

## پیش‌بینی کوتاه مدت مصرف بار الکتریکی با استفاده از شبکه‌های عصبی عمیق CNN و LSTM

نوع مطالعه: پژوهشی

سینا قصابی<sup>۱</sup>، دانش‌آموخته کارشناسی ارشد، رضا روانمهر<sup>۲</sup>، استادیار

۱- دانشکده مهندسی- گروه مهندسی کامپیوتر- واحد تهران مرکزی- دانشگاه آزاد اسلامی- تهران- ایران

sina.ghassai@gmail.com

۲- دانشکده مهندسی- گروه مهندسی کامپیوتر- واحد تهران مرکزی- دانشگاه آزاد اسلامی- تهران- ایران

r.ravanmehr@iauctb.ac.ir

### چکیده:

امروزه انرژی الکتریسیته یکی از اساسی‌ترین نیازهای جوامع بشری محسوب می‌شود به گونه‌ای که تمام فعالیت‌های صنعتی و بخش زیادی از فعالیت‌های اجتماعی، اقتصادی، کشاورزی و ... با اتکا به این انرژی انجام می‌شود، بنابراین کیفیت و تداوم انرژی الکتریسیته از اهمیت بسزایی برخوردار است. هدف این پژوهش آن است که بر اساس عوامل موثر بر بار الکتریکی که دارای روابط پیچیده غیرخطی هستند و عمدتاً شامل تغییرات آب و هوا و نوسانات دوره‌ای روزانه و هفتگی مصرف می‌باشند به پیش‌بینی تغییرات مصرف بار کوتاه مدت دست یابد. روش پیشنهادی یک شبکه عصبی ترکیبی، با استفاده از یادگیری عمیق می‌باشد که از ترکیب دو معماری CNN و LSTM ایجاد شده است. معماری CNN با توجه به قابلیت آن در استخراج الگوهای موجود در داده و معماری LSTM بر پایه توانایی آن در پیش‌بینی سری‌های زمانی، مورد استفاده قرار گرفته‌اند. رویکرد ارائه شده با استفاده از پیش‌بینی آب و هوای ساعات آینده و الگوی مصرف بار الکتریکی در ساعات گذشته، قادر به پیش‌بینی الگوی مصرف آینده خواهد بود. نتایج ارزیابی نشان می‌دهد که دقت پیش‌بینی بر اساس معیارهای MAPE، RMSE، RSE و CORR در مقایسه با بهترین روش‌های موجود بهبود یافته است.

**واژه‌های کلیدی:** پیش‌بینی کوتاه مدت، مصرف بار الکتریکی، شبکه‌های عصبی پیچشی، شبکه‌های عصبی حافظه طولانی کوتاه-مدت، یادگیری عمیق

تاریخ ارسال مقاله : ۱۳۹۹/۰۴/۱۲

تاریخ پذیرش مقاله : ۱۳۹۹/۰۹/۰۸

نام نویسنده‌ی مسئول : رضا روانمهر

نشانی نویسنده‌ی مسئول : گروه مهندسی کامپیوتر- واحد تهران مرکزی- دانشگاه آزاد اسلامی- تهران- ایران

## ۱- مقدمه

صنعت برق از نقشی حساس و زیربنایی در رشد و پیشرفت جوامع امروزی برخوردار است. با توجه به اینکه از یک طرف پروژه های صنعت برق زمان بر و نیاز به سرمایه گذاری کلان دارد و از طرف دیگر با تکنولوژی موجود هنوز امکان ذخیره سازی این انرژی ارزشمند در ابعاد بزرگ وجود ندارد، بنابراین برنامه ریزی تولید باید به گونه ای صورت گیرد که پاسخگوی تقاضای متغیر انرژی الکتریکی باشد. در این راستا پیش بینی مصرف بار الکتریکی به عنوان عاملی مهم در طرح توسعه و بهره برداری از سیستم های قدرت تلقی شده و در واقع شاخصی است که به کمک آن می توان بهینه سازی روند تخصیص منابع برای توسعه و استفاده مناسب از شبکه برق رسانی را امکان پذیر نمود.

در توسعه زیرساخت های سیستم تولید و توزیع الکتریسیته میزان خطای پیش بینی مصرف بار الکتریکی از اهمیت زیادی برخوردار است. اگر میزان بار پیش بینی شده کمتر از بار واقعی باشد ضریب اطمینان و در نتیجه کیفیت خدمات کاهش می یابد و این امر ممکن است حتی به خاموشی های اجباری بینجامد. از طرف دیگر اگر میزان بار آینده بیش از مقدار مورد نیاز پیش بینی شود سرمایه گذاری زیادی به هدر می رود. پیش بینی دقیق بار منجر به رضایت مندی مصرف کنندگان، صرفه جویی انرژی و افزایش ضریب کیفیت خدمات شده و همواره برای برنامه ریزی و تصمیم های عملیاتی، توسط سیستم تولید و توزیع الکتریسیته امری ضروری بوده است. با توجه به نوسانات عرضه و تقاضا، تغییرات وضعیت آب و هوا و افزایش هزینه انرژی در زمان های پر مصرف، پیش بینی بار برای شرکت های برق امری ضروری و حیاتی است.

یکی از مسائل مهم و اساسی در طراحی و بهره برداری سیستم های تولید و توزیع قدرت، پیش بینی بار برای یک ساعت تا چند روز آینده است که تحت عنوان پیش بینی کوتاه مدت بار شناخته می شود. در واقع پیش بینی بار با توجه به فاصله زمانی پیش بینی شده در سیستم های مدیریت انرژی به چهار نوع [۱]: (۱) پیش بینی بار بسیار کوتاه مدت<sup>۱</sup> (VSTLF): پیش بینی بار برای چند دقیقه (۲) پیش بینی بار کوتاه مدت<sup>۲</sup> (STLF): پیش بینی بار از ۲۴ ساعت تا یک هفته، (۳) پیش بینی بار متوسط مدت<sup>۳</sup> (MTLF): پیش بینی بار بیش از یک هفته تا چند ماه و (۴) پیش بینی بار دراز مدت<sup>۴</sup> (LTLF): پیش بینی بار بیش از یک سال طبقه بندی می شود. تمرکز ما در این مقاله بر روی پیش بینی بار کوتاه مدت است. پیش بینی کوتاه مدت بار در تخمین جریان بار و در تصمیم گیری هایی که منجر به جلوگیری از بالا رفتن بیش از حد مصرف بار می شود کمک می کند، همچنین در به فعال سازی به هنگام مدارها و مراکز دیسپاچینگ کاربرد دارد. اجرای به موقع این تصمیم ها سبب بهبود اطمینان به شبکه، کاهش خرابی های تجهیزات و خاموشی ها می شود. STLF برای کنترل و برنامه ریزی سیستم قدرت در فراهم سازی الکتریسیته مورد نیاز روزمره، ارزیابی مراکز تبادل، ارزیابی امنیت، تحلیل

اطمینان و محاسبه قیمت های واقعی ضروری است [۲، ۳] که منجر به نیاز به دقت بالاتر نسبت به پیش بینی طولانی مدت می شود.

روش های گوناگونی برای پیش بینی مصرف بار الکتریکی با استفاده از تکنیک های آماری [۴، ۵]، تجزیه و تحلیل سری های زمانی [۶، ۷]، مدل های فراابتکاری [۸، ۹، ۱۰] و یادگیری ماشین [۱۱، ۱۲، ۱۳، ۱۴] پیشنهاد شده است اما با توجه به نیاز برای پیش بینی دقیق تر به مدل های پیش بینی مصرف بار کارآمدتری نیاز است [۱۵]. اخیراً جوامع پژوهشی در فیلدهای مختلف جذب شبکه های یادگیری عمیق شده اند. این شبکه ها بر پایه شبکه های عصبی مصنوعی به همراه معماری عمیق هستند که توانایی دریافت و تحلیل رفتار داده ها در زمانی که از الگوهای غیرخطی پیچیده تبعیت می کنند و نیز حجم زیادی دارند را دارا می باشند [۱۶].

یادگیری عمیق منجر به پیشرفت چشمگیر رویکردهای مرتبط با پیش بینی کوتاه مدت مصرف بار الکتریکی شده است. این شبکه ها فرصت های پژوهشی نوآورانه بیشتری که باعث افزایش دقت پیش بینی می شوند به وجود آورده اند. در همین راستا، مطالعات گوناگونی بر اساس به کارگیری مدل های مختلف یادگیری عمیق برای پیش بینی کوتاه مدت مصرف بار از قبیل مدل فیوژن عمیق<sup>۵</sup> [۱۷]، شبکه عصبی پیچشی مکرر آغازین<sup>۶</sup> [۱۸]، هسته آنالیز مؤلفه اصلی<sup>۷</sup> و شبکه عصبی پیچشی پیشرفته<sup>۸</sup> [۱۹]، شبکه عصبی خود مختار با متغیرهای برونزا<sup>۹</sup> [۲۰] و شبکه عصبی عمیق با پرسپترون چند لایه<sup>۱۰</sup> (MLP) [۲۱] انجام شده است.

تمرکز اکثر پژوهش های صورت گرفته در حوزه پیش بینی کوتاه مدت مصرف بار الکتریکی بر روی پیش بینی مصرف بار الکتریکی تا حداکثر ۲۴ ساعت آینده بوده است [۲، ۲۳، ۲۴، ۲۵، ۲۶، ۲۷، ۲۸، ۲۹، ۳۰، ۳۱، ۳۲، ۳۵] و در صورتی که پیش بینی بلند مدت تری تا یک هفته ارائه کرده باشند دقت آن تا حد زیادی کاهش یافته است. در ضمن معماری های پیشنهاد شده برای پیش بینی کوتاه مدت مصرف بار الکتریکی عوامل پنهان تاثیرگذار دیگری نظیر وضعیت آب و هوا را دخیل نکرده اند. با توجه به این مسائل، پژوهش های صورت گرفته نمی توانند تمام نیازمندی های محیط عملیاتی پیش بینی کوتاه مدت مصرف بار الکتریکی را به طور کامل برآورده سازند.

در این پژوهش به دنبال آن هستیم که با توجه به عوامل موثر بر مصرف بار الکتریکی از قبیل آب و هوا، تغییرات دوره ای مصرف روزانه و هفتگی، که دارای روابط پیچیده غیرخطی هستند به پیش بینی تغییرات مصرف بار کوتاه مدت دست یابیم، بدین منظور از یکی از کارآمدترین معماری های یادگیری عمیق، شبکه عصبی پیچشی<sup>۱۱</sup> (CNN) استفاده خواهیم کرد. این نوع از شبکه های عصبی دارای قابلیت استخراج الگو<sup>۱۲</sup> از داده های ورودی در زمان یادگیری هستند که با استفاده از آن می توان الگوهای گذشته مصرف بار الکتریکی در فصل ها و روزهای مختلف آن را شناسایی کرد. نوعی دیگر از معماری شبکه های عصبی عمیق، شبکه عصبی حافظه طولانی کوتاه مدت<sup>۱۳</sup> (LSTM) از مدل های زیرمجموعه

اقتصادی و اقلیمی مانند دما، رطوبت، سرعت باد و زمان بر منحنی مصرف بار تأثیر می گذارد. با توجه به متغیر بودن مصرف بار الکتریکی، شرکت های تولید و توزیع کننده برق، موظف هستند با پیش بینی آن در زمان های گوناگون، اطلاعات مورد نیاز برای تصمیم گیری های درست و به موقع خود در سیستم تولید و توزیع برق فراهم نمایند.

## ۲-۲- شبکه های عصبی پیچشی

شبکه های عصبی پیچشی شباهت زیادی به شبکه های عصبی مصنوعی دارند و عموماً از گونه ای از پرسپترون های چندلایه به منظور کمینه کردن بیش پردازش ها استفاده می کنند. این نوع شبکه ها متشکل از نرون هایی با وزن ها و بایاس های قابل یادگیری (تنظیم) هستند. هر نرون تعدادی ورودی دریافت کرده و سپس حاصل ضرب وزن ها در ورودی ها را محاسبه کرده و در انتها با استفاده از یک تابع تبدیل (فعال سازی) غیر خطی نتیجه را ارائه می دهد [۳۴]. این نوع شبکه ها معمولاً یک تابع هزینه<sup>۱۶</sup> (مانند SVM یا Softmax) در لایه آخر (تماماً متصل<sup>۱۸</sup>) دارند و تمامی نکات طراحی در مورد شبکه های عصبی معمولی در اینجا هم صادق است. CNN ها معمولاً متشکل از لایه های کانولوشن، لایه های pooling و لایه تماماً مرتبط هستند. هدف عملیات کانولوشن استخراج الگوهای موجود در داده های ورودی است و با افزایش تعداد لایه ها شبکه قادر به استخراج الگوهای پیچیده تر بر اساس الگوهای قبلی می باشد. به طور کلی ویژگی های استخراج شده از لایه کانولوشن دارای ابعاد زیادی هستند که تعداد آنها با استفاده از لایه pooling کاهش داده می شوند، در نهایت لایه تماماً متصل تمامی ویژگی های محلی را با یکدیگر ترکیب کرده و ویژگی نهایی را به عنوان خروجی تولید می کند [۳۴].

ورودی لایه کانولوشن معمولاً به صورت سه بعدی است که شامل طول، عرض و تعداد کانال ها است. در لایه اول، ورودی ها با مجموعه ای از فیلترهای سه بعدی ترکیب می شوند و نگاشت ویژگی های خروجی را تولید می کنند. برای به دست آوردن نگاشت ویژگی های لایه اول از ورودی تک بعدی  $x = (x_t)_{t=0}^{N-1}$  با اندازه  $N$ ، ترکیب فیلترهای  $w_h^1$  که در آن  $h = 1, \dots, M_1$  با ورودی ها رابطه زیر را خواهیم داشت:

$$a^1(i, h) = (w_h^1 * x)(i) = \sum_{j=-\infty}^{\infty} w_h^1(j) x(i-j) \quad (1)$$

که در آن  $a^1 \in \mathbf{R}^{1 \times N-k+1 \times M_1}$  و  $w_h^1 \in \mathbf{R}^{1 \times k \times 1}$  است. مشابه شبکه های عصبی پیشرو<sup>۱۹</sup>، این خروجی از تابع غیر خطی  $h(\cdot)$  عبور می کند تا خروجی  $f^1 = h(a^1)$  را تولید کند. برای هر لایه بعدی  $l = 2, \dots, L$  از شبکه نگاشت، ویژگی های  $f^{l-1} \in \mathbf{R}^{1 \times N_{l-1} \times M_{l-1}}$  با اندازه  $1 \times N_{l-1} \times M_{l-1}$  با خروجی فیلتر کانولوشن قبلی ترکیب شده و نگاشت ویژگی های  $a^l \in \mathbf{R}^{1 \times N_l \times M_l}$  را تولید می کنند:

$$a^l(i, h) = (w_h^l * f^{l-1})(i) = \sum_{j=-\infty}^{\infty} \sum_{m=1}^{M_{l-1}} w_h^l(j, m) f^{l-1}(i-j, m) \quad (2)$$

شبکه های عصبی مکرر<sup>۱۴</sup> (RNN) است، معماری این شبکه به گونه ای است که دسترسی به تمامی مقادیر گذشته در سری های زمانی را مقدور می سازد. با توجه به این قابلیت، می توان الگوهای استخراج شده از CNN را به همراه شرایط آب و هوای پیش بینی شده برای ساعات آینده (یا برخی اطلاعات تأثیرگذار دیگر مانند تاریخ فعلی) به عنوان ورودی به شبکه LSTM داده و پیش بینی کوتاه مدت مصرف بار را بدست آورد. نوآوری های این پژوهش در موارد زیر خلاصه می شوند:

- ترکیب شبکه عصبی پیچشی و شبکه عصبی حافظه طولانی کوتاه مدت با رویکرد یادگیری عمیق برای پیش بینی کوتاه مدت مصرف بار الکتریکی،
- استفاده از شرایط آب و هوایی (پوشش ابری، رطوبت، سرعت باد، دمای واقعی، دمای حس شده) جهت بهبود شناسایی الگوهای مصرف بار الکتریکی،
- توانایی پیش بینی مصرف بار الکتریکی تا ۱۶۸ ساعت آینده، بیشتر روش های پیش بینی کوتاه مدت بار الکتریکی پیش بینی مصرف بار تا ۲۴ ساعت آینده انجام می دهند.

این مقاله شامل ۶ بخش است، پس از بخش مقدمه مبانی تحقیق می آید که مفاهیم بنیادی در شبکه های عصبی عمیق و مدل های بکار رفته از آن در این تحقیق و همچنین مفاهیم مربوط به سری های زمانی و پیش بینی مصرف بار الکتریکی را شرح می دهد. در بخش پیشینه تحقیق به بررسی پژوهش های صورت گرفته در پیش بینی کوتاه مدت مصرف بار الکتریکی، پرداخته می شود. فصل ۴ به ارائه روش پیشنهادی،<sup>۱۵</sup> CLSMNet، که رویکردی برای پیش بینی کوتاه مدت مصرف بار الکتریکی است، می پردازد. بخش پیاده سازی و ارزیابی نتایج حاصل از CLSMNet را ارائه می کند و به مقایسه روش پیشنهاد شده با برخی دیگر از روش های جدید پیش بینی کوتاه مدت مصرف بار الکتریکی می پردازد. فصل آخر شامل نتیجه گیری و کارهای آینده جهت بهبود روش پیشنهادی است.

## ۲- مبانی پژوهش

در این بخش به بررسی و شناسایی برخی از مفاهیم در الگوی مصرف بار الکتریکی، شبکه های عصبی پیچشی، شبکه های عصبی مکرر و شبکه های عصبی حافظه طولانی کوتاه مدت پرداخته می شود. لازم به ذکر است که موارد یاد شده بلاک های سازنده روش پیشنهادی می باشند و به همین دلیل مروری مختصر بر آنها در این بخش می تواند مفید باشد.

### ۲-۱- الگوی مصرف بار و عوامل مؤثر بر آن

مجموع بار تمامی مصرف کننده ها به اضافه تلفات شبکه، کل بار سیستم را تشکیل می دهد. منحنی مصرف بار برای مصرف کننده ها تا حدودی تصادفی و غیر خطی بوده و به درستی قابل پیش بینی نیست اما با وجود همه این شرایط عموماً مصرف کننده ها یک روند و الگوی کلی ارائه می دهند که می توان آن را با روش های آماری پیش بینی کرد. عوامل

### ۲-۳- شبکه‌های عصبی مکرر

شبکه‌های عصبی مکرر کلاسی از شبکه‌های عصبی عمیق هستند که به صورت یک گراف جهت‌دار چرخه‌ای<sup>۲۰</sup> بیان می‌شوند. به عبارت دیگر ورودی یا خروجی هریک از لایه‌های (های) پنهان علاوه بر خروجی لایه قبل، شامل ورودی از مرحله قبل به صورت بازخورد نیز می‌شود. بر خلاف ارتباطات وزن‌دار ایجاد شده بین لایه‌های شبکه عصبی ساده، RNNها قادر به استفاده از وضعیت داخلی (حافظه) برای پردازش سری ورودی هستند. وضعیت مخفی اطلاعات مربوط به گام زمانی قبلی را ذخیره کرده و خروجی با توجه به زمان فعلی و حافظه گذشته بدست می‌آید [۲۲].

در RNN، نگاشت ورودی  $X_t$ ، گره حافظه  $S_t$  و خروجی  $O_t$  می‌تواند به صورت زیر نمایش داده شود:

$$S_t = f(U \times X_t + W \times S_{t-1}) \quad (۳)$$

$$O_t = g(V \times S_t) \quad (۴)$$

در روابط فوق  $U$ ،  $W$  و  $V$  ماتریس وزن در هر لایه هستند و  $f(\cdot)$  و  $g(\cdot)$  نیز توابع غیرخطی را نشان می‌دهند.

متاسفانه RNNها در طول زمان‌های یادگیری طولانی با مشکلات انفجار گرادیان<sup>۲۱</sup> و یا محو شدن گرادیان<sup>۲۲</sup> مواجه هستند [۲۲]. برای رفع این مشکلات از شبکه‌های عصبی حافظه طولانی کوتاه-مدت که نوع خاصی از شبکه‌های عصبی مکرر هستند و توانایی یادگیری وابستگی‌های بلند مدت را دارند می‌توان استفاده کرد.

### ۲-۴- شبکه‌های عصبی حافظه طولانی کوتاه-مدت

این شبکه برای اولین بار توسط Hochreiter و Schmidhuber در سال ۱۹۹۷ ارائه شد [۳۶]. حضور شبکه‌های عصبی حافظه طولانی کوتاه-مدت (LSTM) در سال‌های اخیر بسیار پر رنگ شده است [۲۲]. در حقیقت هدف از طراحی شبکه‌های LSTM، حل مشکل وابستگی بلند مدت بود. به یادسپاری اطلاعات برای بازه‌های زمانی بلند مدت، رفتار پیش‌فرض و عادی شبکه‌های LSTM است و ساختار آن‌ها به صورتی است که اطلاعات بسیار دور (از لحاظ زمانی) را به خوبی می‌آموزند. تمام شبکه‌های عصبی مکرر توالی‌های تکرار شونده از ماجول‌های (واحدهای) شبکه‌های عصبی هستند. در شبکه‌های عصبی مکرر ساده، این ماجول‌های تکرار شونده دارای ساختار ساده‌ای هستند. شبکه‌های LSTM نیز دارای چنین ساختار دنباله یا زنجیره مانند هستند اما ماجول تکرار شونده دارای ساختار پیچیده‌تری است. عنصر اصلی LSTM، وضعیت سلول<sup>۲۳</sup> است که LSTM را قادر به حذف یا اضافه کردن اطلاعات جدید به وضعیت سلول می‌کند. این عمل توسط ساختارهای دقیقی با نام دروازه<sup>۲۴</sup> صورت می‌گیرد که مسیری برای ورود اختیاری اطلاعات هستند [۲۲].

در یک شبکه LSTM، ورودی  $X_t$  در زمان  $t$  به صورت انتخابی در سلول  $C_t$  ذخیره می‌شود که این سلول توسط دروازه ورودی تعیین می‌شود. وضعیت آخرین لحظه سلول  $C_{t-1}$  به صورت انتخابی توسط دروازه فراموشی<sup>۲۵</sup> فراموش می‌شود. سرانجام، دروازه خروجی کنترل می‌کند که چه بخشی از سلول  $C_t$  به خروجی  $h_t$  اضافه شود. حال اگر  $I_t$  را به عنوان دروازه ورودی و  $F_t$  را به عنوان دروازه فراموشی در نظر بگیریم، آنگاه مقدار به روز شده دروازه وضعیت سلول  $C_t$  خواهد بود:

$$C_t = F_t \times C_{t-1} + I_t \times (\tanh(W_c \times [O_{t-1}, X_t] + b_c)) \quad (۵)$$

که در آن:

$$I_t = \sigma(W_i \times [O_{t-1}, X_t] + b_i) \quad (۶)$$

$$F_t = \sigma(W_f \times [O_{t-1}, X_t] + b_f)$$

در معادلات فوق  $W_i$ ،  $W_f$  و  $W_c$  ماتریس وزنی هستند،  $O_{t-1}$  خروجی سلول قبلی است،  $X_t$  ورودی و  $b_i$ ،  $b_f$  و  $b_c$  نیز بردارهای بایاس هستند.

خروجی نهایی  $O_t$  به صورت زیر بیان می‌شود:

$$O_t = \sigma_t \times \tanh(C_t) \quad (۷)$$

### ۳- پیشینه پژوهش

در این بخش به بررسی پژوهش‌های صورت گرفته در راستای پیش‌بینی کوتاه مدت مصرف بار الکتریکی پرداخته خواهد شد. با توجه به اینکه رویکرد پیشنهادی در این مقاله بر اساس CNN و LSTM است (که هر دو از مدل‌های یادگیری عمیق می‌باشند)، بررسی پیشینه تحقیق به روش‌های مبتنی بر CNN، روش‌های مبتنی بر LSTM و روش‌های ترکیبی تقسیم شده است.

#### ۳-۱- روش‌های مبتنی بر CNN

در مقاله [۳۷] برای پیش‌بینی کوتاه مدت مصرف بار، مقادیری از اطلاعات پیشین آن به CNN داده می‌شود و با توجه به اینکه این اطلاعات از نوع سری زمانی هستند، کانولوشن یک بعدی روی آن‌ها اعمال شده و خروجی عملیات کانولوشن به تابع فعال‌سازی داده شده است. در نهایت خروجی تابع فعال‌سازی از یک لایه Max Pooling برای کاهش اطلاعات موجود در نگاشت ویژگی‌ها گذرانده می‌شود.

روش پیش‌بینی کوتاه مدت مصرف بار مبتنی بر CNN با استفاده از تاریخچه بار ورودی، زمان استفاده و قیمت الکتریسیته توسط شن و همکاران برای تولید بردارهای ویژگی ارائه شده است [۳۳]. سپس یک شبکه چند لایه<sup>۲۶</sup> GRU و BPN<sup>۲۷</sup> سنتی برای پیش‌بینی بار به کار گرفته شده است.

حافظ و همکاران چارچوبی جهت پیش‌بینی کوتاه مدت مصرف بار الکتریکی مبتنی بر دو مدل استخراج شده از ماشین بولتزمن محدود

ارائه شده با برخی از روش های متداول پیش بینی سری های زمانی مانند ARIMA<sup>۳۳</sup> مقایسه شده است.

محققان در مقاله [۲۱] روشی مبتنی بر رمزگذارهای خودکار انباشته<sup>۳۴</sup> و شبکه عصبی GRU جهت پیش بینی کوتاه مدت مصرف بار الکتریکی ارائه داده اند. شبکه پیشنهادی به سه بخش لایه SAE، لایه GRU و لایه خروجی تقسیم شده است. در لایه SAE ابتدا داده های ورودی به شبکه فشرده شده و سپس جهت آموزش به لایه GRU داده می شوند و در نهایت مصرف بار پیش بینی شده تولید می شود.

وانگ و همکاران یک روش پیش بینی برای مصرف انرژی دوره ای بر اساس LSTM ارائه داده اند [۴۱]. حالت تناوبی رویکرد مورد نظر یک تغییر نوسانی در سری های زمانی مربوط به یک روند طولانی مدت است.

### ۳-۳- روش های ترکیبی

یک چارچوب یادگیری عمیق، LSTNet، توسط لای و همکاران ارائه شده است که برای استخراج الگوهای وابستگی محلی کوتاه مدت در میان متغیرها و نیز کشف الگوهای بلند مدت برای روند سری زمانی از یک شبکه ترکیبی بهره می گیرد [۲۸]. LSTNet از ترکیب CNN و LSTM برای به کارگیری نقاط قوت هر دو استفاده می کند، لایه کانولوشن برای استخراج الگوهای محلی وابسته از متغیرهای ورودی چند بعدی و لایه LSTM برای دستیابی به وابستگی های بلند مدت پیچیده.

محققان در مقاله [۲۹] مدلی متشکل از سه لایه موازی کانولوشن یک بعدی را پیشنهاد داده اند. استفاده از کامپوننت های CNN به صورت موازی که هر کدام دارای فیلترهایی با اندازه های متفاوت هستند، توانایی استخراج الگوهای غنی تر را به شبکه می دهد. سپس، تنوع و پویایی در بار الکتریکی گذشته توسط مؤلفه عصبی مکرر مبتنی بر LSTM مدل شده تا بار پیش بینی شده آینده حاصل شود.

دونگ و همکاران نشان دادند که از ترکیب CNN با خوشه بندی K-means می توان برای پیش بینی بار کوتاه مدت که منجر به بهبود مقیاس پذیری نیز می شود، استفاده کرد [۴۲]. خوشه بندی K-means برای تقسیم مجموعه داده ها به زیر مجموعه های آموزش و آزمایش اعمال می شود و سپس شبکه CNN با به کارگیری این زیر مجموعه ها برای ساخت مدل پیش بینی آموزش داده می شود.

گوپتا و همکاران رویکرد سری زمانی دوگانه را انتخاب کرده اند، یکی برای رویکرد پارامتری و دیگری برای غیرپارامتری [۴۳]. برای رویکرد پارامتری، از رگرسیون XGBoost<sup>۳۵</sup> استفاده کرده اند که مبتنی بر GBDT<sup>۳۶</sup> است. برای رویکرد غیرپارامتری نیز شبکه LSTM در نظر گرفته شده است تا وابستگی های طولانی مدت بین داده های فعلی و قبلی را تدوین کند.

جهت پیش بینی دقیق تر مصرف بار الکتریکی رویکردی بر اساس ماشین های یادگیرنده مکرر مفرد<sup>۳۷</sup> توسط ارتوگروپ پیشنهاد شده است [۲]. ELM یک رویه یادگیری خاص برای شبکه عصبی تک لایه پنهان پیش خور<sup>۳۸</sup> است.

یعنی CRBM<sup>۳۸</sup> و CRBM<sup>۳۹</sup> ارائه داده اند [۳۸]. CRBM یک مدل احتمالی برای مدل سازی فعالیت انسان ها، داده های آب و هوایی و دسته بندی داده های سری های زمانی است. در FCRBM، که مدلی تعمیم یافته از CRBM است، فاکتورهایی جهت شبیه سازی فعالیت های متعدد انسان اضافه شده است.

با استفاده از مدل CNN برای استخراج الگوهای موجود در مصرف بار، روشی جهت پیش بینی کوتاه مدت مصرف بار الکتریکی توسط تیان و همکاران ارائه شده است [۳۵]. روش ارائه شده از توانایی شبکه های CNN در استخراج الگوهای موجود در داده و قدرت شبکه های LSTM در شناسایی ارتباط میان گام های زمانی، جهت پیش بینی کوتاه مدت مصرف بار الکتریکی استفاده کرده است.

بینکوفسکی و همکاران یک مدل مبتنی بر CNN با نام SO-CNN را پیشنهاد می کنند که گسترش شبکه پیچشی از مدل های خودهمبسته<sup>۴۰</sup> استاندارد است و از یک مکانیزم وزن گذاری غیرخطی استفاده می کند [۲۳]. در واقع در این مدل، وزنها با آموزش آنها از طریق CNN، مجاز هستند که وابسته به داده ها باشند.

### ۳-۲- روش های مبتنی بر LSTM

ژانگ و همکاران روشی برای بهبود پیش بینی کوتاه مدت مصرف بار با نام سری های زمانی چندگانه پیشنهاد داده اند که ترکیبی از اطلاعات کلان و خرد سری های زمانی پیوسته و گسسته است [۲۴]. سپس، شبکه های LSTM و GRU طراحی شده اند که می توانند اطلاعات سری های زمانی پیوسته و گسسته را آموخته و عملیات پیش بینی بار را انجام دهند.

پژوهشگران در مقاله [۲۵] به بررسی عملکرد روش های یادگیری عمیق با استفاده از شبکه های عصبی RNN در پیش بینی کوتاه مدت مصرف بار می پردازند. محققین برای انجام بررسی های خود از معماری شبکه عصبی مکرر استفاده کرده اند که در دو حالت عمیق و کم عمق استفاده شده است.

کینگ و همکاران استفاده از شبکه LSTM را برای مشکل SLTF پیشنهاد کردند [۲۶]. در ابتدا، یک مدل خوشه بندی مبتنی بر تراکم برای ارزیابی ناسازگاریهای موجود در بار الکتریکی بکار گرفته می شود. سپس، شبکه LSTM با دو لایه پنهان برای پیش بینی مصرف انرژی استفاده شده است.

در مقاله [۳۹] پیکربندی بهینه از یک مدل LSTM توسط بوکتیف و همکاران پیشنهاد شده که برای توصیف الگوهای مصرف برق و کشف پویایی سری زمانی در حوزه انرژی استفاده شده است. برای یافتن مقادیر بهینه به منظور پیکربندی شبکه LSTM، نویسندگان از دو الگوریتم فرا ابتکاری PSO<sup>۴۱</sup> و GA<sup>۴۲</sup> استفاده می کنند.

ژانگ و همکاران روشی برای پیش بینی مصرف بار بر اساس یک شبکه LSTM ساده ارائه می کنند [۴۰]. این مدل می تواند توالی و وابستگی های بلندمدت زمانی سری بارهای الکتریکی را بیاموزد. رویکرد

جدول (۲): داده‌های مصرف بار الکتریکی

| نام فیلد | نوع داده | توصیف                         |
|----------|----------|-------------------------------|
| Date     | nvarchar | تاریخ ثبت اطلاعات             |
| Time     | int      | زمان محلی ثبت اطلاعات         |
| Active   | float    | بار اکتیو                     |
| ReActive | float    | بار راکتیو                    |
| PeakTemp | float    | دمای هوا در زمان پیک          |
| MaxTemp  | float    | حداکثر دمای هوا در طول یک روز |


ونجی و همکاران یک شبکه یکپارچه مبتنی بر LSTM طراحی کرده‌اند که از نگاشت خودسازمانده<sup>۳۹</sup> و الگوریتم بهینه‌سازی هوشمند استفاده می‌کند [۳۰]. از SOM برای کاهش پیچیدگی منحنی بار در کلاس‌های مشابه استفاده شده است. همچنین یک بهینه‌سازی هوشمند برای دستیابی سریع‌تر به وزن‌های بهینه محلی در LSTM به کار گرفته شده است.

وو و همکاران نیز یک مدل شبکه عصبی عمیق ترکیبی مبتنی بر GRU و CNN ارائه کرده‌اند [۳۱]. ماجول GRU برای مدل‌سازی تغییرات پویا در داده‌های توالی بار و ماجول CNN برای پردازش و نگاشت ماتریس‌های فضایی- زمانی در بردار ویژگی استفاده می‌شود. جدول ۱ خلاصه‌ای از پژوهش‌های بررسی شده شامل نکات برجسته و مسایل هریک، مشخصات دیتاست و معیارهای ارزیابی را نمایش می‌دهد.

#### ۴- روش پیشنهادی: CLSMNet

در این بخش، ابتدا طرح کلی CLSMNet آورده می‌شود و سپس مراحل مختلف آن شامل جمع‌آوری داده‌ها، پیش‌پردازش، طراحی شبکه عصبی عمیق و پیش‌بینی بار الکتریکی ارائه می‌شود.

همانطور که در بخش‌های قبلی ذکر شد، هدف این مقاله معرفی یک شبکه عصبی عمیق ترکیبی برای پیش‌بینی کوتاه مدت بار الکتریکی در سیستم‌های توزیع برق است. شبکه عصبی عمیق در CLSMNet با ترکیب معماری‌های CNN و LSTM ایجاد می‌شود. شکل ۱ مرور کلی از رویکرد پیشنهادی را نشان می‌دهد.



شکل (۱): روندنمای روش پیشنهادی

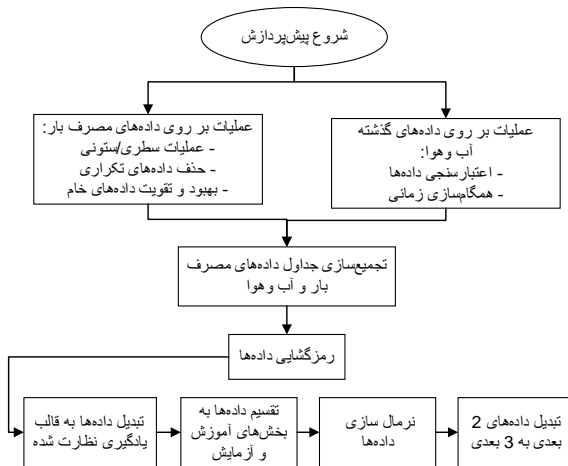
##### ۴-۱- جمع‌آوری داده‌ها

در ابتدا، داده‌های مصرف بار الکتریکی در هر ساعت با استفاده از وب سرویسی که توسط مرکز توزیع برق ارائه شده است به پایگاه‌داده سیستم منتقل می‌شود. همزمان اطلاعات ساعت‌به‌ساعت وضعیت آب و هوا نیز با استفاده از وب سرویس توسعه داده شده از سایت DarkSky دریافت شده و در پایگاه‌داده سیستم ذخیره می‌گردد.

داده‌های استخراج شده از مرکز توزیع نیروی برق تهران است که درمجموع شامل ۱۰۹۱۴۰۷۵ رکورد از اردیبهشت ۱۳۹۵ تا تیر ۱۳۹۶ می‌باشد که فیلدهای آن در جدول ۲ نشان داده شده است.

جدول (۱): خلاصه پژوهش های بررسی شده

| مرجع / سال | نکات برجسته تحقیق   | مسایل و چالش های تحقیق   | دیتاست                  | معیارهای سنجش       |
|------------|---|--|-------------------------|---------------------|
| [۳۷], ۲۰۱۷ | • CNN تک بعدی برای تهیه نگاشت ویژگی<br>• تابع فعال سازی خطی اصلاح شده   | • عدم برتری CNN پیشنهادی نسبت به سایر مدل های یادگیری عمیق مانند LSTM<br>• عدم استفاده از داده های هواشناسی                          | دیتاست عمومی UCI        | RMSE                |
| [۳۳], ۲۰۱۹ | • توانایی مدل CNN برای یادگیری اتصال ذاتی داده ها و ایجاد سری زمانی ویژگیها<br>• پیاده سازی SLTF از طریق GRU و BPNN                       | • گیت های ساده به روزرسانی و تنظیم مجدد GRU<br>• شبکه عصبی عمیق GRU تنها با چهار لایه<br>• عدم مقایسه با مدل های یادگیری عمیق        | دیتاست اختصاصی          | MAE                 |
| [۳۸], ۲۰۱۸ | • یادگیری الگوهای غیر خطی و تصادفی با استفاده از FCRBM<br>• مدل SLTF بر اساس FCRBM انباشته شده و CRBM                                     | • اتصالات بیش از حد در CRBM و FCRBM<br>• مقایسه فقط با ANN و CNN   | دیتاست اختصاصی          | MAPE<br>NRMSE       |
| [۳۵], ۲۰۱۸ | • ترکیبی از CNN و LSTM<br>• آرایه مفهومی یک لایه ویژگی فیوزن برای پیش بینی بار  | • پیش بینی بار تنها برای ۲۴ ساعت آینده<br>• عدم کارآمدی تابع سیگموئید به عنوان فعال کننده<br>• عدم استفاده از داده های هواشناسی      | دیتاست اختصاصی          | RMSE                |
| [۲۳], ۲۰۱۸ | • استفاده از شبکه CNN تحریک پذیر برای رگرسیون سری زمانی<br>• عدم توازن بین نیاز به حافظه و توانایی یادگیری عوامل غیرخطی                   | • پیش بینی بار تنها برای ۲۴ ساعت آینده<br>• عدم استفاده از داده های هواشناسی   | دیتاست عمومی UCI        | MSE                 |
| [۲۴], ۲۰۱۸ | • MTS شامل توالی پیوسته و گسسته سری های زمانی<br>• توسعه مدل ترکیبی LSTM و GRU در سری های زمانی پیوسته و گسسته                            | • عدم مقایسه با مدل های یادگیری عمیق<br>• پیش بینی بار تنها برای ۲۴ ساعت آینده<br>• محدودیت رکوردهای دیتاست                          | دیتاست اختصاصی          | MAPE<br>MAE         |
| [۲۵], ۲۰۱۷ | • بهره گیری از پتانسیل یادگیری عمیق با مقایسه عملکرد بین شبکه های عصبی "کم عمق" و "عمقی"<br>• بکارگیری RNN با عمقهای مختلف                | • پیش بینی بار تنها برای ۲۴ ساعت آینده<br>• محدودیت رکوردهای دیتاست<br>• عدم استفاده از داده های هواشناسی                            | دیتاست اختصاصی          | RMSE<br>MAE<br>MAPE |
| [۲۶], ۲۰۱۹ | • تحلیل داده های مشتری-محور اکتشافی<br>• خوشه بندی مبتنی بر چگالی برای از بین بردن ناسازگاری در بار<br>• چارچوب پیش بینی بار بر اساس LSTM | • عدم مقایسه با مدل های یادگیری عمیق<br>• پیش بینی بار تنها برای ۲۴ ساعت آینده<br>• عدم استفاده از داده های هواشناسی                 | دیتاست اختصاصی          | MAPE                |
| [۳۹], ۲۰۲۰ | • یافتن بیکربندی بهینه برای مدل پیش بینی بار با استفاده از GA و PSO<br>• SLTF از طریق مدل LSTM چند توالی                                  | • مقایسه روش تنها با برخی از روش های اصلی یادگیری ماشین نظیر ANN و SVR<br>• عدم استفاده از داده های هواشناسی                         | دیتاست اختصاصی          | RMSE<br>MAE         |
| [۴۰], ۲۰۱۷ | • معماری ساده LSTM<br>• دروازه ورودی/خروجی با استفاده از سیگموئید   | • عدم مقایسه با مدل های یادگیری عمیق<br>• محدودیت رکوردهای دیتاست  | دیتاست اختصاصی          | RMSE<br>MAPE        |
| [۲۷], ۲۰۱۹ | • رمزگذاری خودکار به همراه GRU انباشته شده<br>• در نظر گرفتن اطلاعات تعطیلات<br>• استفاده از شبکه عصبی عمیق ۳ لایه GRU برای پیش بینی      | • مشکل overfitting در هنگام افزایش حجم داده ورودی<br>• نیاز به بهبود سطوح تکرار مدل GRU<br>• محدودیت ورودی SAE در داده های سری زمانی | دیتاست اختصاصی          | NMAE<br>NRMSE       |
| [۴۱], ۲۰۲۰ | • پیش بینی مصرف انرژی دوره ای بر اساس LSTM<br>• استخراج ویژگی های پنهان توسط نمودار همبستگی   | • مقایسه روش تنها با برخی از روش های اصلی یادگیری ماشین نظیر BPNN و AR<br>• عدم استفاده از داده های هواشناسی                         | دیتاست اختصاصی          | MSE<br>MAE          |
| [۲۸], ۲۰۱۸ | • ترکیب CNN و RNN برای پیش بینی سری زمانی<br>• افزایش توانایی مدل با استفاده از مدل خطی AR به موازات شبکه عصبی غیرخطی                     | • تنظیم دستی پارامتر طول پرش از لایه مکرر<br>• عدم استفاده از داده های هواشناسی<br>• پیش بینی بار تنها برای ۲۴ ساعت آینده            | دیتاست عمومی UCI        | RSE<br>CORR         |
| [۴۳], ۲۰۲۰ | • ترکیب رویکرد پارامتری و غیر پارامتری<br>• ترکیبی از شبکه XGBoost Regressor و LSTM برای پیش بینی   | • افزایش زمان ایجاد درخت تصمیم گیری XGBoost<br>• مستعد مشکل overfitting<br>• پیش بینی بار تنها برای ۲۴ ساعت آینده                    | دیتاست عمومی GEFCom۲۰۱۴ | MAPE                |
| [۳۰], ۲۰۲۰ | • ترکیب LSTM با SOM و الگوریتم بهینه سازی هوشمند  | • عدم استفاده از داده های هواشناسی<br>• پیش بینی بار تنها برای ۲۴ ساعت آینده   | دیتاست اختصاصی          | RMSE                |
| [۳۱], ۲۰۲۰ | • مدل ترکیبی GRU و CNN: پردازش داده های توالی توسط GRU و پردازش ماتریس فضایی-زمانی توسط CNN   | • مدت زمان طولانی آموزش شبکه عصبی<br>• عدم استفاده از داده های هواشناسی<br>• پیش بینی بار تنها برای ۲۴ ساعت آینده                    | دیتاست اختصاصی          | RMSE<br>MAPE        |



شکل (۲): جریان کار فاز پیش‌پردازش داده‌ها

از طرفی، آرایه  $\lambda$  جهت نگهداری مقادیر در ست بار اکتیو ساعت بعد تولید می‌شود. شبه‌کد ۱ چگونگی تولید این سری‌های زمانی با استفاده از الگوریتم Sliding Window را نمایش می‌دهد.

```

Function createWindow (x, windowSize, metadata);
Input: x //2D array containing active load,
//weather forecast data and time data
Input: metadata //2D array containing weather forecast
//data and time data for the next timestep
Input: windowSize //Size of the array containing historical values
Output: window //Final array containing historical values
//expected for the active load for last time step,
//plus metadata for the next timestep
Output: y (window <- extract_window (x, windowSize)
//Extracts an array containing the number of
//samples specified by the windowSize
y <- extract_active_load (window)
//Extracts and removes the active load from the
//final timestep and preserves it in y
window <- concatenate (window, metadata)
//Concatenates the extracted window array with
//the metadata)
Return: window
Return: y
  
```

شبه‌کد (۱): تولید سری‌های زمانی برای آموزش شبکه عصبی عمیق

همانطور که ذکر شد، داده‌های آب و هوا نیز با استفاده از وب سرویس‌های DarkSkyLib از وبسایت Darksky استخراج می‌شوند. اطلاعات جمع‌آوری شده شامل فیلدهایی است که در جدول ۳ نشان داده شده است.

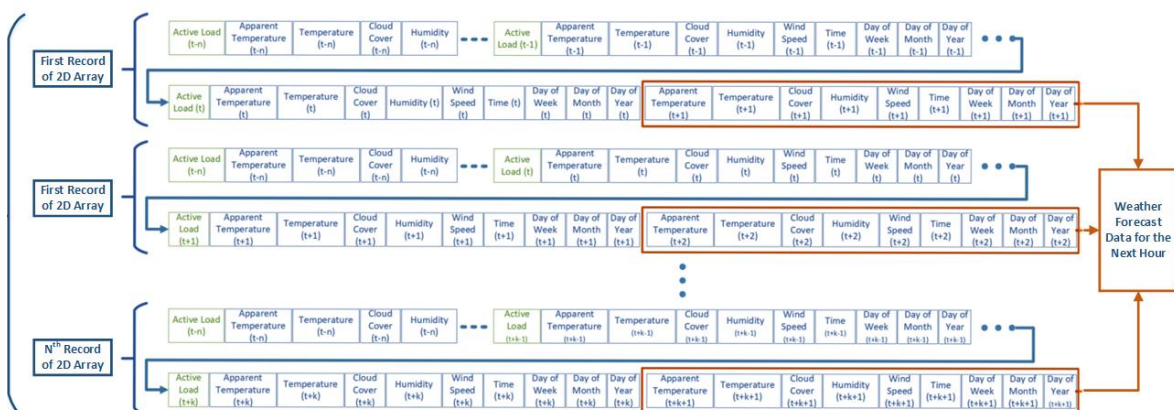
جدول (۳): داده‌های وضعیت آب و هوا

| نام فیلد            | نوع داده | توصیف                         |
|---------------------|----------|-------------------------------|
| UnixTime            | int      | برچسب زمانی یکتای ثبت اطلاعات |
| CloudCoverage       | float    | درصد پوشش ابری                |
| Humidity            | float    | درصد رطوبت هوا                |
| Temperature         | float    | دمای واقعی                    |
| ApparentTemperature | float    | دمای احساس شده توسط انسان     |
| WindSpeed           | float    | سرعت باد                      |

## ۴-۲- پیش‌پردازش داده‌ها

اکنون اطلاعات استخراج شده از مرحله قبل پیش‌پردازش می‌شود تا اطمینان حاصل شود که داده‌های ذخیره شده برای استفاده در شبکه عصبی عمیق ارائه شده در این مقاله مناسب هستند. شکل ۲ جریان کار مرحله پیش‌پردازش داده‌ها را نشان می‌دهد.

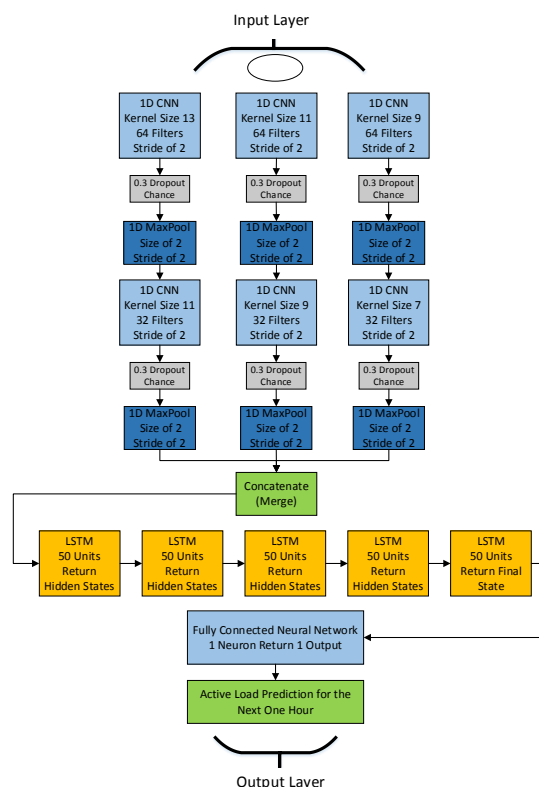
مسائل پیش‌بینی مصرف بار الکتریکی از نوع سری‌های زمانی هستند در نتیجه جهت آموزش داده‌ها به شبکه عصبی، ساختار داده باید به صورت سری زمانی درآورده شود. به همین منظور در مرحله پیش‌پردازش داده، ساختار مورد نیاز شبکه با استفاده از الگوریتم Sliding Window تولید می‌شود، بدین صورت که چند رکورد در یک آرایه کنار هم قرار می‌گیرند که تعداد رکوردهای درون پنجره با مشخصه Window Size تعیین می‌شود. در نتیجه اطلاعات وضعیت آب و هوا، اطلاعات زمانی و اطلاعات مصرف بار از زمان  $t-n$  تا زمان  $t$  در یک آرایه قرار می‌گیرند. در نهایت داده‌های زمانی و وضعیت آب و هوای یک ساعت آینده نیز به انتهای آرایه اضافه می‌شوند، این مجموعه داده حاوی داده‌های آب و هوا، زمان و بار اکتیو مجموعه داده  $X$  نامیده می‌شود. شکل ۳ ساختار این سری زمانی را نشان می‌دهد که در آن چندین رکورد به شکل آرایه  $X$  در کنار هم قرار گرفته‌اند.



شکل (۳): ساختار داده سری زمانی



گام زمانی بعد است. شکل ۴ معماری شبکه ترکیبی پیشنهادی در CLSMNet را نشان می دهد.



شکل (۴): معماری شبکه عصبی عمیق پیشنهادی در CLSMNet

برای دستیابی به وزن های بهینه شبکه از الگوریتم بهینه سازی Adam [۴۴] استفاده شده که در شبه کد ۲ نمایش داده شده است.

```

Function Adam ( $\alpha, \beta_1, \beta_2, f(\theta), \theta_0, m_0, v_0, t$ )
Input:  $\alpha$ 
Input:  $\beta_1, \beta_2 \in [0,1]$ 
Input:  $f(\theta)$ 
Input:  $\theta_0$ 
     $m_0 \leftarrow 0$ ;
     $v_0 \leftarrow 0$ ;
     $t \leftarrow 0$ ;
Output:  $\theta_t$ 
while  $\theta_0$  not converged do
     $t \leftarrow t + 1$ 
     $g_t \leftarrow \nabla_{\theta} f_t(\theta_{t-1})$ 
     $m_t \leftarrow \beta_1 \times m_{t-1} + (1 - \beta_1) \times g_t$ 
     $v_t \leftarrow \beta_2 \times v_{t-1} + (1 - \beta_2) \times g_t^2$ 
    Compute bias-corrected first moment estimate
    Compute bias-corrected second raw moment estimate
    Update parameters
end while
Return  $\theta_t$ 

```

شبه کد (۲): الگوریتم بهینه سازی Adam

#### ۴-۴ آموزش شبکه عصبی عمیق

در طول آموزش شبکه، داده های تجربی به شبکه وارد می شود تا دقت شبکه پیشنهادی در پیش بینی بار فعال ارزیابی شود. شکل ۵ فرآیند آموزش شبکه عصبی عمیق CLSMNet را نشان می دهد.

#### ۳-۴ معماری شبکه عصبی عمیق

CLSMNet از ترکیب دو شبکه عصبی عمیق تشکیل شده است: CNN و LSTM. از معماری های CNN و LSTM به ترتیب برای استخراج الگوهای موجود در داده ها و پیش بینی میزان مصرف بار در ساعت های بعدی استفاده می شود.

بخش CNN در CLSMNet از سه ردیف موازی متشکل از دو لایه کانولوشن تشکیل شده است. استفاده از کامپوننت های CNN به صورت موازی که هر کدام دارای فیلترهایی با اندازه های متفاوت هستند، توانایی استخراج الگوهای غنی تر را به شبکه می دهد. شبکه های عصبی CNN با تفکر اتصالات محلی بوجود آمده اند. هر نود فقط به یک بخش محلی از ورودی متصل است. با جایگزین کردن جمع وزن های شبکه عصبی با عملیات کانولوشن می توان به اتصال محلی دست یافت. در هر لایه از CNN، عملیات کانولوشن بین ورودی ها و ماتریس وزن ها (یا همان فیلترها) اعمال می شود که نگاشت ویژگی ها را تولید می کند.

در معماری پیشنهاد شده تمامی نرون های داخل هر لایه با احتمال از پیش تعیین شده ای Dropout می شوند. پس از انجام عملیات کانولوشن، ماتریس خروجی از یک لایه Max Pool عبور کرده که باعث کاهش حجم اطلاعات شده و در عین حال اطلاعات مهم را حفظ می کند. در نهایت خروجی سه CNN موازی با استفاده از Concatenate با یکدیگر ادغام شده و به بخش LSTM داده می شود.

همانطور که در شکل ۴ نشان داده شده است اندازه فیلترهای CNN در لایه اول به ترتیب ۹، ۱۱ و ۱۳ است و تعداد فیلترها برای تمامی CNN های این لایه ۶۴ می باشد. اندازه های فیلترهای لایه دوم به ترتیب برابر ۷، ۹ و ۱۱ هستند و تعداد فیلترها برای تمامی CNN های این لایه نیز ۳۲ است. همچنین گام حرکتی ۲۰ تمامی فیلترها برابر ۲ می باشد و متغیر احتمال Dropout نرون های CNN، ۳۰ درصد تعیین شده اند. تمامی لایه های Max Pool نیز دارای گام حرکتی ۲ و اندازه آن ها نیز برابر ۲ می باشد.

در این پژوهش از شبکه LSTM نیز به همراه CNN استفاده شده است. شبکه LSTM طراحی شده دنباله ورودی  $\{x_1, x_2, \dots, x_n\}$  را با استفاده از فرمول زیر مدل می کند:

$$O_t = \sigma_t \times \tanh(C_t) \quad (8)$$

$x_t$  ورودی در زمان  $t$  است و  $h_t$  وضعیت مخفی نرون می باشد که برداری حاوی تمامی ورودی های مشاهده شده تا زمان  $t$  است.

با تغذیه دنباله  $\{x_1, x_2, \dots, x_n\}$  به LSTM، خروجی های وضعیت مخفی  $\{h_1, h_2, \dots, h_n\}$  بدست خواهد آمد. خروجی های بدست آمده به LSTM دیگری داده شده و دنباله جدید از وضعیت های مخفی تولید خواهد شد و در نهایت آخرین لایه LSTM خروجی دنباله  $\{h_1, h_2, \dots, h_n\}$  را از لایه قبلی دریافت کرده و یک مقدار نهایی را تولید می کند که این خروجی نهایی در واقع پیش بینی بار اکتیو برای

**Function** nextWindow( $x$ ,  $metadata$ ,  $y_{pred}$ ):  
**Input:**  $x$  2D array containing active load, weather forecast, and time data  
**Input:**  $metadata$  2D array containing weather forecast and time data for the next time-step  
**Input:**  $y_{pred}$  1D array containing predicted active load for the next time-step  
**Output:** The next window  
 $x \leftarrow \text{inverse\_transform}(x)$  Transform scaled data to original scale  
 $y_{pred} \leftarrow \text{inverse\_transform}(y_{pred})$  Transform scaled prediction to original scale  
 $next_{hour} \leftarrow y_{pred} \cup metadata$  Concatenate prediction and forecast data to create data for the new time-step  
 $x \leftarrow x \cup next_{hour}$  Concatenate  $x$  with the newly created time-step  
 $x \leftarrow \text{shift\_window}(x, 1)$  Shift window one time-step  
**Return:**  $x$  New window

### شبه‌کد (۳): تولید پنجره زمانی بعدی برای پیش‌بینی بار اکتیو

لازم به ذکر است که این فرآیند به صورت تکراری با تعداد پیش‌بینی مورد نظر انجام شده و هر پیش‌بینی جدید در آرایه‌ای ذخیره می‌شود. شکل ۸ این فرآیند تکرار شونده را با استفاده از سری‌های زمانی مورد نظر نشان می‌دهد.

## ۵- شبیه‌سازی و ارزیابی

در این بخش، پس از معرفی معیارهای سنجش دقت پیش‌بینی، خلاصه‌ای از پیکربندی سخت‌افزار/نرم‌افزار محیط پیاده‌سازی ارائه می‌شود. سپس، نتایج ارزیابی CLSMNet مورد بحث و بررسی قرار گرفته و با برخی از بهترین روش‌های موجود در پیش‌بینی کوتاه مدت مصرف بار مقایسه می‌شود.

### ۵-۱- معیارهای سنجش دقت پیش‌بینی

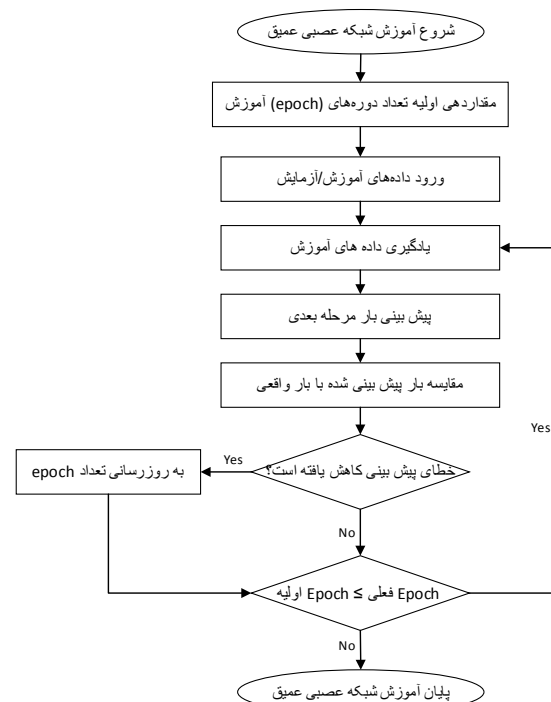
برای ارزیابی روش ارائه شده، از ریشه میانگین مربعات خطا<sup>۴۱</sup> (RMSE) و میانگین درصد قدر مطلق خطا<sup>۴۲</sup> (MAPE) استفاده می‌شود. RMSE میزان خطای بین دو مجموعه داده را طبق رابطه زیر اندازه‌گیری می‌کند:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{Y}_i - Y_i)^2} \quad (9)$$

MAPE یک سنجه آماری برای تعیین دقت یک سیستم پیش‌بینی است. این دقت را به صورت درصد اندازه‌گیری می‌کنند و طبق رابطه زیر محاسبه می‌شود:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{\hat{Y}_i - Y_i}{Y_i} \right| \quad (10)$$

علاوه بر این، به منظور مقایسه با سایر روشها از معیارهای ریشه مربعات نسبی خطا<sup>۴۳</sup> (RSE) و ضریب همبستگی تجربی<sup>۴۴</sup> (CORR) نیز استفاده می‌شود. RSE نسخه مقیاس شده معیار RMSE است که برای ارائه ارزیابی‌های خواناتر صرف نظر از مقیاس داده‌ها توسعه یافته است. همانند RMSE، مقادیر کوچکتر RSE بهتر است، در حالی که برای CORR، مقادیر بزرگتر مناسب‌تر هستند. معادلات (۱۱) و (۱۲) روابط RSE و CORR را نشان می‌دهد:




شکل (۵): فرآیند آموزش شبکه عصبی عمیق CLSMNet

شکل ۷ لایه‌های مختلف و ورودی‌ها/خروجی‌های شبکه عصبی CLSMNet را بر اساس فرآیند آموزش شکل ۵ نشان می‌دهد.

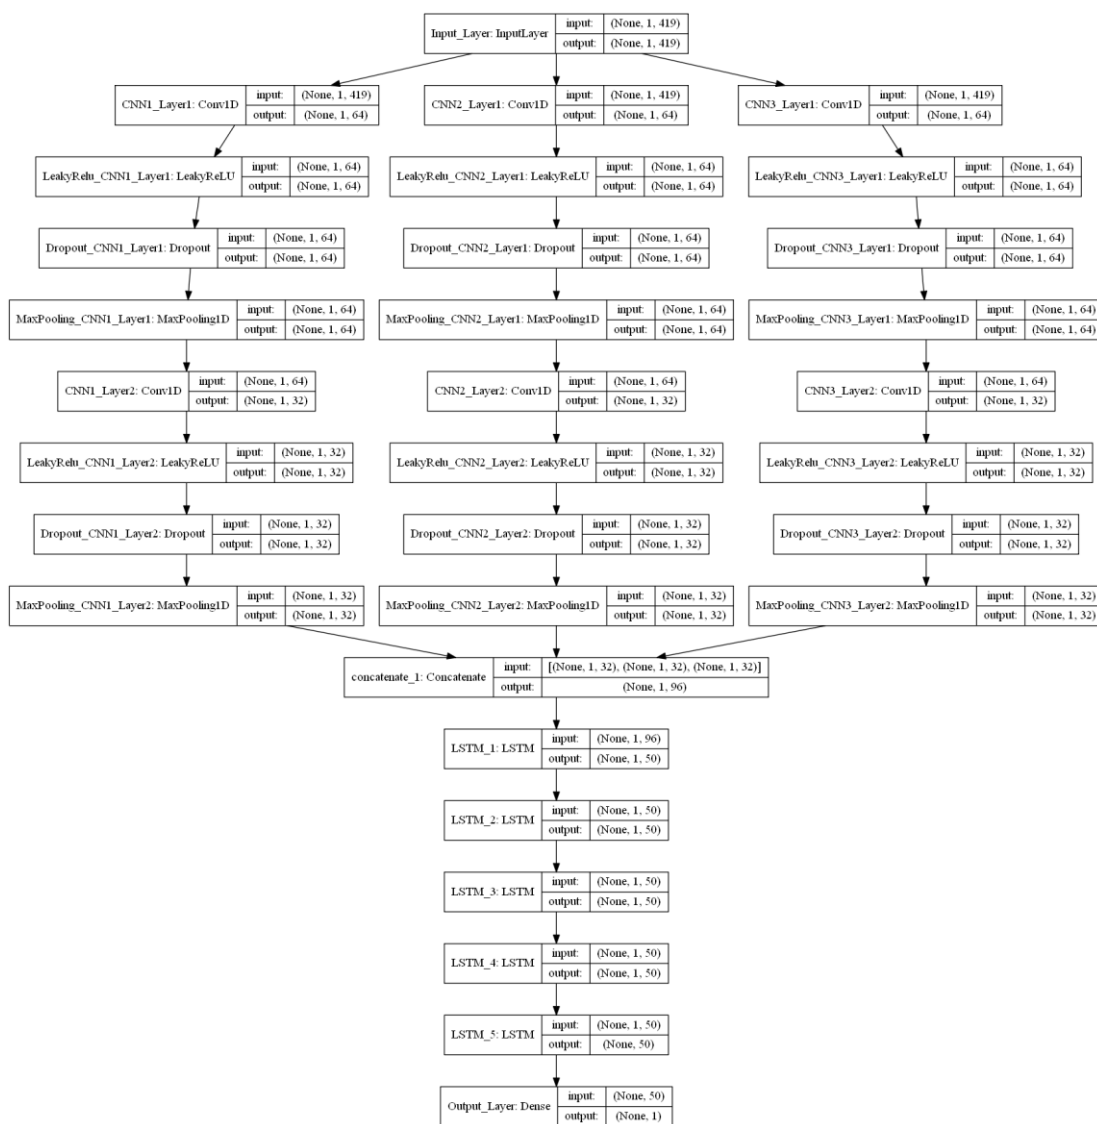
### ۵-۴- پیش‌بینی مصرف بار الکتریکی

پس از پایان فرآیند آموزش شبکه عصبی عمیق با استفاده از مجموعه داده‌های  $x$  و  $y$  که حاوی ویژگی‌ها و برجسبها می‌باشند (در بخش ۴.۲ بدست آمدند)، پیش‌بینی بار اکتیو ساعات آینده انجام می‌شود. برای شروع پیش‌بینی در روش پیشنهاد شده فقط اولین رکورد در مجموعه داده  $x$  کافیست. همانطور که قبلاً نیز عنوان شد مجموعه داده  $x$  حاوی اطلاعات گذشته وضعیت آب و هوا، زمان و بار اکتیو است. رکوردی از این آرایه برای پردازش به شبکه عصبی عمیق داده شده و شبکه بار اکتیو پیش‌بینی شده برای ساعت آینده را تولید می‌کند. حال با استفاده از بار پیش‌بینی شده، وضعیت آب و هوا و اطلاعات زمانی، آرایه جدیدی تولید می‌شود، سپس این آرایه به انتهای آرایه سری زمانی حاوی اطلاعات ساعات گذشته اضافه شده و پنجره یک گام زمانی به جلو حرکت می‌کند. شکل ۶ جریان کار فرآیند پیش‌بینی توسط شبکه را نمایش می‌دهد.

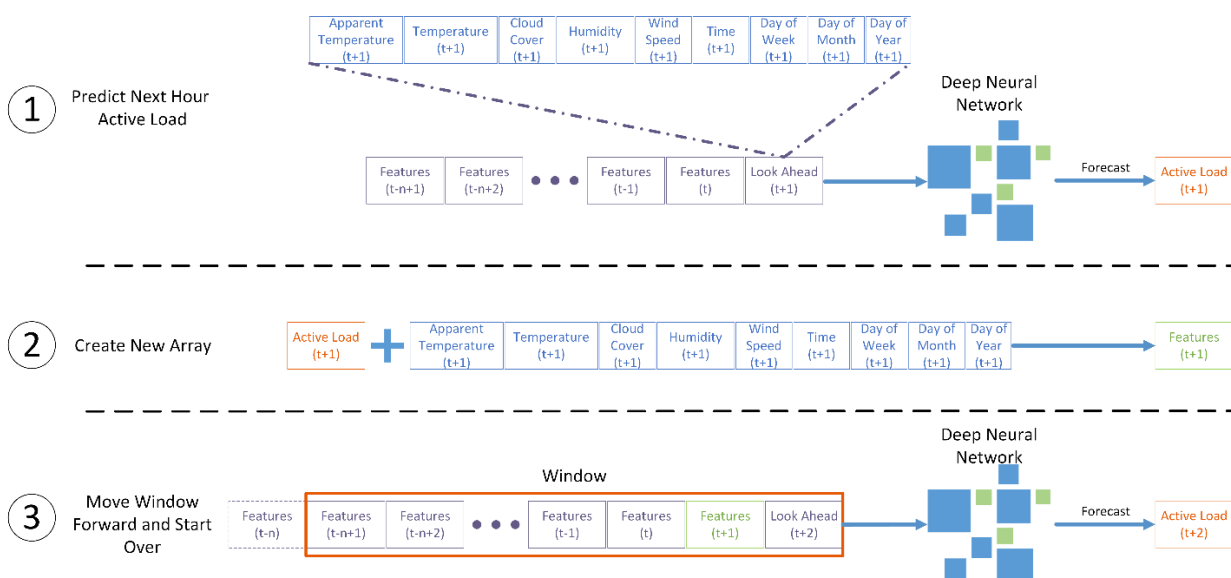


شکل (۶): جریان کار پیش‌بینی بار اکتیو

شبه‌کد ۳ تولید پنجره زمانی بعدی برای پیش‌بینی بار اکتیو در ساعات آینده را نمایش می‌دهد.



شکل (۷): معماری و اندازه تنسورهای ورودی و خروجی هر لایه شبکه عصبی



شکل (۸): سری های زمانی برای تولید پنجره بعدی به منظور پیش بینی بار اکتیو

(از ۲۴ تا ۱۶۸ ساعت) ارزیابی شده است. مقادیر مشخص شده با فونت درشت بهترین خروجی روش در گام‌های زمانی پیش‌بینی شده را نشان می‌دهد.

جدول ۶ - MAPE پیش‌بینی مصرف بار برای گام‌های زمانی مختلف

| MAPE  |       |       |       |       |       |       | اندازه پنجره اطلاعات |
|-------|-------|-------|-------|-------|-------|-------|----------------------|
| ۱۶۸   | ۱۴۴   | ۱۲۰   | ۹۶    | ۷۲    | ۴۸    | ۲۴    |                      |
| ۳.۹۲۲ | ۳.۵۴۰ | ۲.۹۰۰ | ۲.۴۵۳ | ۲.۱۱۵ | ۱.۲۵۷ | ۱.۱۵۴ | ۴۰                   |
| ۴.۴۸۴ | ۴.۲۶۰ | ۳.۱۳۶ | ۲.۲۶۲ | ۱.۸۲۲ | ۲.۰۳۴ | ۲.۳۹۴ | ۵۰                   |
| ۳.۴۸۶ | ۳.۷۲۲ | ۲.۵۰۴ | ۱.۸۳۴ | ۱.۸۳۲ | ۱.۸۱۳ | ۱.۳۸۱ | ۶۰                   |
| ۳.۴۱۴ | ۳.۳۰۱ | ۲.۴۶۴ | ۲.۳۲۲ | ۲.۳۲۰ | ۲.۴۴۶ | ۲.۲۱۲ | ۷۰                   |
| ۳.۱۳۲ | ۲.۹۲۸ | ۲.۰۹۷ | ۱.۸۵۸ | ۱.۹۵۱ | ۱.۳۷۳ | ۱.۵۳۳ | ۹۰                   |

جدول ۷ - RMSE پیش‌بینی مصرف بار برای گام‌های زمانی مختلف

| RMSE  |       |       |        |       |       |       | اندازه پنجره اطلاعات |
|-------|-------|-------|--------|-------|-------|-------|----------------------|
| ۱۶۸   | ۱۴۴   | ۱۲۰   | ۹۶     | ۷۲    | ۴۸    | ۲۴    |                      |
| ۶.۸۶۲ | ۵.۵۷۷ | ۴.۵۸۱ | ۴.۰۷۶۴ | ۲.۳۳۸ | ۲.۱۸۴ | ۱.۹۲۲ | ۴۰                   |
| ۹.۱۰۶ | ۸.۸۳۹ | ۶.۰۱۲ | ۴.۰۸۱۱ | ۳.۴۱۷ | ۳.۵۸۴ | ۴.۱۷۵ | ۵۰                   |
| ۷.۱۸۵ | ۷.۰۵۶ | ۵.۱۸۰ | ۳.۳۰۹  | ۳.۳۵۹ | ۳.۳۵۵ | ۲.۶۷۳ | ۶۰                   |
| ۶.۴۵۵ | ۶.۱۳۹ | ۳.۸۲۱ | ۳.۲۸۶  | ۳.۹۳۸ | ۴.۰۶۵ | ۳.۶۳۶ | ۷۰                   |
| ۶.۵۷۷ | ۶.۱۴۶ | ۴.۱۴۲ | ۳.۹۳۱  | ۲.۶۲۵ | ۲.۴۸۳ | ۲.۶۴۲ | ۹۰                   |

همانطور که در جداول فوق نشان داده شده است، اندازه پنجره اطلاعات ۴۰ در پیش‌بینی گام‌های زمانی ۲۴ و ۴۸ ساعت آینده (پیش‌بینی یک و دو روزه) بهترین MAPE و RMSE را نتیجه می‌دهد، در حالی که بهترین مقادیر MAPE و RMSE برای گام زمانی ۹۶ ساعت آینده (پیش‌بینی چهار روزه) از اندازه پنجره اطلاعات ۶۰ بدست می‌آید. در نهایت، اندازه پنجره اطلاعات ۷۰ و ۹۰ در پیش‌بینی گام‌های زمانی ۱۲۰، ۱۴۴ و ۱۶۸ ساعت آینده (پیش‌بینی پنج، شش و هفت روزه) RMSE و MAPE بهینه را بدست می‌آورند. بنابراین می‌توان نتیجه گرفت که هرچه اندازه پنجره اطلاعات بزرگ‌تر باشد، عملکرد شبکه در پیش‌بینی آینده بهتر است.

نمودارهای زیر مقادیر پیش‌بینی شده و میزان واقعی مصرف بار را برای گام‌های زمانی مختلف از ۲۴ ساعت تا ۱۶۸ ساعت آینده نشان می‌دهند.

$$RSE = \sqrt{\frac{\sum_{i=1}^n (\hat{Y}_i - Y_i)^2}{\sum_{i=1}^n (Y_i - \text{mean}(Y))^2}} \quad (11)$$

$$CORR = \frac{1}{n} \times$$

$$\sum_{i=1}^n \frac{\sum_{i=1}^n (Y_i - \text{mean}(Y))(\hat{Y}_i - \text{mean}(\hat{Y}_i))}{\sqrt{\sum_{i=1}^n (Y_i - \text{mean}(Y))^2 \times \sum_{i=1}^n (\hat{Y}_i - \text{mean}(\hat{Y}_i))^2}} \quad (12)$$

در تمامی روابط فوق  $Y_i$  نشان‌دهنده مقدار اندازه‌گیری شده (مقدار واقعی) و  $\hat{Y}_i$  نشان‌دهنده مقدار پیش‌بینی شده است.

## ۲-۵ - پیکربندی سخت‌افزار/نرم‌افزار

برای پیاده‌سازی CLSMNet، از زبان برنامه‌نویسی پایتون به همراه کتابخانه‌های نرم‌افزاری جدول ۴ استفاده شده است.

جدول ۴ - کتابخانه‌های نرم‌افزاری

| کتابخانه        | نسخه   | توصیف   |
|-----------------|--------|---|
| matplotlib      | ۲.۱.۲  | کتابخانه رسم نمودار   |
| Pandas          | ۰.۲۲.۰ | کتابخانه آنالیز داده  |
| pydot-ng        | ۱.۰.۰  | کتابخانه نمایش معماری شبکه                                  |
| pyodbc          | ۴.۰.۲۲ | API ارتباط با ODBC  |
| scikit-learn    | ۰.۱۹.۱ | کتابخانه یادگیری ماشین و استخراج داده                       |
| SQLAlchemy      | ۱.۲.۱  | کتابخانه SQL  |
| Darkskylib      | ۰.۳.۹۱ | کتابخانه ارتباط با سایت DarkSky جهت دریافت اطلاعات آب و هوا |
| python-dateutil | ۲.۶.۱  | کتابخانه تبدیل تاریخ  |
| Keras           | ۲.۱.۵  | API پیاده‌سازی شبکه‌های عصبی عمیق                           |
| Tensorflow-gpu  | ۱.۷.۰  | API پیاده‌سازی و اجرای شبکه‌های عصبی عمیق با استفاده از GPU |
| Python          | ۳.۵.۵  | کتابخانه استاندارد Python                                   |

پیکربندی سخت‌افزاری محیط پیاده‌سازی در جدول ۵ ارائه شده است.


جدول ۵ - مشخصات سخت‌افزاری سیستم اجرایی

| مشخصات   | اجزای سخت‌افزاری |
|--|------------------|
| Intel(R) Core(TM) i۷-۷۷۰۰ HQ CPU - ۲.۸۰ GHz, ۴ Core(s), ۸ Logical Processor(s) | CPU              |
| GeForce GTX ۱۰۵۰ Ti, NVIDIA compatible - ۴GB RAM                               | GPU              |
| ۱۶GB   | RAM              |

## ۳-۵ - نتایج ارزیابی CLSMNet

جداول ۶ و ۷ نتایج حاصل از روش پیشنهادی CLSMNet را برای پارامترهای مختلف نشان می‌دهد. برای این منظور، روش مورد نظر برای اندازه‌های مختلف پنجره اطلاعات (از ۴۰ تا ۹۰) و گام‌های زمانی مختلف

مجموعه داده عمومی، که توسط بسیاری از مقالات استفاده شده است، نیز ارزیابی می شود.



شکل (۱۱): پیش بینی مصرف بار برای ۱۶۸ گام زمانی آینده


برای نیل به هدف اول ارزیابی، چهار روش مختلف انتخاب شده است: [۲۴] MTS-RNN، [۳۷] CNN، [۴۳] LSTM-XG، و [۳۰] LSTM-SOM که تمام آنها از شبکه های یادگیری عمیق برای افزایش دقت پیش بینی مصرف بار الکتریکی استفاده کرده اند. این رویکردها با استفاده از مجموعه داده مورد استفاده در CLSMNet پیاده سازی شده اند. دقت پیش بینی مصرف بار الکتریکی کوتاه مدت با در نظر گرفتن معیارهای MAPE و RMSE تجزیه و تحلیل شده است که نتایج مقایسه CLSMNet با روش های فوق برای پیش بینی ۲۴ ساعت آینده در جدول ۸ آمده است. با توجه به خصوصیات ذاتی فرآیندهای ارائه شده در کلیه مقالات مورد مقایسه، تمام آنها فقط میزان بار مصرف را برای ۲۴ ساعت آینده پیش بینی کرده اند. بنابراین، برای مقایسه ای یکسان و عادلانه، تنها نتایج پیش بینی بار برای ۲۴ ساعت آینده در جدول ۸ منظور شده است. جدول ۸ - مقایسه CLSMNet با سایر رویکردها برای پیش بینی بار ۲۴

ساعت آینده با استفاده از مجموعه داده اختصاصی


| روش           | RMSE  | MAPE  |
|---------------|-------|-------|
| CLSMNet       | ۱.۹۲۲ | ۱.۱۵۴ |
| MTS-RNN [۲۴]  | ۲.۲۱۵ | ۱.۳۰۹ |
| CNN [۳۷]      | ۲.۷۱۰ | ۱.۶۶۱ |
| LSTM-XG [۴۳]  | ۲.۹۲۵ | ۲.۱۲۳ |
| LSTM-SOM [۳۰] | ۳.۳۷۳ | ۲.۷۵۴ |

همانطور که در جدول ۸ ذکر شد، در هر دو معیار MAPE و RMSE، روش CLSMNet بهبود قابل توجهی در پیش بینی بار الکتریکی ۲۴ ساعت آینده نسبت به روش های مقایسه شده نشان می دهد.

MTS-RNN از پنج ردیف موازی شبکه GRU استفاده می کند که هر ردیف آن دارای دو لایه است. ردیف های مختلف سری زمانی با ساختارهای متغیر برای پیش بینی بار به این شبکه منتقل می شوند. اما هیچ پردازشی برای استخراج ویژگی های مفید از مجموعه داده ورودی



شکل (۹): پیش بینی مصرف بار برای ۲۴ گام زمانی آینده



شکل (۱۰): پیش بینی مصرف بار برای ۹۶ گام زمانی آینده

#### ۴-۵- مقایسه CLSMNet با روش های موجود

در این بخش، CLSMNet را با برخی از بهترین روش های موجود در پیش بینی کوتاه مدت مصرف بار مقایسه می کنیم تا جایگاه روش پیشنهادی در پژوهش های موجود در این زمینه مشخص شود.

همانطور که در جدول ۱ مشخص شده است، بسیاری از روش های پیش بینی کوتاه مدت مصرف بار از مجموعه داده های اختصاصی برای ارزیابی استفاده می کنند. با این حال، تعدادی از روش ها نیز از مجموعه داده های در دسترس عموم بهره می برند. به منظور ارزیابی هر چه دقیق تر CLSMNet، دو رویکرد فوق بطور همزمان انجام شده است. اول آنکه از داده های اختصاصی تهیه شده در این مقاله برای پیاده سازی روش های دیگر استفاده شده است. همچنین، به منظور از بین بردن هرگونه عدم تناقض یا بایاس احتمالی در مجموعه داده، CLSMNet با استفاده از یک

فرمولاسیون استاندارد فاکتورسازی ماتریس، یک تنظیم‌کننده موقتی طراحی می‌کند.

• VAR-MLP: ترکیبی از MLP و AR [۴۸].

• GRU-CNN: مدل ترکیبی GRU و CNN [۳۱].

• LSTNet-skip: روشی مبتنی بر LSTN با یک لایه جهشی RNN [۲۸].

• LSTNet-Attn: روشی مبتنی بر LSTN با یک لایه توجه زمانی [۲۸].

مجموعه داده ElectricityLoadDiagrams شامل بار الکتریکی ۳۷۰ پست انتقال در کشور پرتغال از ابتدای سال ۲۰۱۱ تا پایان سال ۲۰۱۴ میلادی با دوره نمونه‌برداری ۱۵ دقیقه است که تعداد کل داده‌ها در آن برابر با ۱۴۰۲۵۶ می‌باشد.

از آنجا که تقریباً تمام روشهای مورد مقایسه که در بالا ذکر شدند میزان بار الکتریکی را برای ۲۴ ساعت آینده بر اساس معیارهای RSE و CORR پیش‌بینی می‌کنند، در جدول ۹ نتایج ارزیابی با توجه به این معیارها نشان داده شده است. همانطور که در جدول ۹ نشان داده شده است، در هر دو معیار RSE و CORR، روش CLSMNet بهبود قابل توجهی در پیش‌بینی بار الکتریکی ۲۴ ساعت آینده نسبت به روش‌های مقایسه شده نشان می‌دهد.

**جدول ۹ - مقایسه CLSMNet با سایر رویکردها برای پیش‌بینی بار ۲۴**

**ساعت آینده با استفاده از مجموعه‌داده عمومی**

| روش              | CORR   | RSE    |
|------------------|--------|--------|
| CLSMNet          | ۰.۹۲۷۳ | ۰.۰۹۱۲ |
| LSTNet-skip [۲۸] | ۰.۹۱۱۹ | ۰.۱۰۰۷ |
| LSTNet-Attn [۲۸] | ۰.۹۰۲۵ | ۰.۱۰۵۹ |
| GRU-CNN [۳۱]     | ۰.۸۲۳۶ | ۰.۱۱۲۳ |
| TRMF [۴۷]        | ۰.۷۴۷۱ | ۰.۳۶۵۶ |
| VAR-MLP [۴۸]     | ۰.۸۶۷۹ | ۰.۱۲۷۴ |
| AR [۴۶]          | ۰.۸۵۹۵ | ۰.۱۰۵۴ |

در LSTNet یک لایه CNN با ترکیب LSTN استفاده شده است و از لایه Pooling نیز استفاده نکرده که باعث می‌شود زمان آموزش شبکه و حجم داده‌های مورد نیاز برای آموزش نسبت به شبکه CLSMNet به مراتب بیشتر باشد. همچنین، شبکه CLSMNet با عمق بیشتر قادر به یادگیری بهتر داده‌ها است و به علت استفاده از لایه‌های Max Pooling متعدد و الگوریتم Dropout، شبکه سریع‌تر و پایدارتر عمل می‌کند.

GRU-CNN یک ماژول GRU را برای یادگیری اطلاعات مفید در

داده‌های بلند مدت بار و از طریق یک سلول حافظه به کار می‌گیرد. با این حال، شبکه‌های GRU معمولاً در یادگیری الگوهای بلند مدت نسبت به LSTM ها ضعیف‌تر هستند. بنابراین، CLSMNet که مبتنی بر LSTM است می‌تواند نتایج دقیق‌تری را ارائه دهد.

TRMF سیگنال‌های با ابعاد بالا را به نمایش‌های پنهان کم‌بعدی

تبدیل می‌کند، سپس از VAR با انواع مختلفی از تنظیمات برای پیش‌بینی استفاده می‌کند. اما، در CLSMNet استفاده از ترکیبی از CNN و LSTM نتایج بهتری در استخراج و یادگیری ویژگی‌ها و الگوهای داده‌های بلند مدت ارائه می‌دهد.

صورت نگرفته است، در صورتی که این کار در CLSMNet با استفاده از یک مدل CNN انجام شده است. علاوه بر این، شبکه‌های GRU در یادگیری الگوهای بلند مدت نسبت به LSTM ضعیف‌تر هستند. در واقع، استفاده ترکیبی از CNN و LSTM باعث شده است CLSMNet بتواند ویژگی‌ها و الگوهای موجود در داده‌های طولانی مدت را استخراج کرده و آموزش ببیند.

روش CNN از سه لایه CNN برای استخراج و یادگیری الگوهای مصرف بار استفاده می‌کند، در حالیکه داده‌های زمانی با استفاده از یک شبکه کاملاً متصل و بدون عبور از لایه‌های CNN پردازش می‌شوند. در CLSMNet، تمام داده‌ها به صورت یکپارچه از طریق سه ردیف CNN گذرانده می‌شوند که هر کدام اندازه فیلتر متفاوتی دارند. تغذیه کلیه داده‌ها به صورت یکپارچه به CNN اجازه می‌دهد تا نداشت‌های ویژگی دقیق‌تری تولید کرده و همچنین روابط بین پارامترهای مختلف ورودی را شناسایی کند. علاوه بر این، CLSMNet از LSTM برای پیش‌بینی مصرف بار الکتریکی استفاده می‌کند، که در [۷] برای پیش‌بینی همان CNN بکاربرده شده است.

در LSTM-XG با استفاده از رگرسیون XGBoost مبتنی بر GBDT برای سری‌های زمانی پارامتری و LSTM برای سری‌های زمانی غیر پارامتری، الگوهای بین داده‌های فعلی و قبلی را محاسبه و شناسایی می‌کند. این روش تنها مقیاس‌بندی ساده min-max را برای پیش‌پردازش به کار می‌گیرد. علاوه بر این، معماری LSTM پیشنهادی بسیار ابتدایی بوده و فقط شامل یک دروازه ورودی/خروجی/فراموشی ساده است. در حالی که در CLSMNet یک شبکه عصبی عمیق کامل برای تولید دقیق نداشت‌های ویژگی (CNN) و یک شبکه عصبی عمیق دیگر برای پیش‌بینی بار (LSTM) ارائه شده است.

مفهوم پیش‌بینی بخش‌بندی شده بر اساس SOM در LSTM-SOM برای کاهش نوسانات منحنی بار استفاده شده است، در حالی که پیچیدگی کلی منحنی بار به طور موثر تجزیه و تحلیل نشده است. در این روش بهینه‌سازی هوشمندی برای یافتن وزن‌های بهینه محلی در LSTM طراحی شده است. پیش‌بینی بخش‌بندی شده در LSTM-SOM پیش‌بینی بار را فقط برای یک سری زمانی محدود و بدون در نظر گرفتن تأثیر متقابل این بخش‌ها بر یکدیگر امکان‌پذیر می‌کند. بنابراین دقت و اثربخشی نتایج پیش‌بینی کاهش می‌یابد.

همان‌گونه که در مقدمه زیرفصل نیز اشاره شد، برای ارزیابی بیشتر CLSMNet، از یک مجموعه داده عمومی نیز استفاده شده است. برای این منظور، نتایج CLSMNet با روش‌های زیر بر مبنای مجموعه داده ElectricityLoadDiagrams که از مخزن یادگیری ماشین UCI استخراج شده است [۴۵]، مقایسه می‌شود:

•  $AR^{۴۵}$ : معادل مدل  $VAR^{۴۶}$  یک بعدی است [۴۶]. VAR به دلیل سادگی یکی از مدل‌های بسیار پرکاربرد در سری‌های زمانی چند متغیره است.

• TRMF: مدلی از AR است که از فاکتورسازی ماتریس منظم موقتی<sup>۴۷</sup> استفاده می‌کند [۴۷]. TRMF برای تنظیم این ساختار زمانی در

- توسعه انواع دیگری از شبکه های عصبی عمیق، به ویژه در مراحل استخراج و یادگیری ویژگی ها مانند شبکه عصبی کپسول (CapsNet) به جای مدل فعلی CNN.

## مراجع

- [۱] Singh, P., Dwivedi P., "Integration of new evolutionary approach with artificial neural network for solving short term load forecast problem", Applied Energy, Vol. ۲۱۷, pp. ۵۳۷-۵۴۹, ۲۰۱۸.
- [۲] Ertugrul, Ö F., "Forecasting electricity load by a novel recurrent extreme learning machines approach", International Journal of Electrical Power & Energy Systems, Vol. ۷۸, No. ۴, pp. ۲۹-۴۳۵, ۲۰۱۶.
- [۳] Abedinia, O., Amjady, N., "Short-term load forecast of electrical power system by radial basis function neural network and new stochastic search algorithm", International Transactions on Electrical Energy Systems, Vol ۲۶, pp. ۱۵۱۱-۱۵۲۵, ۲۰۱۶.
- [۴] Liu, M., Shi, Y., Fang, F., "Load forecasting and operation strategy design for CCHP systems using forecasted loads", IEEE Trans Control Syst Technol, Vol. ۱۶۷۲, pp ۱۶۸۴-۱۷۲۳, ۲۰۱۵.
- [۵] Li, L., Sun, J., Wang, C., Zhou, Y., Lin, K., "Enhanced Gaussian process mixture model for short-term electric load forecasting", Information Sciences, Vol ۴۷۷, pp. ۳۸۶-۳۹۸, ۲۰۱۹.
- [۶] Taylor, J., W., McSharry, P., "Univariate methods for short-term load forecasting", In Advances in Electric Power and Energy Systems: Load and Price Forecasting, Wiley, Vol. ۲, pp. ۱۷-۳۹, ۲۰۱۷.
- [۷] Fan, G-F, Peng, L-L, Hong, W-C., "Short term load forecasting based on phase space reconstruction algorithm and bi-square kernel regression model", Applied Energy, Vol. ۲۲۴, pp. ۱۳-۲۳, ۲۰۱۸.
- [۸] Zhang, B., Liu, W., Li, S., Wang, W., Zou, H., Dou, Z., "Short-term load forecasting based on wavelet neural network with adaptive mutation bat optimization algorithm", IEEJ Trans. Electr. Electron. Eng, Vol. ۱۴, pp. ۳۷۶-۳۸۲, ۲۰۱۹.
- [۹] Yang, A., Li, W., Yang, X., "Short-term electricity load forecasting based on feature selection and Least Squares Support Vector Machines", Knowledge-Based Systems, Vol. ۱۶۳, pp. ۱۵۹-۱۷۳, ۲۰۱۹.
- [۱۰] Jahangoshai-Rezaee, M., Dadkhah, M., Falahinia, M., "Integrating neuro-fuzzy system and evolutionary optimization algorithms for short-term power generation forecasting", International Journal of Energy Sector Management, Vol. ۱۳, No. ۴, pp. ۸۲۸-۸۴۵, ۲۰۱۹.
- [۱۱] Borovykh, A., Bohte, S., Oosterlee, C W., "Conditional Time Series Forecasting with Convolutional Neural Networks", arXiv:۱۷۰۳.۰۴۶۹۱, ۲۰۱۷.
- [۱۲] Hong, W-C., Fan, G-F., "Hybrid Empirical Mode Decomposition with Support Vector Regression Model for Short Term Load Forecasting", Energies, Vol. ۱۲, Article. ۱۰۹۳, ۲۰۱۹.

در VAR-MLP از مدل خطی ARIMA (میانگین متحرک یکپارچه AR) و مدل غیرخطی ANN با هدف استخراج اشکال مختلف روابط در داده های سری زمانی به طور مشترک استفاده می شود. در حقیقت، هر دو رویکرد AR و VAR-MLP روش های بنیادی هستند که بسیاری از مدل های پیش بینی مبتنی بر یادگیری عمیق از آنها به عنوان روش های پایه ای برای مقایسه استفاده می کنند تا نشان دهند شبکه های عصبی عمیق چگونه می توانند اثربخشی و دقت پیش بینی بار را بهبود بخشند.

## ۶- نتیجه گیری و کارهای آینده

پژوهش های مرتبط با پیش بینی مصرف بار الکتریکی، هم از سوی دانشگاه ها و مؤسسات پژوهشی و هم از سمت صنایع، مورد توجه بسیاری در سال های اخیر قرار گرفته است. اگرچه هنوز در بسیاری از مراکز از روش های سنتی و مرسوم برای پیش بینی مصرف بار الکتریکی استفاده می شود، اما این رویکردها در ارائه یک پیش بینی موثر و دقیق کارآمدی لازم را ندارند. با توجه به تأثیر پیش بینی کوتاه مدت در میزان خاموشی های رخ داده و سلامت تجهیزات توزیع و انتقال، روش ها سنتی به تدریج با رویکردهای مدرن تر مانند شبکه های عصبی عمیق جایگزین می شوند.

روش پیشنهادی، CLSMNet، یک رویکرد شبکه عصبی ترکیبی است که از تکنیک های یادگیری عمیق با ترکیب معماری های CNN و LSTM بهره می گیرد. LSTM و CNN به ترتیب برای استخراج الگوهای موجود در داده های ورودی و پیش بینی مصرف بار در ساعات بعدی استفاده شده اند. CLSMNet برای پارامترهای پیکربندی شبکه مانند تعداد لایه های شبکه و نرون ها و همچنین اندازه فیلتر بهینه شده است. CLSMNet قادر است میزان بار الکتریکی را با دقت مناسب تا ۱۶۸ ساعت (یک هفته) پیش بینی کند، در حالی که اکثر روش های پیش بینی بار الکتریکی کوتاه مدت تنها قادر به پیش بینی تا ۲۴ ساعت آینده هستند. روش پیشنهادی با برخی از بهترین روش های موجود در پیش بینی کوتاه مدت مصرف بار الکتریکی مقایسه شده است. نتایج ارزیابی نشان دهنده بهبود دقت در پیش بینی بر اساس پارامترهای CORR، RSE، RMSE، MAPE می باشد.

پژوهش های زیر می تواند به عنوان کارهای آینده در نظر گرفته شود:

- استفاده از یادگیری عمیق در هوشمندسازی سیستم های تعمیر و نگهداری پیشگیرانه جهت پیش بینی زمان های سرویس و جلوگیری از خرابی های تجهیزات توزیع و انتقال.
- تکمیل مجموعه داده آموزش شبکه با تعطیلات رسمی و برخی از رویدادهای مهم تأثیرگذار در مصرف بار و سپس بررسی میزان تأثیرگذاری اطلاعات اضافه شده در بهبود دقت پیش بینی ها.

- neural network", IEEE Transactions on Smart Grid, Vol. ۱۰, No. ۱, pp. ۸۴۱-۸۵۱, ۲۰۱۹.
- [۲۷] Ke, K., Hongbin, S., Chengkang, Z., Brown, C., "Short-term electrical load forecasting method based on stacked auto-encoding and GRU neural network", Evolutionary Intelligence, Vol. ۱۲, pp. ۳۸۵-۳۹۴, ۲۰۱۹.
- [۲۸] Lai, G., Chang, W.-C., Yang, Y., Lie, H., "Modeling Long-and Short-Term Temporal Patterns with Deep Neural Networks", In The ۴۱st International ACM SIGIR Conference on Research & Development in Information Retrieval, pp. ۹۵-۱۰۴, ۲۰۱۸.
- [۲۹] He, W., "Load forecasting via deep neural networks", Procedia Computer Science, Vol. ۱۲۲, pp. ۳۰۸-۳۱۴, ۲۰۱۷.
- [۳۰] Wenjie, Z., Jian, Q., Feng, M., Junjie, F., Bo, D., WenWu, Y., "Short-term power load forecasting using integrated methods based on long short-term memory", Science China Technological Sciences, Vol. ۶۳, pp. ۶۱۴-۶۲۴, ۲۰۲۰.
- [۳۱] Wu, L., Kong, C., Hao, X., Chen, W., "A Short-Term Load Forecasting Method Based on GRU-CNN Hybrid Neural Network Model", Mathematical Problems in Engineering, Article ۱۴۲۸۱۰۴, ۲۰۲۰.
- [۳۲] Zhang, Y., Qian, A., Zhaoyu, L., Shuangrui, Y., Huang, K., Yousif, M., Tianguang, L., "Data augmentation strategy for small sample short-term load forecasting of distribution transformer", International Transactions on Electrical Energy Systems, First published online: ۱۱ November ۲۰۱۹.
- [۳۳] Shen, M., Xu, Q., Wang, K., Tu, M., Wu, B., "Short-Term Bus Load Forecasting Method Based on CNN-GRU Neural Network", In International Forum on Smart Grid Protection and Control Springer, Vol. ۵۸۵, pp. ۷۱۱-۷۲۲, ۲۰۲۰.
- [۳۴] Krizhevsky, A., Sutskever, I., Hinton, G. E., "Imagenet classification with deep convolutional neural networks", In Advances in neural information processing systems, pp. ۱۰۹۷-۱۱۰۵, ۲۰۱۲.
- [۳۵] Tian, C., Ma, J., Zhang, C., Zhan, P., "A Deep Neural Network Model for Short-Term Load Forecast Based on Long Short-Term Memory Network and Convolutional Neural Network", Energies, Vol. ۱۱, No. ۱۲, pp. ۳۴۹۳, ۲۰۱۸.
- [۳۶] Hochreiter, S., Schmidhuber, J., "Long short-term memory", Neural Computation, Vol. ۹, No. ۸, pp. ۱۷۳۵-۱۷۸۰, ۱۹۹۷.
- [۳۷] Amarasinghe, K., Marino, D. L., Manic, M., "Deep neural networks for energy load forecasting", In IEEE ۲۶th International Symposium on Industrial Electronics (ISIE), pp. ۱۴۸۳-۱۴۸۸, ۲۰۱۷.
- [۳۸] Hafeez, G., Javaid, N., Ullah, S., Iqbal, Z., Khan, M., Rehman, A., Ziaullah, "Short Term Load Forecasting based on Deep Learning for Smart Grid Applications", In Innovative Mobile and Internet Services in Ubiquitous Computing Springer, pp. ۲۷۶-۲۸۸, ۲۰۱۸.
- [۳۹] Bouktif, S., Fiaz, A., Ouni, A., Serhani, M. A., "Multi-Sequence LSTM-RNN Deep Learning and Metaheuristics for Electric Load Forecasting", Energies, Vol. ۱۳, No. ۲, Article. ۳۹۱, ۲۰۲۰.
- [۴۰] Zheng, J., Xu, C., Zhang, Z., Li, X., "Electric load forecasting in smart grids using long-short-term-memory based recurrent
- [۱۳] Liang, Y., Niu, D., Hong W. C., "Short term load forecasting based on feature extraction and improved general regression neural network model", Energy, Vol. ۱۶۶, pp. ۶۵۳-۶۶۳, ۲۰۱۹.
- [۱۴] Ribeiro, G. T., Mariani, V. C., Coelho, L. D. S., "Enhanced ensemble structures using wavelet neural networks applied to short-term load forecasting", Engineering Applications of Artificial Intelligence, Vol. ۸۲, pp. ۲۷۲-۲۸۱, ۲۰۱۹.
- [۱۵] Hernandez, L., Baladron, C., Aguiar, J. M., Carro B., Sanchez-Esguevillas, A. J., Lloret J., Massana, J., "A survey on electric power demand forecasting: future trends in smart grids, microgrids and smart buildings", IEEE Communications Surveys & Tutorials, Vol. ۱۶, No. ۳, pp. ۱۴۶۰-۱۴۹۵, ۲۰۱۴.
- [۱۶] LeCun, Y., Bengio, Y., Hinton, G., "Deep learning", Nature, Vol. ۵۲۱, No. ۷۵۵۳, pp. ۴۳۶, ۲۰۱۵.
- [۱۷] Lei, M., Tang, L., Li, M., Ye, Z., Pan, L., "Forecasting Short-Term Residential Electricity Consumption Using a Deep Fusion Model", In Proceedings of Chinese Intelligent Systems Conference. Lecture Notes in Electrical Engineering, Springer, Vol. ۵۲۹, pp. ۳۵۹-۳۷۱, ۲۰۱۹.
- [۱۸] Kim, J., Moon, J., Hwang, E., Kanga, P., "Recurrent inception convolution neural network for multi short-term load forecasting", Energy and Buildings, Vol. ۱۹۴, pp. ۳۲۸-۳۴۱, ۲۰۱۹.
- [۱۹] Khan, A. B. M., Javaid, N., Nazeer, O., Zahid, M., Akbar, M., Hameed Khan, M., "Hourly Electricity Load Forecasting in Smart Grid Using Deep Learning Techniques", In: Innovative Mobile and Internet Services in Ubiquitous Computing, Advances in Intelligent Systems and Computing, Springer, Vol. ۹۹۴, pp. ۱۸۵-۱۹۶, ۲۰۲۰.
- [۲۰] Yazici, I., Temizer, L., Beyca, O. F., "Short Term Electricity Load Forecasting with a Nonlinear Autoregressive Neural Network with Exogenous Variables (NarxNet)", In: Industrial Engineering in the Big Data Era. Lecture Notes in Management and Industrial Engineering, Springer, pp. ۲۵۹-۲۷۰, ۲۰۱۹.
- [۲۱] Guo, Z., Zhou, K., Hang, X. Z., Yang, S., "A deep learning model for short-term power load and probability density forecasting", Energy, Vol. ۱۶۰, pp. ۱۱۸۶-۱۲۰۰, ۲۰۱۸.
- [۲۲] Sherstinsky, A., "Fundamentals of Recurrent Neural Network (RNN) and Long Short-Term Memory (LSTM) Network", Physica D: Nonlinear Phenomena, Vol. ۴۰۴, Article. ۱۳۲۳۰۶, ۲۰۲۰.
- [۲۳] Binkowski, M., Marti, G., Donnat, P., "Autoregressive Convolutional Neural Networks for Asynchronous Time Series", In proceedings of the ۳۵th International Conference on Machine Learning, PMLR ۸۰, ۱-۱۶, ۲۰۱۸.
- [۲۴] Zhang, B., Wu, J.-L., Chang, P.-C., "A multiple time series-based recurrent neural network for short-term load forecasting", Soft Computing, Vol. ۲۲, No. ۱۲, pp. ۴۰۹۹-۴۱۱۲, ۲۰۱۸.
- [۲۵] Shi, H., Xu, M., Ma, Q., Zhang, C., Li, R., Li, F., "A Whole System Assessment of Novel Deep Learning Approach on Short-Term Load Forecasting", Energy Procedia, Vol. ۱۴۲, pp. ۲۷۹۱-۲۷۹۶, ۲۰۱۷.
- [۲۶] Kong, W., Dong, Z. Y., Jia, Y., Hill, D. J., Xu, Y., Zhang, Y., "Short-term residential load forecasting based on LSTM recurrent



- [۴۸] Zhang, G P., "Time series forecasting using a hybrid ARIMA and neural network model", Neurocomputing, Vol. ۵۰, pp. ۱۵۹-۱۷۵, ۲۰۰۳.
- [۴۹] Wang, J Q., Du, Y., Wang, J., "LSTM based long-term energy consumption prediction with periodicity", Energy, Vol. ۱۹۷, Article. ۱۱۷۱۹۷, ۲۰۲۰.
- [۴۲] Dong, X., Qian, L., Huang, L., "Short-term load forecasting in smart grid: A combined CNN and K-means clustering approach", In IEEE International Conference on Big Data and Smart Computing (BigComp), pp. ۱۱۹-۱۲۵, ۲۰۱۷.
- [۴۳] Gupta, P., Malsa, N., Saxena, N., Agarwal, S., Singh, S P., "Short-Term Load Forecasting Using Parametric and Non-parametric Approaches", In Soft Computing: Theories and Applications. Advances in Intelligent Systems and Computing Springer, Vol. ۱۰۵۳, pp. ۷۴۷-۷۵۵, ۲۰۲۰.
- [۴۴] Kingma, D P., Ba, J., "Adam: A method for stochastic optimization", Proceedings of the International Conference on Learning Representations (ICLR), ۲۰۱۵.
- [۴۵] Trindade, A., "UCI Machine Learning Repository", ElectricityLoadDiagrams۲۰۱۱۲۰۱۴ DataSet, <https://archive.ics.uci.edu/ml/datasets/ElectricityLoadDiagrams۲۰۱۱۲۰۱۴>
- [۴۶] Box, G E., Jenkins, G M., Reinsel, G C., Ljung, G M., "Time series analysis: forecasting and control", John Wiley & Sons, ۲۰۱۵.
- [۴۷] Yu, H F., Rao, N., Dhillon, I S., "Temporal regularized matrix factorization for high-dimensional time series prediction", In Proceedings of Advances in Neural Information Processing Systems, Vol. ۲۹, pp. ۸۴۷-۸۵۵, ۲۰۱۶.

### زیر نویس ها

- |  |  |
|--|--|
| 25 Forget Gate                                       | 1 Very Short-Term Load Forecast                          |
| 26 Gated Recurrent Units                             | 2 Short-Term Load Forecast                               |
| 27 Back-Propagation Neural Networks                  | 3 Mid-Term Load Forecast                                 |
| 28 Factored Conditional Restricted Boltzmann Machine | 4 Long-Term Load Forecast                                |
|  | 5 Deep Fusion Model                                      |
| 29 Conditional Restricted Boltzmann Machine          | 6 Recurrent Inception Convolution Neural Network         |
| 30 Autoregressive                                    | 7 Kernel Principle Component Analysis                    |
| 31 Particle Swarm Optimization                       | 8 Enhanced Convolutional Neural Network                  |
| 32 Genetic Algorithm                                 | 9 Autoregressive Neural Network with Exogenous Variables |
| 33 Autoregressive Integrated Moving Average          | 10 Multi-Layer Perceptron (MLP)                          |
| 34 Stacked Autoencoders (SAE)                        | 11 Convolutional Neural Network (CNN)                    |
| 35 eXtreme Gradient Boosting                         | 12 Feature Extraction                                    |
| 36 Gradient Boosted Decision Trees                   | 13 Long Short-term Memory (LSTM)                         |
| 37 Recurrent Extreme Learning Machine (RELM)         | 14 Recurrent Neural Network (RNN)                        |
| 38 Feed-forward                                      | 15 Convolutional Long Short Memory Network               |
| 39 Self-Organizing Map (SOM)                         | 16 Loss function   |
| 40 Stride  | 17 Support Vector Machine                                |
| 41 Root Mean Square Error (RMSE)                     | 18 Fully Connected                                       |
| 42 Mean Average Percentage Error (MAPE)              | 19 Feedforward Neural Networks                           |
| 43 Root Relative Squared Error (RSE)                 | 20 Directed Cyclic Graph                                 |
| 44 Empirical Correlation Coefficient (CORR)          | 21 Exploding gradient                                    |
| 45 Autoregression                                    | 22 Vanishing gradient                                    |
| 46 Vector Autoregression                             | 23 Cell State  |
| 47 Temporal Regularized Matrix Factorization         | 24 Gateway   |