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

نوع مطالعه: پژوهشی

سینا قصایی[1] ، دانش‌آموخته کارشناسی ارشد، رضا روانمهر[2]، استادیار

۱- دانشکده مهندسی- گروه مهندسی کامپیوتر-واحد تهران مرکزی-دانشگاه آزاد اسلامی- تهران- ایران
sina.ghassai@gmail.com

۱- 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 وCORR 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

[Downloaded from ieijqp.ir on 2026-11-04]

[DOR: 20.1001.1.23222344.1400.10.1.6.1]

[DOI: 10.52547/ieijqp.10.1.35]

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 ذخیره‌سازی این انرژی ارزشمند در ابعاد بزرگ وجود ندارد، بنابراین برنامه‌ریزی تولید باید به گونه‌ای صورت گیرد که پاسخگوی تقاضای متغیر انرژی الکتریکی باشد. در این راستا پیش‌بینی مصرف بار الکتریکی به عنوان عاملی مهم در طرح توسعه و بهره‌برداری از سیستم‌های قدرت تلقی شده و در واقع شاخصی است که به‌کمک آن می‌توان بهینه‌سازی روند تخصیص منابع برای توسعه و استفاده مناسب از شبکه برق‌رسانی را امکان‌پذیر نمود.

در توسعه زیرساخت‌های سیستم تولید و توزیع الکتریسیته میزان خطای پیش‌بینی مصرف بار الکتریکی از اهمیت زیادی برخوردار است. اگر میزان بار پیش‌بینی شده کمتر از بار واقعی باشد ضریب اطمینان و در نتیجه کیفیت خدمات کاهش می‌یابد و این امر ممکن است حتی به خاموشی‌های اجباری بینجامد. از طرف دیگر اگر میزان بار آینده بیش از مقدار مورد نیاز پیش‌بینی شود سرمایه‌گذاری زیادی به هدر می‌رود. پیش‌بینی دقیق بار منجر به رضایت‌مندی مصرف کنندگان، صرفه‌جویی انرژی و افزایش ضریب کیفیت خدمات شده و همواره برای برنامه‌ریزی و تصمیم‌های 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 زمان‌های پر مصرف، پیش‌بینی بار برای شرکت‌های برق امری ضروری و حیاتی است.

یکی از مسائل مهم و اساسی در طراحی و بهره‌برداری سیستم‌های تولید و توزیع قدرت، پیش‌بینی بار برای یک ساعت تا چند روز آینده است که تحت عنوان پیش‌بینی کوتاه مدت بار شناخته می‌شود. در واقع پیش‌بینی بار با توجه به فاصله زمانی پیش‌بینی شده در سیستم‌های مدیریت انرژی به چهار نوع [۱]: (۱) پیش‌بینی بار بسیار کوتاه مدت[۱] (VSTLF): پیش‌بینی بار برای چند دقیقه (۲) پیش‌بینی بار کوتاه مدت[۲] (STLF): پیش‌بینی بار از ۲۴ ساعت تا یک هفته، (۳) پیش‌بینی بار متوسط مدت[۳] (MTLF): پیش‌بینی بار بیش از یک هفته تا چند ماه و (۴) پیش‌بینی بار درازمدت[۴] (LTLF): پیش‌بینی بار بیش از یک سال طبقه بندی می شود. تمرکز ما در این مقاله بر روی پیش‌بینی بار کوتاه مدت است. پیش‌بینی کوتاه مدت بار در تخمین جریان بار و در تصمیم‌گیری‌هایی که منجر به جلوگیری از بالا رفتن بیش از حد مصرف بار می‌شود کمک می‌کند، همچنین در به فعال‌سازی به هنگام مدارها و مراکز دیسپاچینگ کاربرد دارد. اجرای به موقع این تصمیم‌ها سبب بهبود اطمینان به شبکه، کاهش خرابی‌های تجهیزات و خاموشی‌ها می‌شود. STLF برای کنترل و برنامه‌ریزی سیستم قدرت در فراهم‌سازی الکتریسیته موردنیاز روزمره، ارزیابی مراکز تبادل، ارزیابی امنیت، تحلیل اطمینان و محاسبه قیمت‌های واقعی ضروری است [۲، ۳] که منجر به نیاز به دقت بالاتر نسبت به پیش بینی طولانی مدت می‌شود.

روش‌های گوناگونی برای پیش‌بینی مصرف بار الکتریکی با استفاده از تکنیک‌های آماری [۴، ۵]، تجزیه و تحلیل سری‌های زمانی [۶، ۷]، مدل‌های فرابتکاری [۸، ۹، ۱۰] و یادگیری ماشین [۱۱، ۱۲، ۱۳، ۱۴] پیشنهاد شده است اما با توجه به نیاز برای پیش‌بینی دقیق‌تر به مدل‌های پیش‌بینی مصرف بار کارآمدتری نیاز است [۱۵]. اخیراً جوامع پژوهشی در فیلدهای مختلف جذب شبکه‌های یادگیری عمیق شده‌اند. این شبکه‌ها بر پایه شبکه‌های عصبی مصنوعی به‌همراه معماری عمیق هستند که توانایی دریافت و تحلیل رفتار داده‌ها در زمانی که از الگوهای غیرخطی پیچیده تبعیت می‌کنند و نیز حجم زیادی دارند را دارا می‌باشند [۱۶].

یادگیری عمیق منجر به پیشرفت چشمگیر رویکردهای مرتبط با پیش‌بینی کوتاه مدت مصرف بار الکتریکی شده است. این شبکه‌ها فرصت‌های پژوهشی نوآورانه بیشتری که باعث افزایش دقت پیش‌بینی می‌شوند به‌وجود آورده‌اند. در همین راستا، مطالعات گوناگونی بر اساس به‌کارگیری مدل‌های مختلف یادگیری عمیق برای پیش‌بینی کوتاه مدت مصرف بار از قبیل مدل فیوژن عمیق[۵] [۱۷] ، شبکه عصبی پیچشی مکرر آغازین[۶] [۱۸] ، هسته آنالیز مؤلفه اصلی[۷] و شبکه عصبی پیچشی پیشرفته[۸] [۱۹]، شبکه عصبی خود مختار با متغیرهای برونزا[۹] [۲۰] و شبکه عصبی عمیق با پرسپترون چند لایه[۱۰] (MLP) [۲۱] انجام شده است.

تمرکز اکثر پژوهش‌های صورت گرفته در حوزه پیش‌بینی کوتاه مدت مصرف بار الکتریکی بر روی پیش‌بینی 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 مدت‌تری تا یک هفته ارائه کرده باشند دقت آن تا حد زیادی کاهش یافته است. در ضمن معماری‌های پیشنهاد شده برای پیش‌بینی کوتاه مدت مصرف بار الکتریکی عوامل پنهان تاثیرگذار دیگری نظیر وضعیت آب و هوا را دخیل نکرده‌اند. با توجه به این مسائل ، پژوهش‌های صورت گرفته نمی‌توانند تمام نیازمندی‌های 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 دوره‌ای مصرف روزانه و هفتگی، که دارای روابط پیچیده غیرخطی هستند به پیش‌بینی تغییرات مصرف بار کوتاه مدت دست یابیم، بدین منظور از یکی از کارآمدترین معماری‌های یادگیری عمیق، شبکه عصبی پیچشی[۱۱] (CNN) استفاده خواهیم کرد. این نوع از شبکه‌های عصبی دارای قابلیت استخراج الگو[۱۲] از داده‌های ورودی در زمان یادگیری هستند که با استفاده از آن می‌توان الگوهای گذشته مصرف بار الکتریکی در فصل‌ها و روزهای مختلف آن را شناسایی کرد. نوعی دیگر از معماری شبکه‌های عصبی عمیق، شبکه عصبی حافظه طولانی کوتاه-مدت[۱۳] (LSTM) از مدل‌های زیرمجموعه

[Downloaded from ieijqp.ir on 2026-11-04]
[DOR: 20.1001.1.23222344.1400.10.1.6.1]
[DOI: 10.52547/ieijqp.10.1.35]

شبکه‌های عصبی مکرر[۱۴] (RNN) است، معماری این شبکه به گونه‌ای است که دسترسی به تمامی مقادیر گذشته در سری‌های زمانی را مقدور می‌سازد. با توجه به این قابلیت، می‌توان الگوهای استخراج شده از CNN را به همراه شرایط آب و هوای پیش‌بینی شده برای ساعات آینده (یا برخی اطلاعات تاثیرگذار دیگر مانند تاریخ فعلی) به عنوان ورودی به شبکه LSTM داده و پیش‌بینی کوتاه مدت مصرف بار را بدست آورد.

نوآوری های این پژوهش در موارد زیر خلاصه می‌شوند:

- ترکیب شبکه عصبی پیچشی و شبکه عصبی حافظه طولانی کوتاه-مدت با رویکرد یادگیری عمیق برای پیش‌بینی 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 پیش‌بینی مصرف بار الکتریکی تا ۱۶۸ ساعت آینده، بیشتر روش‌های پیش‌بینی کوتاه مدت بار الکتریکی پیش‌بینی مصرف را تا ۲۴ ساعت آینده انجام می‌دهند.

این مقاله شامل ۶ بخش است، پس از بخش مقدمه مبانی تحقیق می‌آید که مفاهیم بنیادی در شبکه‌های عصبی عمیق و مدل‌های بکار رفته از آن در این تحقیق و همچنین مفاهیم مربوط به سری‌های زمانی و پیش‌بینی مصرف بار الکتریکی را شرح میدهد. در بخش پیشینه تحقیق به بررسی پژوهش‌های صورت گرفته در پیش‌بینی کوتاه مدت مصرف بار الکتریکی، پرداخته می‌شود. فصل ۴ به ارایه روش پیشنهادی، [۱۵] CLSMNet ، که رویکردی برای پیش‌بینی کوتاه مدت مصرف بار الکتریکی است، می‌پردازد. بخش پیاده‌سازی و ارزیابی نتایج حاصل از CLSMNet را ارائه می‌کند و به مقایسه روش پیشنهاد شده با برخی دیگر از روش‌های جدید پیش‌بینی کوتاه مدت مصرف بار الکتریکی می‌پردازد. فصل آخر شامل نتیجه‌گیری 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، شبکه‌های عصبی پیچشی، شبکه‌های عصبی مکرر و شبکه‌های عصبی حافظه طولانی کوتاه-مدت پرداخته می‌شود. لازم به ذکر است که موارد یاد شده بلاک‌های سازنده روش پیشنهادی می‌باشند و به همین دلیل مروری مختصر بر آنها در این بخش می‌تواند مفید باشد.

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

مجموع بار تمامی مصرف کننده‌ها به اضافه تلفات شبکه، کل بار سیستم را تشکیل می‌دهد. منحنی مصرف بار برای مصرف کننده‌ها تا حدودی تصادفی و غیرخطی بوده و به درستی قابل پیش‌بینی نیست اما با وجود همه این شرایط عموما مصرف کننده‌ها یک روند و الگوی کلی ارائه می‌دهند که می‌توان آن را با روش‌های آماری پیش‌بینی کرد. عوامل اقتصادی و اقلیمی مانند دما ، رطوبت ، سرعت باد و زمان بر منحنی مصرف بار تأثیر می‌گذارد. با توجه به متغیر بودن مصرف بار الکتریکی، شرکت‌های تولید و توزیع کننده برق، موظف هستند با پیش‌بینی آن در زمان‌های گوناگون، اطلاعات مورد نیاز برای تصمیم‌گیری‌های درست و به‌موقع خود در سیستم تولید و توزیع برق فراهم نمایند.

۲-۲- شبکه‌های عصبی پیچشی

شبکه‌های عصبی پیچشی شباهت زیادی به شبکه‌های عصبی مصنوعی دارند و عموما از گونه‌ای از پرسپترون‌های چندلایه به‌منظور کمینه کردن پیش‌پردازش‌ها استفاده می‌کنند. این نوع شبکه‌ها متشکل از نرون‌هایی با وزن‌ها و بایاس‌های قابل یادگیری (تنظیم) هستند. هر نرون تعدادی ورودی دریافت کرده و سپس حاصل ضرب وزن‌ها در ورودی‌ها را محاسبه کرده و در انتها با استفاده از یک تابع تبدیل (فعال‌سازی) غیرخطی نتیجه را ارائه می‌دهد [۳۴]. این نوع شبکه‌ها معمولا یک تابع هزینه[۱۶] (مانند[۱۷] SVM یا Softmax) در لایه آخر (تماما متصل[۱۸]) دارند و تمامی نکات طراحی در مورد شبکه‌های عصبی معمولی در اینجا هم صادق است. CNNها معمولاً متشکل از لایه‌های کانولوشن، لایه‌های pooling و لایه تماماً مرتبط هستند. هدف عملیات کانولوشن استخراج الگوهای موجود در داده‌های ورودی است و با افزایش تعداد لایه‌ها شبکه قادر به استخراج الگوهای پیچیده‌تر بر اساس الگوهای قبلی می‌باشد. به طور کلی ویژگی‌های استخراج شده از لایه کانولوشن دارای ابعاد زیادی هستند که تعداد آنها با استفاده از لایه pooling کاهش داده می‌شوند، در نهایت لایه تماماً متصل تمامی ویژگی‌های محلی را با یکدیگر ترکیب کرده و ویژگی نهایی را به‌عنوان خروجی تولید می‌کند [۳۴].

ورودی لایه کانولوشن معمولاً به صورت سه‌بعدی است که شامل طول، عرض و تعداد کانال‌ها است. در لایه اول، ورودی‌ها با مجموعه‌ای از فیلترهای سه بعدی ترکیب می‌شوند و نگاشت ویژگی‌های خروجی را تولید می‌کنند. برای به‌دست آوردن نگاشت ویژگی‌های لایه اول از ورودی تک بعدی $x=(x_t)_{t=0}^{N-1}$ با اندازه N ، ترکیب فیلترهای w_h^1 که در آن $h=1,...,M_1$ با ورودی‌ها رابطه زیر را خواهیم داشت:

$$a^1(i,h)=(w_h^1 * x)(i)=\sum_{j=-\infty}^{\infty} w_h^1(j)x(i-j) \qquad (۱)$$

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

$$a^l(i,h)=(w_h^l * f^{l-1})(i)= \sum_{j=-\infty}^{\infty}\sum_{m=1}^{M_{l-1}} w_h^l(j,m)f^{l-1}(i-j,m) \qquad (۲)$$

[Downloaded from ieijqp.ir on 2026-11-04]
[DOR: 20.1001.1.23222344.1400.10.1.6.1]
[DOI: 10.52547/ieijqp.10.1.35]

۲-۳- شبکه‌های عصبی مکرر

شبکه‌های عصبی مکرر کلاسی از شبکه‌های عصبی عمیق هستند که به صورت یک گراف جهت‌دار چرخه‌ای[۲۰] بیان می‌شوند. به عبارت دیگر ورودی یا خروجی هریک از لایه(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 $f(.)$ و $g(.)$ نیز توابع غیرخطی را نشان می‌دهند.

متاسفانه RNNها در طول زمان‌های یادگیری طولانی با مشکلات انفجار گرادیان[۲۱] و یا محو شدن گرادیان[۲۲] 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 ۱۹۹۷ارائه 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[۲۳] است که LSTM را قادر به حذف یا اضافه کردن اطلاعات جدید به وضعیت سلول می‌کند. این عمل توسط ساختارهای دقیقی با نام دروازه[۲۴] 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[۲۵] 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 به‌عنوان دروازه ورودی و F_t را به‌عنوان 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:

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

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 درنگاشت 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 ارایه شده است [۳۳]. سپس یک شبکه چند لایهGRU[۲۶] وBPNN[۲۷] سنتی برای پیش‌بینی بار به‌کارگرفته شده است.

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

[Downloaded from ieijqp.ir on 2026-11-04]
[DOR: 20.1001.1.23222344.1400.10.1.6.1]
[DOI: 10.52547/ieijqp.10.1.35]

یعنی CRBM[۲۸] و CRBM[۲۹] ارائه داده‌اند [۳۸]. CRBM یک مدل احتمالی برای مدل‌سازی فعالیت انسان‌ها، داده‌های آب و هوایی و دسته‌بندی داده‌های سری‌های زمانی است. در FCRBM، که مدلی تعمیم یافته از CRBM است، فاکتورهایی جهت شبیه‌سازی فعالیت‌های متعدد انسان اضافه شده است.

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

بینکوفسکی و همکاران یک مدل مبتنی بر CNN با نام SO-CNN را پیشنهاد می‌کنند که گسترش شبکه پیچشی از مدل‌های خودهمبسته[۳۰] استاندارد است و از یک مکانیزم وزن‌گذاری غیرخطی استفاده می‌کند [۲۳]. در واقع در این مدل، وزنها با آموزش آنها از طریق CNN، مجاز هستند که وابسته به داده‌ها باشند.

۲-۳- روش‌های مبتنی بر LSTM

ژانگ و همکاران روشی برای بهبود پیش‌بینی کوتاه مدت مصرف بار با نام سری‌های زمانی چندگانه پیشنهاد داده‌اند که ترکیبی از اطلاعات کلان و خرد سری‌های زمانی پیوسته و گسسته است [۲۴]. سپس، شبکه‌های LSTM و GRU طراحی شده‌اند که می‌توانند اطلاعات سری‌های زمانی پیوسته و گسسته را آموخته و عملیات پیش‌بینی بار را انجام دهند.

پژوهشگران در مقاله [۲۵] به بررسی عملکرد روش‌های یادگیری عمیق با استفاده از شبکه‌های عصبی RNN در پیش‌بینی کوتاه مدت مصرف بار می‌پردازند. محققین برای انجام بررسی‌های خود از معماری شبکه عصبی مکرر استفاده کرده‌اند که در دو حالت عمیق و کم عمق استفاده شده است.

کنگ و همکاران استفاده از شبکه LSTM را برای مشکل SLTF پیشنهاد کردند [۲۶]. در ابتدا، یک مدل خوشه‌بندی مبتنی بر تراکم برای ارزیابی ناسازگاریهای موجود در بار الکتریکی بکار گرفته می‌شود. سپس، شبکه LSTM با دو لایه پنهان برای پیش‌بینی 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 شبکهLSTM ، نویسندگان از دو الگوریتم فرا ابتکاری PSO[۳۱] و GA[۳۲] استفاده می‌کنند.

ژنگ و همکاران روشی برای پیش‌بینی مصرف بار بر اساس یک شبکه LSTM ساده ارائه می‌کنند [۴۰]. این مدل می‌تواند توالی و وابستگی‌های بلندمدت زمانی سری بارهای الکتریکی را بیاموزد. رویکرد ارائه شده با برخی از روش‌های متداول پیش‌بینی سری‌های زمانی مانند ARIMA[۳۳] مقایسه شده است.

محققان در مقاله [۲۱] روشی مبتنی بر رمزگذارهای خودکار انباشته[۳۴] و شبکه عصبی GRU جهت پیش‌بینی کوتاه مدت مصرف بار الکتریکی ارائه داده‌اند. شبکه پیشنهادی به سه بخش لایه SAE، لایه GRU و لایه خروجی تقسیم شده است. در لایه SAE ابتدا داده‌های ورودی به شبکه فشرده شده و سپس جهت آموزش به لایه GRU داده می‌شوند و در نهایت مصرف بار پیش‌بینی شده تولید می‌شود.

وانگ و همکاران یک روش پیش‌بینی برای مصرف انرژی دوره‌ای بر اساس LSTM ارائه داده‌اند [۴۱]. حالت تناوبی رویکرد مورد نظر یک تغییر نوسانی در سری‌های زمانی مربوط به یک روند طولانی مدت است.

۳-۳- روش‌های 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 می‌گیرد [۲۸]. LSTNet از ترکیب CNN و LSTM برای به‌کارگیری نقاط قوت هر دو استفاده می‌کند، لایه کانولوشن برای استخراج الگوهای محلی وابسته از متغیرهای ورودی چند بعدی و لایه LSTM برای دستیابی به وابستگی‌های بلند مدت پیچیده.

محققان در مقاله [۲۹] مدلی متشکل از سه لایه موازی کانولوشن یک بعدی را پیشنهاد داده‌اند. استفاده از کامپوننت‌های CNN به صورت موازی که هر کدام دارای فیلترهایی با اندازه‌های متفاوت هستند، توانایی استخراج الگوهای غنی‌تر را به شبکه می‌دهد. 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 خوشه‌بندی K-means می‌توان برای پیش‌بینی بار کوتاه مدت که منجر به بهبود مقیاس‌پذیری نیز می‌شود، استفاده کرد [۴۲]. خوشه‌بندی K-means برای تقسیم مجموعه داده‌ها به زیر مجموعه‌های آموزش و آزمایش اعمال می‌شود و سپس شبکه CNN با به‌کارگیری این زیر مجموعه‌ها برای ساخت مدل پیش‌بینی آموزش داده می‌شود.

گوپتا و همکاران رویکرد سری زمانی دوگانه را انتخاب کرده‌اند، یکی برای رویکرد پارامتری و دیگری برای غیرپارامتری [۴۳]. برای رویکرد پارامتری، از رگرسیون XGBoost[۳۵] استفاده کرده‌اند که مبتنی بر GBDT[۳۶] است. برای رویکرد غیرپارامتری نیز شبکه LSTM در نظر گرفته شده است تا وابستگی‌های طولانی مدت بین داده‌های فعلی و قبلی را تدوین کند.

جهت پیش‌بینی دقیق‌تر مصرف بار الکتریکی رویکردی بر اساس ماشین‌های یادگیرنده مکرر مفرط[۳۷] توسط ارتوگرول پیشنهاد شده است [۲]. ELM یک رویه یادگیری خاص برای شبکه عصبی تک لایه پنهان پیش‌خور[۳۸] است.

[Downloaded from ieijqp.ir on 2026-11-04]
[DOR: 20.1001.1.23222344.1400.10.1.6.1]
[DOI: 10.52547/ieijqp.10.1.35]

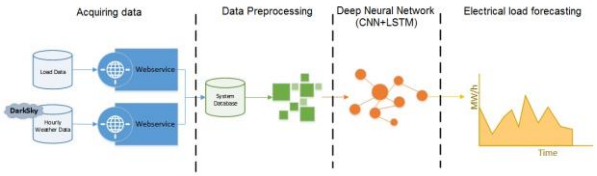
ونجی و همکاران یک شبکه یکپارچه مبتنی بر LSTM طراحی کرده‌اند که از نگاشت خودسازمانده[۳۹] و الگوریتم بهینه‌سازی هوشمند استفاده می‌کند [۳۰]. از SOM برای کاهش پیچیدگی منحنی بار در کلاس‌های مشابه استفاده شده است. همچنین یک بهینه‌سازی هوشمند برای دستیابی سریع‌تر به وزن‌های بهینه محلی در LSTM به‌کارگرفته شده 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 ۱،۹۱۴،۰۷۵ رکورد از اردیبهشت ۱۳۹۵ تا تیر ۱۳۹۶ می‌باشد که فیلدهای آن در جدول ۲ نشان داده شده است.

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

[Downloaded from ieijqp.ir on 2026-11-04]
[DOR: 20.1001.1.23222344.1400.10.1.6.1]
[DOI: 10.52547/ieijqp.10.1.35]

جدول (۱): خلاصه پژوهش‌های بررسی شده

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

[Downloaded from ieijqp.ir on 2026-11-04]
[DOR: 20.1001.1.23222344.1400.10.1.6.1]
[DOI: 10.52547/ieijqp.10.1.35]

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.

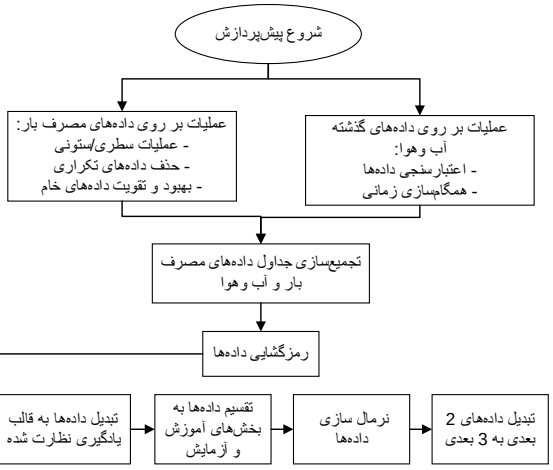
جدول (۳): داده‌های وضعیت آب و هوا

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

۲-۴- 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.

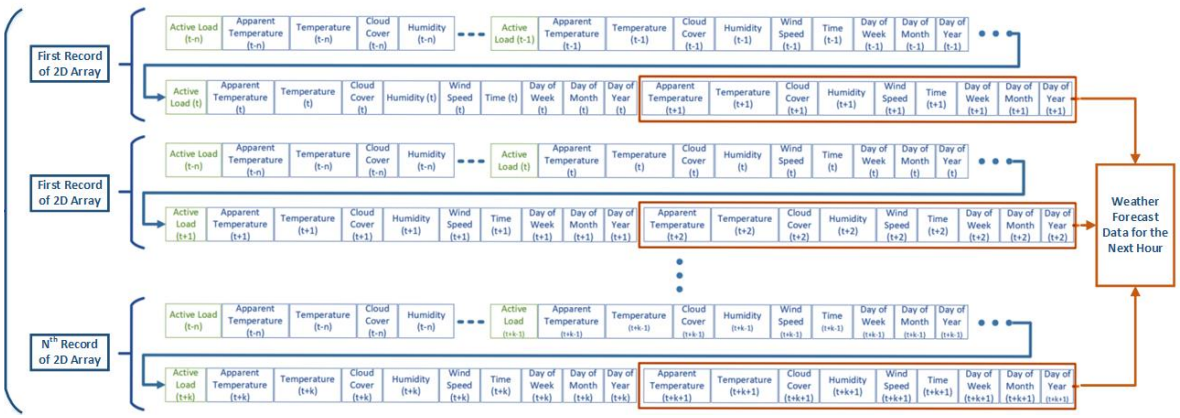


شکل (۲): جریان کار فاز پیش‌پردازش داده‌ها

از طرفی، آرایه y جهت نگهداری مقادیر در ست بار اکتیو ساعت بعد تولید می شود. 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



شکل (۳): ساختار داده سری زمانی

[Downloaded from ieijqp.ir on 2026-11-04]
[DOR: 20.1001.1.23222344.1400.10.1.6.1]
[DOI: 10.52547/ieijqp.10.1.35]

۳-۴- معماری شبکه عصبی عمیق

CLSMNet از ترکیب دو شبکه عصبی عمیق تشکیل شده است: CNN و LSTM. از معماری‌های CNN و LSTM به ترتیب برای استخراج الگوهای موجود در داده‌ها و پیش‌بینی میزان مصرف بار در ساعت‌های بعدی استفاده می‌شود.

بخش CNN در CLSMNet از سه ردیف موازی متشکل از دو لایه کانولوشن تشکیل شده است. استفاده از کامپوننت‌های CNN به صورت موازی که هر کدام دارای فیلترهایی با اندازه‌های متفاوت هستند، توانایی استخراج الگوهای غنی‌تر را به شبکه می‌دهد. شبکه‌های عصبی CNN با تفکر اتصالات محلی بوجود آمده‌اند. هر نود فقط به یک بخش محلی از ورودی متصل است. با جایگزین کردن جمع وزن‌های شبکه عصبی با عملیات کانولوشن می‌توان به اتصال محلی دست یافت. در هر لایه از CNN ، عملیات کانولوشن بین ورودی‌ها و ماتریس وزن‌ها (یا همان فیلترها) اعمال می‌شود که نگاشت ویژگی‌ها را تولید می‌کند.

در معماری پیشنهاد شده تمامی نرون‌های داخل هر لایه با احتمال از پیش تعیین شده‌ای Dropout می‌شوند. 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 می‌کند. در نهایت خروجی سه CNN موازی با استفاده از Concatenate با یکدیگر ادغام شده و به بخش LSTM داده می‌شود.

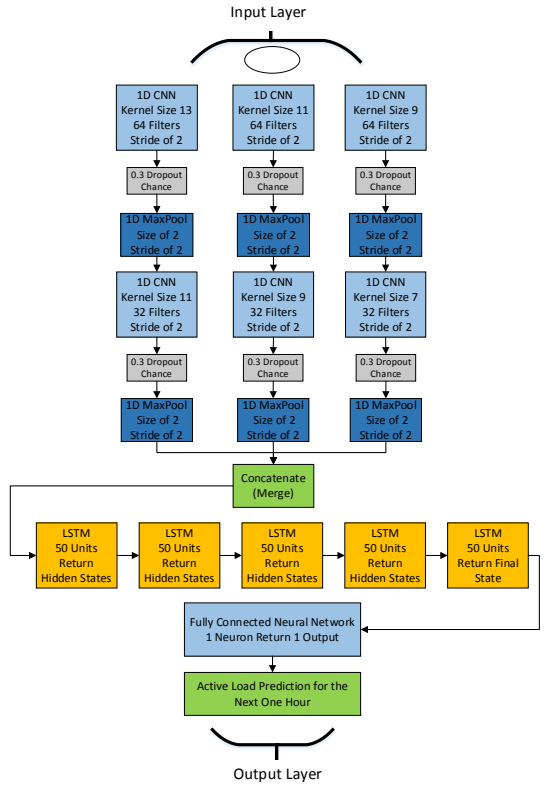
همانطور که در شکل ۴ نشان داده شده است اندازه فیلترهای CNN در لایه اول به ترتیب ۹، ۱۱و ۱۳ است و تعداد فیلترها برای تمامی CNNهای این لایه ۶۴ می‌باشد. اندازه‌های فیلترهای لایه دوم به ترتیب برابر ۷، ۹ و ۱۱ هستند و تعداد فیلترها برای تمامی CNNهای این لایه نیز ۳۲ است. همچنین گام حرکتی[۴۰] تمامی فیلترها برابر ۲ می‌باشد و متغیر احتمال Dropout نرون‌های CNN، ۳۰ درصد تعیین شده‌اند. تمامی لایه‌های Max Pool نیز دارای گام حرکتی ۲ و اندازه آن‌ها نیز برابر ۲ می‌باشد.

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

$$O_t = \sigma_t \times tanh\,(C_t) \qquad (۸)$$

x_t ورودی در زمان t است و h_t وضعیت مخفی نرون می‌باشد که برداری حاوی تمامی ورودی‌های مشاهده شده تا زمان t است.

با تغذیه دنباله $\{x_1, x_2, ..., x_n\}$ به LSTM، خروجی‌های وضعیت مخفی $\{h_1, h_2, ..., h_n\}$ بدست خواهد آمد. خروجی‌های بدست آمده به LSTM دیگری داده شده و دنباله جدید از وضعیت‌های مخفی تولید خواهد شد و در نهایت آخرین لایه LSTM خروجی دنباله $\{h_1, h_2, ..., h_n\}$ را از لایه قبلی دریافت کرده و یک مقدار نهایی را تولید می‌کند که این خروجی نهایی در واقع پیش‌بینی بار اکتیو برای گام زمانی بعد است. شکل ۴ معماری شبکه ترکیبی پیشنهادی در CLSMNet را نشان می‌دهد.



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

برای دستیابی به وزن‌های بهینه شبکه از الگوریتم بهینه سازی Adam [۴۴] استفاده شده که در شبه‌کد ۲ نمایش داده شده است.

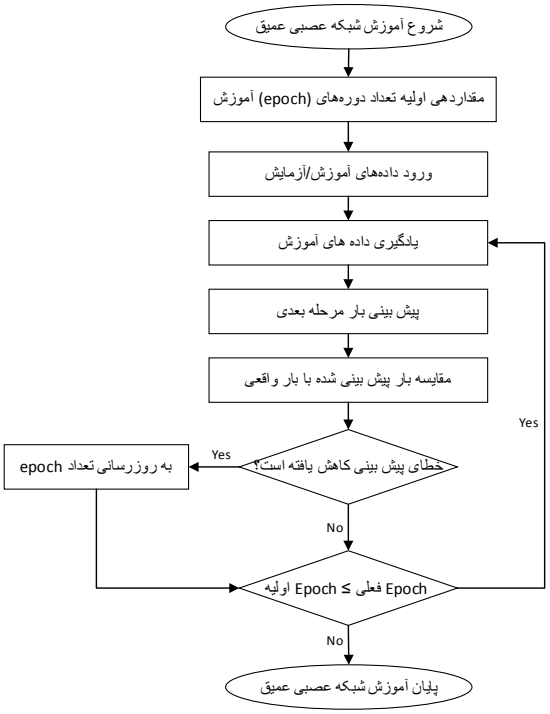
Function Adam $(\alpha, \beta_1, \beta_2, f(\theta), \theta_0, m_0, v_0, t)$
Input: α — Step-size
Input: $\beta_1, \beta_2 \in [0,1)$ — Exponential decay rates for the moment estimates
Input: $f(\theta)$ — Stochastic objective function with parameters θ
Input: θ_0 — Initial parameter vector
$m_0 \leftarrow 0$; — Initialize 1st moment vector
$v_0 \leftarrow 0$; — Initialize 2nd moment vector
$t \leftarrow 0$; — Initialize time-step
Output: θ_t — Resulting parameters
while θ_0 not converged **do**
$t \leftarrow t + 1$
$g_t \leftarrow \nabla_\theta f_t(\theta_{t-1})$ — Get gradients w.r.t stochastic objective at time-step t
$m_t \leftarrow \beta_1 \times m_{t-1} + (1 - \beta_1) \times g_t$ — Update biased first moment estimate
$v_t \leftarrow \beta_2 \times v_{t-1} + (1 - \beta_2) \times g_t^2$ — Update biased second raw moment estimate
Compute bias-corrected first moment estimate
Compute bias-corrected second raw moment estimate
Update parameters
end while
Return θ_t — Resulting parameters

شبه‌کد (۲): الگوریتم بهینه‌سازی Adam

۴-۴- آموزش شبکه عصبی عمیق

در طول آموزش شبکه، داده‌های تجربی به شبکه وارد می‌شود تا دقت شبکه پیشنهادی در پیش‌بینی بار فعال ارزیابی شود. شکل ۵ فرآیند آموزش شبکه عصبی عمیق CLSMNet را نشان می‌دهد.

[Downloaded from ieijqp.ir on 2026-11-04]
[DOR: 20.1001.1.23222344.1400.10.1.6.1]
[DOI: 10.52547/ieijqp.10.1.35]



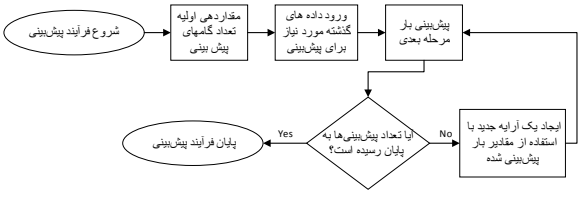
شکل (۵): فرآیند آموزش شبکه عصبی عمیق CLSMNet

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 برچسب‌ها 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 قبلا 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.

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*

$x \leftarrow inverse_transform(x)$	Transform scaled data to original scale
$y_{pred} \leftarrow inverse_transform(y_{pred})$	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
$x \leftarrow shift_window\ (x, 1)$	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 وهر 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 پیش بینی کوتاه مدت مصرف بار مقایسه می‌شود.

۵-۱- معیارهای سنجش دقت پیش‌بینی

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

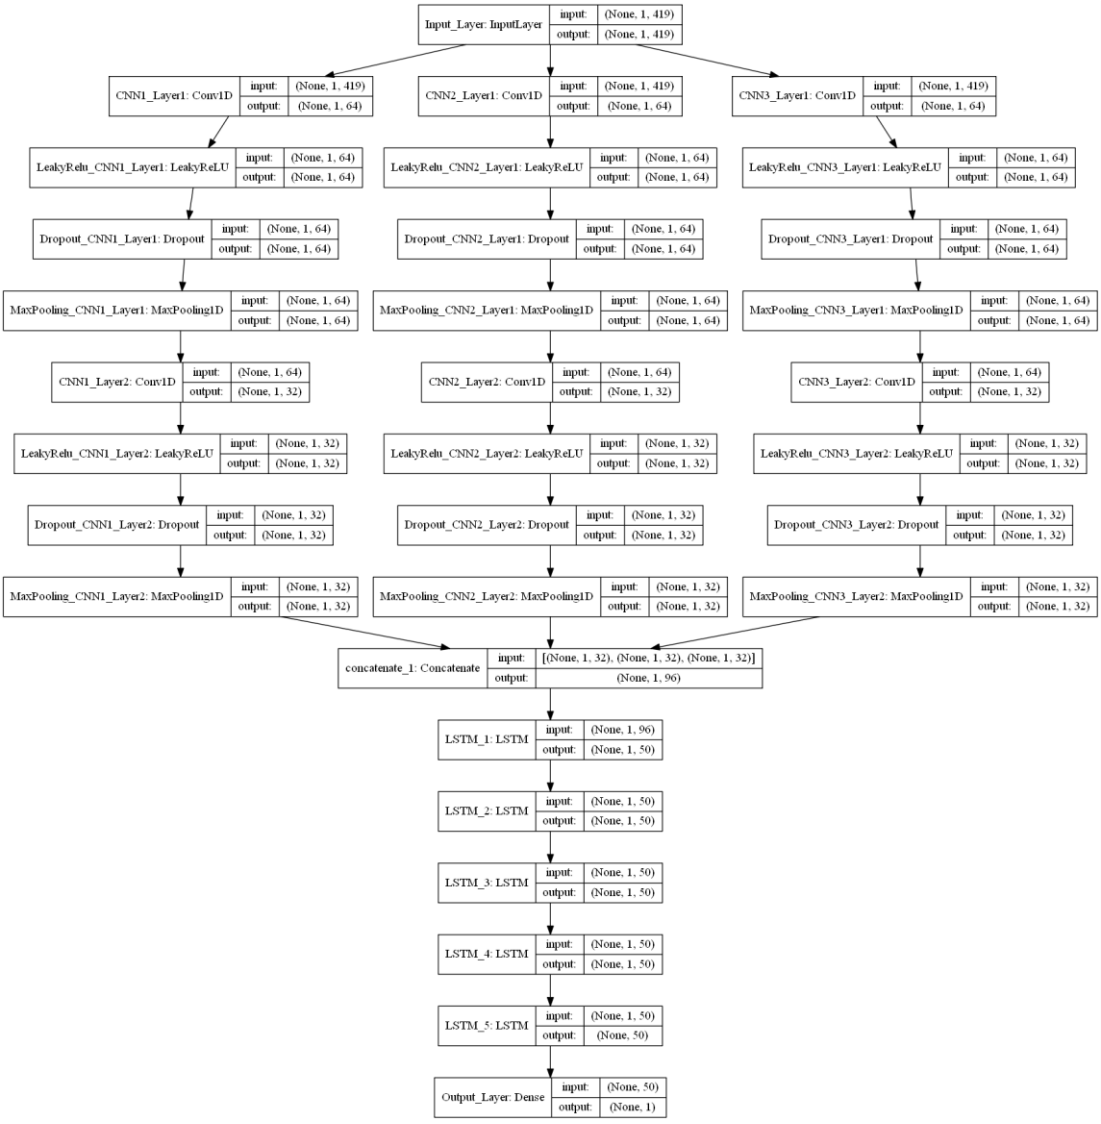
$$RMSE = \sqrt{\frac{1}{n}\sum_{i=1}^{n}(\hat{Y}_i - Y_i)^2} \qquad (۹)$$

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:

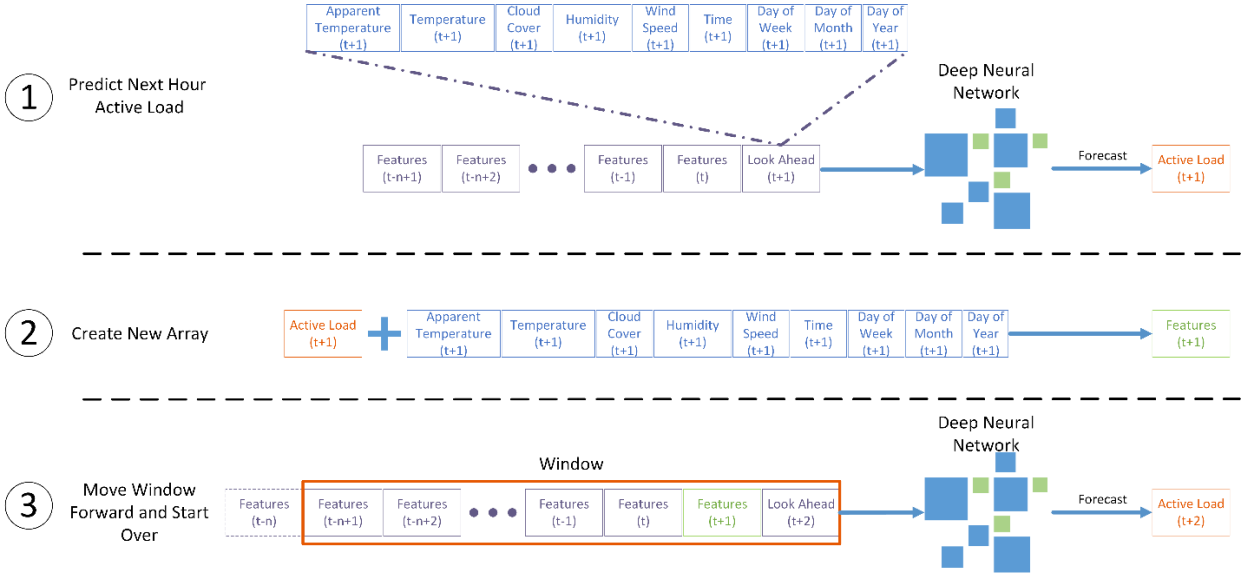
$$MAPE = \frac{1}{n}\sum_{i=1}^{n}\left|\frac{\hat{Y}_i - Y_i}{Y_i}\right| \qquad (۱۰)$$

علاوه بر این، به منظور مقایسه با سایر روشها از معیارهای ریشه مربعات نسبی خطا[۴۳] (RSE) و ضریب همبستگی تجربی[۴۴] (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:

[Downloaded from ieijqp.ir on 2026-11-04]
[DOR: 20.1001.1.23222344.1400.10.1.6.1]
[DOI: 10.52547/ieijqp.10.1.35]



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



شکل (۸): سری‌های زمانی برای تولید پنجره بعدی به منظور پیش‌بینی بار اکتیو

[Downloaded from ieijqp.ir on 2026-11-04]
[DOR: 20.1001.1.23222344.1400.10.1.6.1]
[DOI: 10.52547/ieijqp.10.1.35]

$$RSE = \sqrt{\frac{\sum_{i=1}^{n}(\hat{Y}_i - Y_i)^2}{\sum_{i=1}^{n}(Y_i - mean(Y))^2}} \quad (۱۱)$$

$$CORR = \frac{1}{n} \times \sum_{i=1}^{n} \frac{\sum_{i=1}^{n}(Y_i - mean(Y))(\hat{Y}_i - mean(\hat{Y}_i))}{\sqrt{\sum_{i=1}^{n}(Y_i - mean(Y))^2 \times \sum_{i=1}^{n}(\hat{Y}_i - mean(\hat{Y}_i)^2}} \quad (۱۲)$$

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

۵-۲- پیکربندی سخت‌افزار/نرم‌افزار

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

جدول۴ - 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.

جدول۵ - مشخصات سخت افزاری سیستم اجرایی

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

۵-۳- 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 (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.

جدول۶ - MAPE پیش‌بینی مصرف بار برای گام‌های زمانی مختلف

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

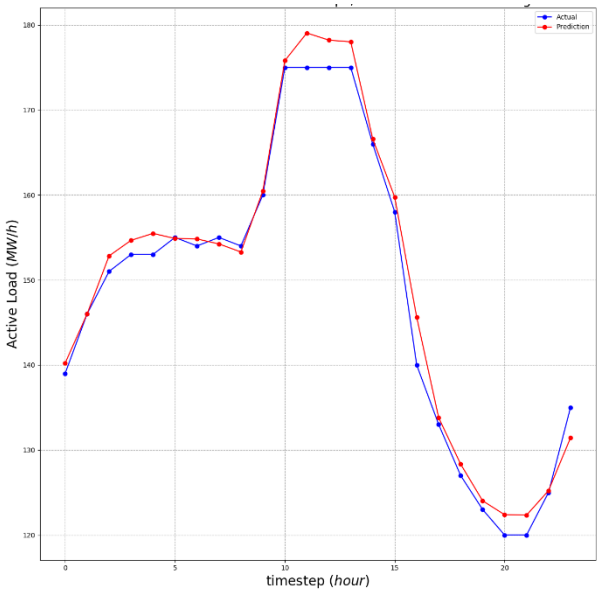
جدول۷ - RMSE پیش‌بینی مصرف بار برای گام‌های زمانی مختلف

اندازه پنجره اطلاعات	RMSE						
	۲۴	۴۸	۷۲	۹۶	۱۲۰	۱۴۴	۱۶۸
۴۰	**۱.۹۲۲**	**۲.۱۸۴**	**۲.۳۳۸**	۴.۰۷۶۴	۴.۵۸۱	۵.۵۷۷	۶.۸۶۲
۵۰	۴.۱۷۵	۳.۵۸۴	۳.۴۱۷	۴.۰۸۱۱	۶.۰۱۲	۸.۸۳۹	۹.۱۰۶
۶۰	۲.۶۷۳	۳.۳۵۵	۳.۳۵۹	**۳.۳۰۹**	۵.۱۸۰	۷.۰۵۶	۷.۱۸۵
۷۰	۳.۶۳۶	۴.۰۶۵	۳.۹۳۸	۳.۳۸۶	**۳.۸۲۱**	**۶.۱۳۹**	**۶.۴۵۵**
۹۰	۲.۶۴۲	۲.۴۸۳	۲.۶۲۵	۳.۹۳۱	۴.۱۴۲	۶.۱۴۶	۶.۵۷۷

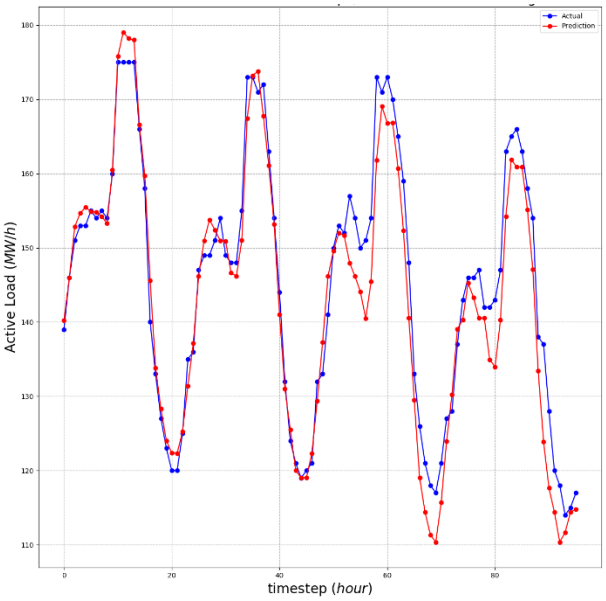
همانطور که در جداول فوق نشان داده شده است، اندازه پنجره اطلاعات ۴۰ در پیش‌بینی گام‌های زمانی ۲۴ و ۴۸ ساعت آینده (پیش بینی یک و دو روزه) بهترین MAPE و RMSE را نتیجه می‌دهد، در حالی که بهترین مقادیر MAPE و RMSE برای گام زمانی ۹۶ ساعت آینده (پیش بینی چهار روزه) از اندازه پنجره اطلاعات ۶۰ بدست می‌آید. درنهایت، 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.

[Downloaded from ieijqp.ir on 2026-11-04]
[DOR: 20.1001.1.23222344.1400.10.1.6.1]
[DOI: 10.52547/ieijqp.10.1.35]



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

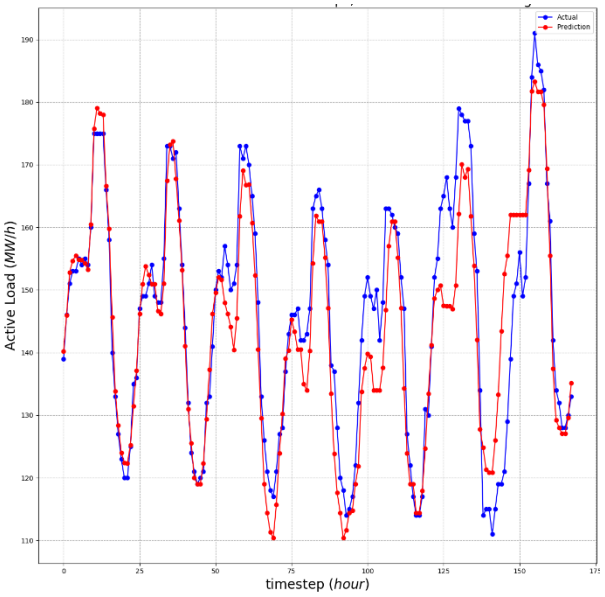


شکل (۱۰): پیش‌بینی مصرف بار برای ۹۶ گام زمانی آینده

۴-۵- مقایسه CLSMNet با روش‌های موجود

در این بخش، CLSMNet را با برخی از بهترین روش‌های موجود در پیش‌بینی کوتاه مدت مصرف بار مقایسه می‌کنیم تا جایگاه روش پیشنهادی در پژوهش‌های موجود دراین زمینه مشخص شود.

همانطور که در جدول ۱ مشخص شده است، بسیاری از روش‌های پیش‌بینی کوتاه مدت مصرف بار از مجموعه داده‌های اختصاصی برای ارزیابی استفاده می‌کنند. با این حال، تعدادی از روش‌ها نیز از مجموعه داده‌های در دسترس عموم بهره می‌برند. به منظور ارزیابی هر چه دقیق‌تر CLSMNet ، دو رویکرد فوق بطور همزمان انجام شده است. اول آنکه از داده‌های اختصاصی تهیه شده در این مقاله برای پیاده‌سازی روش‌های دیگر استفاده شده است. همچنین، به منظور از بین بردن هرگونه عدم تناقض یا بایاس احتمالی در مجموعه داده، CLSMNet با استفاده از یک مجموعه داده عمومی، که توسط بسیاری از مقالات استفاده شده است، نیز ارزیابی می‌شود.



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

برای نیل به هدف اول ارزیابی، چهار روش مختلف انتخاب شده است: MTS-RNN [۲۴]، CNN [۳۷]، LSTM-XG [۴۳] و LSTM-SOM [۳۰] که تمام آنها از شبکه‌های یادگیری عمیق برای افزایش دقت پیش‌بینی مصرف بار الکتریکی استفاده کرده‌اند. این رویکردها با استفاده از مجموعه داده مورد استفاده در CLSMNet پیاده‌سازی شده‌اند. دقت پیش‌بینی مصرف بار الکتریکی کوتاه مدت با در نظر گرفتن معیارهای MAPE و RMSE تجزیه و تحلیل شده است که نتایج مقایسه CLSMNet با روش‌های 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 پیش‌بینی کرده‌اند. بنابراین، برای مقایسه‌ای یکسان و عادلانه، تنها نتایج پیش‌بینی بار برای ۲۴ ساعت آینده در جدول ۸ منظور شده است.

جدول۸ – مقایسه CLSMNet با سایر رویکردها برای پیش‌بینی بار ۲۴ ساعت آینده با استفاده از مجموعه‌داده 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 پیش‌بینی بار الکتریکی ۲۴ ساعت آینده نسبت به روش‌های مقایسه شده نشان می‌دهد.

MTS-RNN از پنج ردیف موازی شبکه GRU استفاده می‌کند که هر ردیف آن دارای دو لایه است. ردیف‌های مختلف سری زمانی با ساختارهای متغیر برای پیش‌بینی بار به این شبکه منتقل می‌شوند. اما هیچ پردازشی برای استخراج ویژگی‌های مفید از مجموعه داده ورودی

[Downloaded from ieijqp.ir on 2026-11-04]
[DOR: 20.1001.1.23222344.1400.10.1.6.1]
[DOI: 10.52547/ieijqp.10.1.35]

صورت نگرفته است، در صورتی‌که 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 نگاشت‌های 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 XG- LSTM 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 نگاشت‌های 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[۴۷] استفاده می‌کند [۴۷]. TRMF برای تنظیم این ساختار زمانی در 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 جهشیRNN [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.

جدول۹ – 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 LSTM 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 به‌کار 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 می تواند 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.

[Downloaded from ieijqp.ir on 2026-11-04]
[DOR: 20.1001.1.23222344.1400.10.1.6.1]
[DOI: 10.52547/ieijqp.10.1.35]

در VAR-MLP از مدل خطی ARIMA (میانگین متحرک یکپارچه AR) و مدل غیرخطی ANN با هدف استخراج اشکال مختلف روابط در داده‌های سری زمانی به طور مشترک استفاده می‌شود. در حقیقت، هر دو رویکرد AR و VAR-MLP روش‌های بنیادی هستند که بسیاری از مدل‌های پیش‌بینی مبتنی بر یادگیری عمیق از آنها به عنوان روش‌های پایه‌ای برای مقایسه استفاده می‌کنند تا نشان دهند شبکه‌های عصبی عمیق چگونه می‌توانند اثربخشی و دقت پیش‌بینی بار را بهبود بخشند.

۶- نتیجه‌گیری و کارهای آینده

پژوهش‌های مرتبط با پیش‌بینی مصرف بار الکتریکی، هم از سوی دانشگاها و مؤسسات پژوهشی و هم از سمت صنایع، مورد توجه بسیاری در سال‌های اخیر قرار گرفته است. اگرچه هنوز در بسیاری از مراکز از روش‌های سنتی و مرسوم برای پیش‌بینی مصرف بار الکتریکی استفاده می‌شود، اما این رویکردها در ارائه یک پیش‌بینی موثر و دقیق کارآمدی لازم را ندارند. با توجه به تأثیر پیش‌بینی کوتاه مدت در میزان خاموشی‌های رخ داده و سلامت تجهیزات توزیع و انتقال، روش‌ها سنتی به تدریج با رویکردهای مدرن‌تر مانند شبکه‌های عصبی عمیق جایگزین می شوند.

روش پیشنهادی، CLSMNet، یک رویکرد شبکه عصبی ترکیبی است که از تکنیک‌های یادگیری عمیق با ترکیب معماری‌های CNN و LSTM بهره می‌گیرد. CNN و LSTM به ترتیب برای استخراج الگوهای موجود در داده‌های ورودی و پیش‌بینی مصرف بار در ساعات بعدی استفاده شده‌اند. CLSMNet برای پارامترهای پیکربندی شبکه مانند تعداد لایه‌های شبکه و نرون‌ها و همچنین اندازه فیلتر بهینه شده است. CLSMNet قادر است میزان بار الکتریکی را با دقت مناسب تا ۱۶۸ ساعت (یک هفته) پیش‌بینی کند، در حالی که اکثر روش‌های پیش‌بینی بار الکتریکی کوتاه مدت تنها قادر به پیش‌بینی تا ۲۴ ساعت آینده هستند. روش پیشنهادی با برخی از بهترین روش‌های موجود در پیش‌بینی کوتاه مدت مصرف بار الکتریکی مقایسه شده است. نتایج ارزیابی نشان دهنده بهبود دقت در پیش‌بینی بر اساس پارامترهای MAPE، RMSE، RSE وCORR می‌باشد.

پژوهش‌های زیر می‌تواند به عنوان کارهای آینده در نظر گرفته شود:

- استفاده از یادگیری عمیق در هوشمندسازی سیستم‌های تعمیر و نگهداری پیشگیرانه جهت پیش‌بینی زمان‌های سرویس و جلوگیری از خرابی‌های تجهیزات توزیع و انتقال.
- تکمیل مجموعه داده آموزش شبکه با تعطیلات رسمی و برخی از رویدادهای مهم تاثیرگذار در مصرف بار و سپس بررسی میزان تاثیرگذاری اطلاعات اضافه شده در بهبود دقت پیش‌بینی‌ها.
- توسعه انواع دیگری از شبکه‌های عصبی عمیق، به ویژه در مراحل استخراج و یادگیری ویژگی‌ها 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. ۱۳-۳۳, 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 Managemen, 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.

[Downloaded from ieijqp.ir on 2026-11-04]
[DOR: 20.1001.1.23222344.1400.10.1.6.1]
[DOI: 10.52547/ieijqp.10.1.35]

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*

[Downloaded from ieijqp.ir on 2026-11-04]

[DOR: 20.1001.1.23222344.1400.10.1.6.1]

[DOI: 10.52547/ieijqp.10.1.35]

[۴۱] 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.

[۴۸] Zhang, G P., *"Time series forecasting using a hybrid ARIMA and neural network model"*, Neurocomputing, Vol. ۵۰, pp. ۱۵۹–۱۷۵, ۲۰۰۳.

زیرنویس‌ها

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

[Downloaded from ieijqp.ir on 2026-11-04]
[DOR: 20.1001.1.23222344.1400.10.1.6.1]
[DOI: 10.52547/ieijqp.10.1.35]