱۶} (ReLU) به عنوان تابع فعالسازی است. این تابع در انتقال خطا عملکرد بهتری از خود نشان می دهد و به صورت زیر تعریف می شود:

$$\varphi(x) = \begin{cases} x, & x > 0 \\ 0, & x \leq 0 \end{cases} \quad (6)$$

این تابع برای ورودی های منفی، خروجی صفر تولید می کند و برای ورودی های مثبت، ورودی را به خروجی می فرستد. تابع سیگموئید بدون توجه به مقدار ورودی گره، خروجی آن را به ۱ محدود می کند، اما تابع ReLU چنین محدودیتی ندارد. در واقع، این تغییر کوچک منجر به بهبود معناداری در کارایی آموزش شبکه عصبی عمیق می گردد. مشتق تابع ReLU که برای الگوریتم پس انتشار مورد نیاز است به صورت زیر می باشد:

$$\varphi'(x) = \begin{cases} 1, & x > 0 \\ 0, & x \leq 0 \end{cases} \quad (7)$$

پیشنهاد شده است. در مرجع [۲۶] این موضوع مورد بحث قرار گرفته است که زمانی دو ورودی x_i و x_s بسیار شبیه به هم باشند می تواند باعث عملکرد انتخاب ورودی باشد. به عبارت دیگر دو ورودی انتخاب شده ممکن است شباهت بسیار بالایی به هم داشته باشند در حالی که این دو ممکن است با خروجی پیش بینی شباهت کمی داشته باشند. بنابراین آن متغیر با شباهت کم با خروجی بایستی از روند انتخاب ورودی حذف شود. محاسبه مشابه بودن یا همان $RE(x_i, x_s)$ به شکل زیر ارائه شده است:

$$RE(x_i, x_s) = I(x_i, x_s) \quad (3)$$

که در این معادله x_i و x_s دو ورودی انتخاب شده هستند.

۲-۱- الگوریتم انتخاب ورودی

الگوریتم بیان شده در این مقاله برای پیاده سازی انتخاب ورودی به صورت زیر عمل می کند:

۱- ابتدا با استفاده از رابطه (۲) به محاسبه مقدار Relevancy بین کلیه ورودی ها و خروجی پرداخته شده است.

۲- سپس با استفاده از رابطه (۳) اقدام به محاسبه Redundancy بین دو ورودی مورد نظر پرداخته شده است.

۳- سپس با استفاده از رابطه (۴) اقدام به محاسبه متغیر IC می کند.

$$IC = D(x_i) + \alpha \sum_{s=1}^n RE(x_i, x_s) \quad (4)$$

که در این رابطه α یک عدد ثابت است که در این مقاله 0.5 فرض شده است. و همچنین معرف تعداد متغیرهای انتخاب شده اولیه است که در این مقاله 400 است.

۴- حال خروجی IC از مقدار بیشتر به کمتر رتبه بندی می شوند. مقادیر بیشتر از حد آستانه^{۱۵} در نهایت به عنوان متغیر ورودی به مرحله تبدیل موجک در نظر گرفته شده اند.

۳- تبدیل موجک

به طور معمول الگوهای سری زمانی بار الکتریکی دارای ویژگی های غیر خطی و دینامیکی هستند که خود را به صورت نقاط نوک تیز و دارای نوسان نشان می دهند. این نقاط اثر خود را بر روی پیش بینی بار الکتریکی به صورت شدیدی می گذارند. یکی از راه های بسیار مناسب در پیش بینی این نوسانات استفاده از تبدیل موجک است. معمولاً تبدیل موجک گسسته برای بهبود محاسبات ارائه شده است که رابطه آن به صورت زیر است:

$$\text{wavelet}(v, k) = v^{-(v/2)} \sum_{t=-\infty}^{T-1} g(t) \varphi\left[\frac{t - kv}{v}\right] \quad (5)$$

که در این رابطه k متغیر انتقالی، v متغیر مقیاس ساز، $g(t)$ موجی است که بایستی توسط تبدیل موجک گسسته سازی شود، $\varphi(\bullet)$ تابع مادر تبدیل موجک، t فاصله زمانی گسسته و T طول سیگنالی که قصد تجزیه کردن آن را داریم، هستند.

۷- حال ضرایب وزنی مناسب استخراج شده از تخمین گر بر روی داده های آزمایش پیاده سازی گردیده است و با استفاده از دو معیار MAPE و MSE که در روابط ۸ و ۹ توضیح داده شده اند خطای الگوریتم طراحی شده اندازه گیری شده است.

$$MAPE = \frac{1}{N} \sum_{i=1}^N \frac{|S_i^{ACT} - S_i^{FOR}|}{S_i^{ACT}} \quad (8)$$

$$MSE = \frac{1}{N} \sum_{i=1}^N (S_i^{ACT} - S_i^{FOR})^2 \quad (9)$$

که در این روابط S_i^{FOR} و S_i^{ACT} بیانگر مقادیر واقعی و پیش بینی برای ساعت ام هستند. همچنین دارای مقدار ۱۶۸ است. فلوجارت الگوریتم پیشنهاد شده برای پیش بینی داده های بار الکتریکی در شکل ۲ آمده است.

در این مقاله برای ارزیابی عملکرد روش مطرح شده جهت پیش بینی بار داده های بازار برق PJM ۲۰۰۶ و پست برق کرمان به عنوان ورودی الگوریتم ارائه شده در نظر گرفته شده اند.

۵-۱- بازار برق PJM ۲۰۰۶

بازار برق PJM یکی از بزرگترین بازارهای انرژی الکتریکی در جهان است که در آمریکا واقع شده است. در این مقاله از داده های بار الکتریکی این بازار در سال ۲۰۰۶ استفاده شده است. همانطور که گفته شد برای شبیه سازی داده های بار، ۴ هفته انتهایی هر فصل سال به عنوان داده های آزمایش انتخاب شده اند. که این هفته ها در بازار PJM برای فصل های زمستان، بهار، تابستان و پاییز به ترتیب از ۱۵ تا ۲۱ فوریه، ۱۵ تا ۲۱ می، ۱۵ تا ۲۱ آگوست و ۱۵ تا ۲۱ نوامبر هستند. در جدول ۱ نتایج مقادیر MAPE هفتگی برای فصل های سال با روش مطرح شده در این مقاله و سایر روش های مطرح شده در سایر مقالات آورده شده است. همانطور که از نتایج جدول ۱ مشخص است روش ارائه شده در این مقاله از قابلیت بسیار خوبی در پیش بینی بار الکتریکی نسبت به سایر روش های مطرح شده برای این بازار دارد. مقدار MSE برای این داده ها در جدول ۲ آمده است. همانطور که مشاهده می شود الگوریتم طراحی شده برای پیش بینی بار الکتریکی از دقت و قدرت مناسبی در این مهم برخوردار است. بر طبق نتایج مشاهده شده در جدول های قبل بیش ترین مقدار خطای پیش بینی مربوط به هفته آخر فصل تابستان است. با وجود این اما بازهم در این هفته نیز الگوریتم طراحی شده دقت مناسبی جهت پیش بینی دارد. شاهد این ادعا نمودار بار الکتریکی واقعی و پیش بینی شده است. این نمودار در شکل ۳ آمده است. علی رغم اینکه این هفته دارای بدترین خطای پیش بینی است اما منحنی پیش بینی به خوبی داده های واقعی را دنبال کرده است. همچنین برای مشخص نمودن دقت پیش بینی برای سایر فصل های سال از نمودار هماهنگی بار واقعی و پیش بینی شده استفاده شده است.

در این مقاله برای پیش بینی سری زمانی بار از شبکه عصبی عمیق ۵ لایه، شامل یک لایه ورودی و خروجی و سه لایه پنهان استفاده شده است. به علاوه از روش یادگیری مبتنی بر آنتروپی متقاطع جهت بهبود کارایی الگوریتم استفاده شده است.

۵- شبیه سازی و بحث در مورد نتایج


همان گونه که اشاره شد سری زمانی بار الکتریکی دارای الگوهای غیر خطی و دینامیکی زیادی است. همچنین اشاره شد که برای حل این نکته از روش های مختلف استفاده شده است. در این مقاله برای برطرف کردن این الگوهای مشکل زا در امر پیش بینی بار الکتریکی ابتدا اقدام به انتخاب ورودی مناسب بر طبق روش مطرح شده در قسمت دوم شده است و سپس این داده ها به بلوک تبدیل موجک رفته و با استفاده از آن داده های دارای نوسان یکسان در دسته مختص خود قرار می گیرند و در انتها این داده ها ورودی شبکه عصبی عمیق می شوند. یکی از ویژگی های مقاله ارائه شده تکیه بر استفاده از شبکه عصبی عمیق به عنوان رهیافتی مناسب برای پیش بینی بار الکتریکی است. به خصوص آنکه این شبکه ها دارای لایه های زیادتری نسبت به شبکه های عصبی معمولی هستند و این نکته امر پیدا کردن ضرایب وزنی را دچار مشکل می کند، که این مهم با استفاده از قانون یادگیری پس انتشار به خوبی رفع شده است. به علاوه با به کارگیری مناسب از این شبکه مشخص شده است که این شبکه ها بسیار توانمند در امر پیش بینی بار الکتریکی و سایر پارامترهای شبکه هستند.

پس برای پیش بینی بار الکتریکی با استفاده از روش مطرح شده در این مقاله بایستی مراحل زیر گذرانده شود:

- ۱- ابتدا سری زمانی داده های بار موجود را دریافت کرده و سپس این داده ها نرمالیزه می شوند.
- ۲- در این مرحله بایستی داده های آموزش و آزمایش مشخص شوند. به همین منظور ابتدا ۴ فصل سال مشخص می شوند. سپس ۴۰۰ نمونه قبل از آخرین هفته هر فصل به عنوان داده های آموزش و هفته آخر هر فصل به عنوان داده آزمایش در نظر گرفته شده است.
- ۳- ۴۰۰ نمونه آموزش به مرحله انتخاب ورودی وارد و از بین این نمونه ها، آن داده هایی که دارای ارزش بالا در پیش بینی بار هستند انتخاب شده اند.
- ۴- حال داده های خروجی از مرحله انتخاب ورودی به عنوان ورودی به تبدیل موجک وارد شده اند. تبدیل موجک این داده ها را به ۴ سطح مختلف فرکانسی تقسیم کرده است.
- ۵- در این مرحله برای هر کدام از خروجی های تبدیل موجک یک تخمین گر مناسب بر پایه شبکه عصبی عمیق با توجه به مشخصاتی که قبلاً در بخش ۴ توضیح داده شده است طراحی گردیده است.
- ۶- از خروجی هریک از تخمین گر ها تبدیل موجک معکوس گرفته شده است.

جدول ۱: مقادیر MAPE برای داده‌های بازار PJM ۲۰۰۶

فصل	[۲۰] MLP+PCA	[۲۰] MLP+MI	[۲۰] MLP+MRMS	Proposed
زمستان	۱/۶	۱/۳۴	۰/۹۵	۰/۱۷
بهار	۱/۲۹	۱/۲۴	۰/۷۲	۰/۱۹
تابستان	۱/۶۶	۱/۶۳	۰/۸۶	۱/۰۵
پاییز	۱/۵۸	۱/۴۰	۰/۹۰	۰/۴
میانگین	۱/۵۳	۱/۴۰	۰/۸۶	۰/۴۶




شکل (۲): فلوچارت الگوریتم پیشنهاد شده برای پیش بینی بار الکتریکی

جدول ۲: مقادیر MSE ($\times 10^{-5}$) برای داده‌های بازار PJM ۲۰۰۶

فصل	زمستان	بهار	تابستان	پاییز
مقدار MSE	۰/۳۲۲۹	۰/۳۲۵۸	۲۱/۷۲۳	۱/۲۳۷۵


شکل ۴ میزان خطای پیش بینی فصل تابستان بر حسب درصد برای این بازار را نشان می دهد. همان طور که مشخص است مقادیر خطا بسیار اندک است. شکل ۵ بیان کننده میزان هماهنگی مقادیر پیش بینی شده و مقادیر اصلی بار برای تمامی فصل هاست. مشاهده شده است که مقدار R^2 برای کلیه ی فصول کمتر از ۰/۹۹ نیست. این مقدار بیانگر نزدیک بودن مقادیر پیش بینی شده و واقعی است. به

عبارت دیگر می توان ادعا کرد که نتایج پیش بینی و مقادیر واقعی بسیار نزدیک به هم هستند. یعنی الگوریتم ارائه شده به خوبی از عهده پیش بینی بار الکتریکی بازار PJM ۲۰۰۶ بر آمده است.



شکل (۳): مقادیر بار واقعی و پیش بینی شده برای هفته آخر تابستان بازار PJM ۲۰۰۶


میزان خطای پیش بینی فصل تابستان



شکل (۴): میزان خطای پیش بینی فصل تابستان بر حسب درصد بازار برق PJM ۲۰۰۶

۵-۲- یک پست برق کرمان

مورد مطالعاتی دوم که برای پیاده سازی روش مطرح شده در این مقاله استفاده شده است اطلاعات پست برق شماره ۲ کرمان در سال ۱۳۹۵ است. این پست از مصرف کنندگان خانگی، کشاورزی و صنعتی تشکیل شده است. بخش عمده مصرف کنندگان این پست برق مشترکین خانگی و کشاورزی هستند. به دلیل وجود مصرف کنندگان کشاورزی در این پست مقادیر بار الکتریکی تغییرات دارد. این امر در



شکل (۵): مقدار هماهنگی مقادیر پیش‌بینی شده و مقادیر اصلی بار برای تمام فصل‌ها بازار برق PJM ۲۰۰۶

این شکل‌ها بیانگر این نکته است که الگوریتم به خوبی داده‌های واقعی و پیش‌بینی را به خوبی بر روی هم تطبیق داده است.

۶- نتیجه گیری

تاکنون روش‌های مختلف و متنوعی برای پیش‌بینی کوتاه مدت بار الکتریکی ارائه شده است، که هر کدام با استفاده از روش‌ها و تکنیک‌های متنوع به این امر مهم پرداخته‌اند. در این مقاله به ارائه روش ترکیبی جهت پیش‌بینی بار الکتریکی بر پایه شبکه عصبی عمیق با تبدیل موجک و انتخاب ورودی بر مبنای تابع آنتروپی پرداخته شده است. برای نشان دادن کارایی الگوریتم ارائه شده از دو مورد تحقیقاتی که شامل اطلاعات بار الکتریکی بازار برق PJM در سال ۲۰۰۶ و پست برق شماره ۲ کرمان در سال ۱۳۹۵ است، استفاده شده است. که در هر دو مورد ارائه شده این الگوریتم قابلیت خود را در پیش‌بینی بار الکتریکی به خوبی نشان داده است. به علاوه این الگوریتم ارائه شده قابل پیاده سازی برای پیش‌بینی سایر پارامترهای مهم در شبکه قدرت مانند قیمت، تولید انرژی الکتریکی بادی و است.

جدول (۳): مقادیر MAPE برای داده‌های یک پست برق کرمان


میانگین	زمستان	پاییز	تابستان	بهار	فصل
مقدار MAPE	۰/۶۶۹۰	۰/۴۳۳۵	۰/۸۹۱۲	۰/۸۵۵۶	۰/۴۹۵۸

جدول (۴): مقادیر MSE ($\times 10^{-7}$) برای داده‌های یک پست برق کرمان

میانگین	زمستان	پاییز	تابستان	بهار	فصل
MSE	۲۹/۴۱۷	۴/۱۱۰۸	۳۵/۴۳۸	۲۲/۴۰	۲۹/۴۱۷


بر طبق جدول‌های فوق بدترین مقدار پیش‌بینی مربوط به فصل پاییز است. اما با این وجود بار الکتریکی پیش‌بینی شده بار الکتریکی واقعی را به خوبی تعقیب کرده است. این نکته در شکل ۶ به وضوح قابل مشاهده است. به علاوه مقدار خطای پیش‌بینی بر حسب کیلو وات برای این فصل از سال ۱۳۹۵ نیز در شکل ۷ آورده شده است. مشاهده شده است که این خطا بسیار اندک و ناچیز است.

برای نشان دادن برازش دقیق داده‌های واقعی و پیش‌بینی شده بر روی یک خط از نمودار میزان هماهنگی مقادیر پیش‌بینی شده و مقادیر اصلی بار استفاده شده است. شکل ۸ برای کلیه فصول سال ۱۳۹۵ پست برق شماره ۲ کرمان این نمودار را نشان داده است. که




شکل (۶): مقادیر بار واقعی و پیش بینی شده برای هفته آخر پاییز

میزان خطا پیش بینی فصل پاییز



شکل (۷): میزان خطای پیش بینی فصل پاییز بر حسب کیلووات یک پست برق کرمان



شکل (۸): مقدار هماهنگی مقادیر پیش‌بینی شده و مقادیر اصلی بار برای تمام فصل‌ها یک پست برق کرمان

۷- نتیجه

در این مقاله، مشخصات یک مقاله قابل چاپ در مجله کیفیت و بهره‌وری صنعت برق ایران بیان شد. مهمترین مشخصات عبارتند از: ابعاد و حاشیه‌های صفحه، نحوه آماده کردن صفحه اول، بخشهای اصلی مقاله، نحوه شماره‌گذاری‌ها، شکل‌ها، جدول‌ها، فرمول‌ها، منابع، و بالاخره چگونگی نگارش متن مقاله.

نویسندگان محترم مقالات سعی کنند تمام موارد ذکر شده را دقیقاً رعایت کنند، و از همین سند بعنوان الگوی نگارش مقاله خود استفاده کنند.

مراجع

- [۱] حسین شایقی، علی قاسمی، «ارائه سک مدل ترکیبی در پیش‌بینی بار در بازار تجدید ساختار یافته»، نشریه کیفیت و بهره‌وری صنعت برق ایران، جلد ۲، شماره ۳، ۱۹ تا ۲۸، بهار و تابستان ۹۲.
- [2] R. Weron, *Modeling and Forecasting Electricity Loads and Prices: A Statistical Approach*, Wiley Publishing, 2006
- [3] R. Weron, "Electricity price forecast.: A review of the state-of-the-art with a look into the future," *International Journal of Forecasting*, vol. 30, no. 4, pp. 1030–1081, 2014.
- [4] J.W. Taylor, "Short-term load forecasting with exponentially weighted methods", *IEEE Transactions on Power Systems*, vol. 27, no.1, pp. 458–464, 2012.
- [5] D.G. Infield, D.C. Hill, "Optimal smoothing for trend removal in short term electricity demand forecasting", *IEEE Transactions on Power Systems*, vol. 13, no. 3, pp. 1115–1120, 1998.
- [6] S.J. Huang, K.R. Shih, "Short-term load forecasting via ARMA model identification including non-Gaussian process considerations", *IEEE Transactions on Power Systems*, vol. 18, no. 2, pp. 673–679, 2003.

توضیح داده شوند. اگر قبل از نوشتن فرمول این کار انجام نشده است، باید بلافاصله پس از فرمول این توضیحات بیان شوند. مانند:

$$\Pi_X(x) = 1 - \int_0^x \hat{f}(\xi) d\xi \quad (۱)$$

که در آن $\hat{f}$ چگالی تخمینی و Π_X تابع توزیع امکان است. اگر تعداد متغیرها و پارامترها برای تعریف در ادامه متن زیاد است، از فهرست علائم در بخش ضمایم استفاده و یا بصورت فهرست در زیر رابطه تعریف شود.

برای نوشتن روابط ریاضی می‌توان بدون بکارگیری ابزار Equation Editor، از بالانویسی^{۱۷}، زیر نویسی^{۱۸}، و نمادهای یونانی بهره گرفت. این روش بیشتر برای ارجاع به متغیرها در متن مناسب است. مثلاً ما تابع توزیع امکان را در متن توضیحی فرمول (۱) با این شیوه نوشتیم. این روش موجب می‌شود که فاصله سطرها به دلیل استفاده از ابزار فرمول‌نویسی زیاد نشود و تنظیمات صفحه بهم نریزد.

در صورتی که یک رابطه ریاضی طولانی بود و در یک سطر جا نشد، می‌توان آن را در دو یا چند سطر نوشت. در این حالت باید سطرهای دوم به بعد با تورفتگی شروع شوند. همچنین می‌توان شماره آن را نیز در یک سطر مستقل نوشت. فرمول (۲) را ببینید.

$$I(\gamma_1; \lambda) = \int_0^{r_2} F(r, \varphi) dr d\varphi = [\sigma r_2 / (2\mu_0)] \cdot \int_0^\infty \exp(-\lambda |z_j - z_i|) \lambda^{-1} J_1(\lambda r_2) J_0(\lambda r_1) d\lambda \quad (۲)$$

یک فرمول یا عبارت ریاضی حتماً باید بعد از ارجاع آن در متن ظاهر شود. الگوریتم‌های مقاله را نیز همانند عبارات ریاضی شماره‌گذاری کنید و به آنها ارجاع دهید.

- networks", IEEE Transactions on Power Systems, vol. 24, no. 1, pp. 20-27, 2009.
- [24] N. Amjady and F. Keynia, "Short-term load forecasting of power systems by combination of wavelet transform and neuro-evolutionary algorithm," Energy, vol. 34, no. 1, pp. 46-57, 2009.
- [۲۵] فرشته صادقی، ابوالفضل جلیلود، سید هادی حسینی، «ارائه یک روش ترکیبی مبتنی بر تبدیل موجک گسسته برای پیش بینی بار الکتریکی با استفاده از یک مدل دوبعدی»، مجله مهندسی برق دانشگاه تبریز، جلد ۴۵، شماره ۳، ۶۷ تا ۷۸، پاییز ۹۴.
- [26] N. Kwak and C.-H. Choi, "Input feature selection for classification problems," IEEE Transactions on Neural Networks, vol. 13, no. 1, pp. 143-159, 2002.
- [27] P. E. Latham and S. Nirenberg, "Synergy, redundancy, and independence in population codes, revisited," Journal of Neuroscience, vol. 25, no. 21, pp. 5195-5206, 2005.
- [28] H. Peng, F. Long, and C. Ding, "Feature selection based on mutual information: Criteria of max-dependency, max-relevance and min redundancy," IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 27, no. 8, pp. 1226-1238, 2005.
- [29] P.A. Estevez, M. Tesmer, C. A. Perez, and J. M. Zurada, "Normalized mutual information feature selection," IEEE Transactions on Neural Networks, vol. 20, no. 2, pp. 189-201, 2009.
- [7] M. López, S. Valero, C. Senabre, J. Aparicio, A. Gabaldon, "Application of SOM neural networks to short-term load forecasting: the Spanish electricity market case study", Electric Power Systems Research, vol. 91, no. 1, pp. 18-27, 2012.
- [8] Y.M. Wi, S.K. Joo, K.B. Song, "Holiday load forecasting using fuzzy polynomial regression with weather feature selection and adjustment", IEEE Transactions on Power Systems, vol. 27, no. 2, pp. 596-603, 2012.
- [9] S. Fan, L. Chen, "Short-term load forecasting based on an adaptive hybrid method", IEEE Transactions on Power Systems. Vol. 21, no. 1, pp. 392-401, 2006.
- [10] K. Kalaitzakis, G.S. Stavrakakis, E.M. Anagnostakis, "Short-term load forecasting based on artificial neural networks parallel implementation", Electric Power Systems Research, vol. 63, no. 3, pp. 185-196, 2002.
- [11] 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, 2018.
- [12] K. Chen, K. Chen, Q. Wang, Z. He, J. Hu, "Short-term Load Forecasting with Deep Residual Networks", IEEE Transactions on Smart Grid, Doi: 10.1109/TSG.2018.2844307.
- [13] H.Z. Wang, G.Q. Li, G.B. Wang, J.C. Peng, H. Jiang, Y.T. Liu, "Deep learning based ensemble approach for probabilistic wind power forecasting", vol. 188, no. 1, pp. 56-70, 2017.
- [14] S. Fan and L. Chen, "Short-term load forecasting based on an adaptive hybrid method," IEEE Transactions on Power Systems, vol. 21, no. 1, pp. 392-401, 2006.
- [15] M. Rana, I. Koprinska, and A. Khosravi, "Feature selection for interval forecasting of electricity demand time series data," Artificial Neural Network, vol. 4, no. 1, pp. 445-462, 2015.
- [16] S. Kouhi, F. Keynia, and S. N. Ravadanegh, "A new short-term load forecast method based on neuro-evolutionary algorithm and chaotic feature selection," International Journal of Electrical Power & Energy Systems, vol. 62, no. 1, pp. 862-867, 2014.
- [17] M. Shahidehpour, H. Yamin, and Z. Li, *Market Operations in Electric Power Systems*, Wiley Publishing, 2002.
- [18] P. Mandal, A. K. Srivastava, M. Negnevitsky, and J. W. Park, "Sensitivity analysis of neural network parameters to improve the performance of electricity price forecasting," International Journal of Energy Research, vol. 33, no. 1, pp. 38-51, 2009.
- [19] N. Amjady and F. Keynia, "Day-ahead price forecasting of electricity markets by mutual information technique and cascaded neuro-evolutionary algorithm," IEEE Transactions on Power Systems, vol. 24, no. 1, pp. 306-318, Feb. 2009.
- [20] O. Abedinia, N. Amjady, H. Zareipour, "A New Feature Selection Technique for Load and Price Forecast of Electrical Power Systems", IEEE Transactions on Power Systems, vol. 32, no. 1, pp. 62-74, 2017.
- [21] N. Amjady and A. Daraeepour, "Design of input vector for day-ahead price forecasting of electricity markets", Expert Systems with Applications, vol. 36, no. 10, pp. 12281-12294, 2009.
- [22] N. Tai, J. Stenzel, H. Wu, "Techniques of applying wavelet transform into combined model for short-term load forecasting", Electric Power Systems Research, vol. 76, no. 6-7, pp. 525-533, 2006.
- [23] Z.A. Bashir, M.E. El-Hawary, "Applying wavelets to short-term load forecasting using PSO-based neural

زیر نویس ها

- 1 Feature selection
- 2 Exponential smoothing
- 3 Kalman filters
- 4 Time series methods
- 5 Artificial neural network
- 6 Support vector machines
- 7 Fuzzy logic
- 8 Deep neural network
- 9 Correlation analysis
- 10 Numerical sensitivity analysis
- 11 Mutual information
- 12 Relevancy
- 13 Relevancy Filter
- 14 Redundancy Filter
- 15 Threshold
- 16 Rectified Linear Unit