

## پیش‌بینی کوتاه مدت مصرف بار الکتریکی با استفاده از یک ساختار یادگیری عمیق مبتنی بر گراف

مهتاب گنججوری<sup>۱</sup>، مزدا معطری\*<sup>۲</sup>، احمد فروزان تبار<sup>۳</sup>، محمد آزادی<sup>۴</sup>

۱- دانشجوی دکتری، دانشکده مهندسی برق، واحد مرودشت، دانشگاه آزاد اسلامی، مرودشت، ایران mahtab.ganjouri@miau.ac.ir

\*۲- استادیار، دانشکده مهندسی برق، واحد مرودشت، دانشگاه آزاد اسلامی، مرودشت، ایران moattari@miau.ac.ir

۳- استادیار، دانشکده مهندسی برق، واحد مرودشت، دانشگاه آزاد اسلامی، مرودشت، ایران a.forouzantabar@miau.ac.ir

۴- استادیار، دانشکده مهندسی، واحد مرودشت، دانشگاه آزاد اسلامی، مرودشت، ایران mazadi@miau.ac.ir

تاریخ پذیرش: ۱۳۹۹/۱۱/۱

تاریخ دریافت: ۱۳۹۹/۸/۱

**چکیده:** پیش‌بینی بارهای الکتریکی یک عملیات ضروری برای برنامه‌ریزی مدیریت مصرف در سیستم‌های قدرت به شمار می‌رود. با پیدایش فناوری‌های جدید در سیستم‌های قدرت، رشد سریع صنایع مبتنی بر انرژی الکتریکی و افزایش بی‌رویهی جمعیت، مسئله‌ی پیش‌بینی کوتاه مدت بار مصرفی شکل جدیدی به خود گرفته است. در این مقاله یک ساختار یادگیری عمیق بر مبنای گراف برای پیش‌بینی کوتاه مدت بار ارائه شده است. این ساختار پیشنهادی از سه قسمت اصلی تشکیل شده است. از شبکه‌های عصبی کانولوشنی (CNN) برای یادگیری مشخصات مکانی، از ساختار دو طرفه حافظه‌ی بلند کوتاه مدت (BLSTM) برای یادگیری کامل مشخصات زمانی سری زمانی بار مصرفی و یک ساختار انکودر-دکودر عمیق برای افزایش قدرت یادگیری مشخصات سری زمانی بار از داده‌های خام بار مصرفی پیشین استفاده شده است. این ساختار به صورت یک ساختار مبتنی بر گراف طراحی شده است تا با یادگیری تاثیرات مشخصاتی اقلیمی همچون رطوبت، دما و فشار هوا بر روی بار مصرفی، دقت مطلوبی برای پیش‌بینی بارهای مصرفی داشته باشد. برای ارزیابی نتایج از داده‌های پیشین واقعی شهر شیراز، ایران استفاده شده است. برای این که موثر بودن و برتری روش پیشنهادی نشان داده شود، تکنیک پیشنهادی در پیش‌بینی فصل‌های مختلف و در طول یک سال و همچنین، تاثیرگذاری مشخصات اقلیمی بر روی بارهای مصرفی مورد ارزیابی و مقایسه با روش‌های متنوعی بر مبنای یادگیری عمیق و روش‌های مبتنی بر یادگیری ماشین مختلف و با استفاده از نرم‌افزار python مقایسه شده است.

**واژه‌های کلیدی:** انکودر-دکودر، دو طرفه حافظه‌ی بلند کوتاه-مدت، پیش‌بینی کوتاه مدت بار مصرفی، شبکه‌ی عصبی کانولوشنی، یادگیری عمیق بر مبنای گراف

### ۱- مقدمه

[۱]، مخصوصاً بارهای الکتریکی که تحت تاثیر عادات‌های اجتماعی مصرف‌کنندگان، رویدادهای فرهنگی و پدیده‌های آب و هوایی قرار می‌گیرند [۳].  
در مطالعات پیشین، روش‌های پیش‌بینی بار را می‌توان به چهار گروه اصلی شامل روش‌های پایدار، فیزیکی، آماری و روش‌های هوشمند می‌باشند [۲].

پیش‌بینی بار یک وظیفه‌ی ضروری در سیستم قدرت به شمار می‌رود. بدون داشتن بار مصرفی در ساعات آتی، تامین با کیفیت انرژی الکتریکی غیرممکن است [۱]. با ظهور مفاهیم جدیدی همچون شبکه‌های هوشمند و ریزشبکه‌ها در کنار افزایش سطح نفوذ منابع انرژی تجدیدپذیر و افزایش شدید بار مصرفی مسئله‌ی پیش‌بینی بار را به یک چالش اساسی در شبکه‌های مدرن قدرت تبدیل نموده است

اشاره نمود. اگرچه روش‌های ترکیبی عملکرد به نسبت رضایت‌بخشی از خود نشان داده‌اند، اما با توجه به این که قابل‌تعمیم به عنوان یک روش کلی نیستند و همچنین، بار محاسباتی را افزایش می‌دهند و نیاز به سخت‌افزار اضافی در پیاده‌سازی عملی دارند، را نمی‌توان به عنوان راه‌کار مطلوب برای پیش‌بینی بارهای الکتریکی در کوتاه مدت در نظر گرفت.

یادگیری عمیق به عنوان یک مفهوم انقلابی توجهات بسیاری را در زمینه‌های مختلف علوم بشری به خود جلب نموده است. این روش‌های هوشمند قادر هستند که مشخصات پیچیده و غیرخطی را از یکدیگر متمایز نموده و به خوبی درک نمایند. از این رو این قابلیت را دارند که بر مبنای توانایی یادگیری خود، دقت پیش‌بینی کوتاه مدت بار را بهبود بخشند. روش‌های یادگیری عمیق که در پیش‌بینی سری‌های زمانی کاربرد دارند را می‌توان به پنج گروه، انکودرهای خودکار (AE)، ماشین‌های بولتزمن عمیق (DBM)، شبکه‌های عصبی بازگشتی (RNN)، شبکه‌های عصبی کانولوشنی (CNN) و شبکه‌های مولد متخاصم (GAN) دسته‌بندی نمود [۱۸]. به عنوان نمونه، دو مدل بر مبنای AE و DBM به ترتیب در [۱۹] و [۲۰] برای پیش‌بینی بارهای الکتریکی ارائه شده‌اند. اگرچه که روش‌های AE و DBM قادر به یادگیری از داده‌های خام به صورت مستقیم با استفاده از یک فرآیند کاهش ابعاد می‌باشد، اما ایراد عمده آن‌ها عدم قادر یادگیری در پوشش کامل مشخصات زمانی (تغییرات در بازه‌ی زمان) و مشخصات مکانی (مکان‌های مختلف که داده‌ها از آن گرفته می‌شود). دچار مشکل هستند. روش GAN یک تولیدکننده‌ی داده‌های مصنوعی است که نمی‌تواند به صورت مستقیم در پیش‌بینی به کار گرفته شود، از این رو با روش‌های دیگر مانند CNN [۲۱] ادغام شود. اگرچه تعداد داده‌های بالایی که چه به صورت مصنوعی تولید شوند و چه در مجموعه‌ی داده‌ها موجود باشند برای بالا بردن قدرت یادگیری مفید است، این عمل می‌تواند به بیش‌برازش منجر شود. همچنین، با توجه به افزایش سیستم‌های اندازه‌گیری در سیستم‌های قدرت امروزی داده‌ی کافی از بار مصرفی و اطلاعات اقلیمی موجود است و استفاده از یک تکنیک تولید داده‌ی مصنوعی همانند GAN تنها بار محاسباتی را بالا می‌برد و کارایی را چندان بالا نمی‌برد. روش دیگری از مجموعه روش‌های مبتنی بر یادگیری عمیق، CNN است که در تحلیل سری‌های زمانی به کار گرفته می‌شود، هر چند CNN به عنوان یک ابزار قدرتمند در استخراج ویژگی‌های مکانی محسوب می‌شود، اما در یادگیری مشخصه‌های زمانی چندان توانمند نیست. روش‌های RNN همانند حافظه بلند کوتاه مدت (LSTM) و واحد بازگشتی دروازه‌دار (GRU) ابزار مطلوبی در استخراج مشخصات زمانی و یادگیری این مشخصات هستند. هر چند این دو روش ابزار کاملاً مطلوبی برای یادگیری مشخصات مکانی نیستند. با توجه به این که در یک مسئله‌ی پیش‌بینی بار، علاوه بر این که اطلاعات بارهای مصرفی از مکان‌های مختلف استخراج می‌شوند و با داده‌های محیطی نیز برای بهبود دقت باید ادغام شوند، مشخصات مکانی نقشی کلیدی در آن‌ها دارند. از این

روش‌های پیش‌بینی بار پایدار بر اساس یک فرض ساده عمل می‌کنند. در این روش‌ها مقدار بار در زمان  $t$  دقیقاً برابر با مقدار  $t-1$  قرار داده شوند. در صورتی که افق زمانی پیش‌بینی بالا برود، دقت این روش شدیداً پایین می‌آید [۴].

روش‌های فیزیکی به دنبال یافتن یک مدل ریاضی برای مدل‌سازی رفتار بار الکتریکی در ساعات آتی باشد که این مدل ریاضی بر اساس داده‌های پیشین و داده‌های اقلیمی به دست می‌آیند. ادغام این داده‌ها باعث افزایش دقت مدل می‌شود، در حالی که بار محاسباتی را افزایش می‌دهد. به بیان دیگر، افزایش دقت در روش‌های فیزیکی نیازمند بار محاسباتی بسیار بالا و یک حافظه‌ی بلند مدت است. از این روش‌های فیزیکی برای پیش‌بینی کوتاه‌مدت ابزار مناسبی نیستند [۵].

روش‌های آماری که عمدتاً در خانواده‌ی روش‌های میانگین متحرک رگرسیون خودکار (ARMA) قرار دارند، این روش بر اساس خطای بین مقادیر واقعی در بازه‌های زمانی پیشین و ساعات بعدی آن یک رابطه‌ی خطی را استخراج می‌کنند. این رابطه‌ی خطی، نشان‌دهنده‌ی یک رابطه بین بار مصرفی در ساعات‌های آتی و حال حاضر است. اگرچه این روش‌ها بار محاسباتی کمی دارند، قادر به مدل‌سازی مطلوب ماهیت غیرخطی و پیچیده‌ی سری‌های زمانی بار نیستند [۶].

روش‌های هوشمند به عنوان یک پاسخ بالقوه برای مدل‌سازی و یادگیری سری‌های زمانی غیرخطی محسوب می‌شوند. تاکنون روش‌های بسیاری بر مبنای روش‌های هوشمند در تحقیقات پیشین ارائه شده است که می‌توان این روش‌ها را به دو دسته‌ی مدل‌های کم‌عمق و عمیق دسته‌بندی نمود.

بیشتر تحقیقات پیشین در زمینه‌ی پیش‌بینی کوتاه مدت بارهای الکتریکی بر روی مدل‌های کم‌عمق تمرکز نموده‌اند. به عنوان نمونه می‌توان به روش شبکه عصبی مصنوعی (ANN) [۷]، بردار پشتیبان ماشین (SVM) [۸]، روش جنگل تصادفی [۹]، شبکه‌ی عصبی موجک [۱۰] و ... اشاره نمود. اگرچه، یادگیری مشخصات غیرخطی از داده‌های خام به صورت مستقیم برای روش‌های کم‌عمق دشوار است. همچنین، از لحاظ فضای یادگیری با محدودیت مواجه هستند، به این دلیل که تعداد پارامترهای کمی در فضای یادگیری خود دارند [۱۱]. از این رو، روش‌های کم‌عمق قابلیت‌تعمیم‌پذیری به مجموعه داده‌های مختلف را ندارند. دو راه‌کار کلی برای غلبه بر این مشکل وجود دارد که شامل ترکیب این روش‌ها با روش‌های استخراج ویژگی و تکنیک‌های دیگر و استفاده از روش‌های یادگیری عمیق می‌باشد.

ادغام تکنیک‌های استخراج ویژگی همانند تکنیک‌های تحلیل طیف فرکانسی مثل تبدیل فوری [۱۲] و تبدیل موجک [۱۳] به عنوان راه‌کاری برای افزایش قدرت یادگیری در پیش‌بینی سری‌های زمانی بر مبنای روش‌های هوشمند تلقی می‌شود. همچنین، این تکنیک‌ها می‌تواند به ترکیب روش بهینه‌سازی ازدحام ذرات و روش‌های هوشمند SVM [۱۴]، منطق فازی و ANN همانند سیستم فازی - عصبی تطبیقی (ANFIS) [۱۵]، مدل فیزیکی ANN (PHANN) [۱۶]، ترکیب یک روش آماری از خانواده‌ی ARMA و ANN [۱۷]

نشان‌دهنده‌ی تعداد کل ویژگی‌ها و ویژگی‌های هر گره است. بنابراین یک شبکه‌ی مبتنی بر گراف به صورت  $A(\Gamma, \nu, \omega)$  تعریف می‌شود. در یک ساختار STLF مبتنی بر گراف، داده‌های جمع‌آوری شده در زمان  $t$  استفاده می‌شوند تا شبکه بر اساس تابع یادگیری  $L(\cdot)$  بتواند  $X_{t+T}$  را از  $X_t$  برای  $T$  گام زمانی بعدی تولید نماید، که:

$$[X_{(t-T')+1}, \dots, X_t; A] \xrightarrow{L(\cdot)} [X_{t+1}, \dots, X_{t+T}] \quad (1)$$

ماتریس‌های وزنی بر اساس تابع اطلاعات مشترک (MI) و گره‌های شبکه‌ی مبتنی بر گراف تعیین می‌شوند:

$$\omega(k, l) = \begin{cases} e^{-MI(k,l)} & MI(k,l) \geq 0 \\ 0 & MI(k,l) < 0 \end{cases} \quad (2)$$

که  $e$  و  $MI(k,l)$  به ترتیب عدد اویلر و MI نرمالیزه شده بین  $\Gamma_k$  و  $\Gamma_l$  را نشان می‌دهند. مقدار MI بین دو گره برابر است با:

$$MI(k,l) = D_{kl}(P_{(k,l)} \parallel P_k \cdot P_l) \quad (3)$$

که  $D_{kl}(\cdot)$  تابع اختلاف کولبرک-لیبرل را نشان می‌دهد [۲۲].

### ۳- ساختار روش یادگیری عمیق پیشنهادی مبتنی بر گراف برای پیش‌بینی بار

برای این که عدم قطعیت ذاتی بار مصرفی و داده‌های اقلیمی مدل شود، از یک فرآیند انتشار در لایه‌های کانولوشنی استفاده شده است. به صورت تئوری، فرآیند انتشار می‌تواند به صورت ترکیبی از روش گام تصادفی وزنی و ماتریس انتقال یک تابع توزیع ایستا پیاده‌سازی شود:

$$P^+ = \sum_{k=0}^{\infty} p(1-p)^k (T_0^{-1}\omega)^k \quad (4)$$

که  $k$  شمارنده‌ی فرآیند انتشار است. عبارت  $p(1-p)^k$  گام تصادفی را بر روی گراف  $A$  نشان می‌دهد. عبارت دوم یعنی  $(T_0^{-1}\omega)^k$  یک ماتریس انتقال حالت است که در آن  $T_0$  یک ماتریس قطری برابر با  $T_0 = \text{diag}(\omega_z)$  که  $z \in \mathbb{R}^N$  به بردارهای یک گفته می‌شود.

اگر فرآیند گام برداری تصادفی چندین مرتبه تکرار شود، می‌توان یک توزیع ایستا ساخت که به صورت یک ماتریس شامل میزان احتمال هر گره است. فرآیند انتشار بر اساس ساختارهای جهت‌دار می‌تواند بهبود یابد.

#### ۳-۱- لایه‌ی کانولوشنی در ساختار مبتنی بر گراف

برای این که توانایی یادگیری از داده‌های خام ارتقا یابد، فرآیند انتشار با لایه‌های کانولوشنی ادغام می‌شود و لایه‌های کانولوشنی انتشار را تشکیل می‌دهد. این لایه‌های کانولوشنی انتشار به صورت زیر تعریف می‌شوند:

$$X_s^{\wedge} \otimes f^{\theta} = \sum_{k=0}^{K-1} \left\{ (\theta_k^z) (T_0^{-1}\omega)^k + \theta_k^z (T_1^{-1}\omega^T)^k \right\} X_s, \forall s = \{1, \dots, S\} \quad (5)$$

روارائه‌ی یک ساختار که قابلیت یادگیری کامل مشخصات زمانی و مکانی را از داده‌های پیشین بار مصرفی و اطلاعات آب و هوایی دارند، ضروری است.

در این مقاله، یک ساختار مبتنی بر یادگیری عمیق که توانایی یادگیری مشخصات زمانی و مکانی را در پیش‌بینی بار دارند، پیشنهاد شده است. برای این که تاثیر داده‌های اقلیمی در فرآیند یادگیری به صورت مطلوبی لحاظ شوند، ساختار پیشنهادی بر مبنای گراف می‌باشد. به بیان دیگر، روش پیشنهادی یک گراف جهت‌دار اسست که قادر به درک همگرایی بین داده‌های محیطی و بار مصرفی می‌باشد. علاوه بر این ساختار احتمالی بار مصرفی از یک مجموعه از لایه‌های کانولوشنی انتشاردهنده استفاده شده است. در ساختار عمیق مبتنی بر گراف روش LSTM نیز برای یادگیری مشخصات زمانی ادغام شده است. همچنین، برای ارتقای قدرت یادگیری از ساختارهای دی‌کودر و انکودر نیز استفاده شده است تا دقت را تا حد مطلوبی ارتقا دهد. به صورت خلاصه، می‌توان نوآوری‌های این مقاله را به صورت زیر خلاصه نمود:

- طراحی یک ساختار که قادر به یادگیری کامل مشخصات زمانی و مکانی از داده‌های خام پروفیل بار مصرفی را دارد.
- یادگیری همگرایی بین داده‌های واقعی بار مصرفی و داده‌های اقلیمی بر اساس یک ساختار گراف جهت‌دار
- بهبود دقت پیش‌بینی بر اساس یک ساختار دی‌کودر و انکودر این مقاله علاوه بر این قیمت از چهار قسمت دیگر تشکیل شده است: در قسمت دوم، مفاهیم پیش‌بینی بر مبنای یک ساختار مبتنی بر گراف آورده شده است. جزئیات روش پیشنهادی یادگیری عمیق در قسمت سوم معرفی شده است. نتایج عددی در قسمت چهارم مورد تجزیه و تحلیل قرار گرفته است. قسمت پنجم و آخر نیز نتیجه‌گیری مقاله آورده شده است.

### ۲- مبانی پیش‌بینی بر اساس ساختارهای مبتنی بر گراف

فرض کنید مجموعه‌ی داده‌ها بار و داده‌های اقلیمی بر اساس مجموعه‌ی  $X \in \{x_1, \dots, x_n, \dots, x_N\} \quad \forall n = 1, \dots, N$  و خروجی‌ها با مجموعه‌ی  $Y \in \{y_1, \dots, y_m, \dots, y_M\} \quad \forall m = 1, \dots, M$  مشخص شده باشند. در مسئله‌ی پیش‌بینی کوتاه مدت بار (STLF) فرض بر این است که یک ساختار طراحی شود تا مجموعه  $\hat{Y}$  را طوری نگاشت کند که کمترین اختلاف را با مجموعه  $Y$  داشته باشد. در این مقاله برای این که وابستگی میان داده‌ها به صورت مطلوب مدل شود، از یک ساختار مبتنی بر گراف استفاده شده است. در ساختار مبتنی بر گراف از سه مولفه‌ی گره‌ها  $\Gamma$ ، لبه‌ها  $\nu$  و ماتریس‌های وزنی  $\omega$  استفاده شده است. یک ساختار مبتنی بر گراف بر اساس گره‌ها که برابر با ویژگی‌ها می‌باشند و ماتریس‌های وزنی که همگرایی و میزان شباهت رفتاری بین داده‌های بار مصرفی و داده‌های اقلیمی را نشان می‌دهد. بار مصرفی به عنوان یک گراف  $X \in \mathbb{R}^{f \times f'}$  که  $f'$  و  $f$  به ترتیب

خروجی تشکیل شده است. دروازه‌ی ورودی وزن مجموع را بر اساس تابع فعالیت محاسبه می‌کند که:

$$y^t = f^{\text{ReLU}}(W^{\text{in}}x^t + R^{\text{in}}h^{t-1} + b^t) \quad (10)$$

که  $W^{\text{in}}$ ،  $R^{\text{in}}$  و  $b^t$  به ترتیب وزن ورودی، پارامتر بازگشتی و ماتریس بایاس در دروازه‌ی ورودی را نشان می‌دهند. همچنین،  $x^t$  و  $h^{t-1}$  ورودی‌های متغیر با زمان  $t$  و حالت‌های پنهان را نشان می‌دهند. این دروازه ورودی‌ها را به دروازه‌ی حافظه می‌دهد که داریم:

$$y^f = f^{\text{ReLU}}(W^f x^t + R^f h^{t-1} + b^f) \quad (11)$$

که  $W^f$ ،  $R^f$  و  $b^f$  به ترتیب وزن ورودی، پارامتر بازگشتی و ماتریس بایاس در دروازه‌ی فراموشی را نشان می‌دهند. دروازه‌ی خروجی اهمیت ویژگی را مشخص می‌کند. در صورتی که این داده که از دروازه‌ی فراموشی عبور کرده، اهمیت کمی داشته باشد، توسط این دروازه حذف می‌شود. خروجی این دروازه به صورت زیر به دست می‌آید:

$$y^o = f^{\text{ReLU}}(W^o x^t + R^o h^{t-1} + b^o) \quad (12)$$

که  $W^o$ ،  $R^o$  و  $b^o$  به ترتیب وزن ورودی، پارامتر بازگشتی و ماتریس بایاس در دروازه‌ی خروجی را نشان می‌دهند. در این ساختار انوکدر-دی کودرها با LSTM ادغام شده‌اند. در این راستا ورودی‌ها به انوکدر داده می‌شوند. سپس خروجی LSTM به دی کودر داده می‌شود. دی کودر مقادیر پیش‌بینی نهایی را در ساختار پیشنهادی تشکیل می‌دهد.

#### ۴- نتایج عددی

در این بخش روش پیش‌بینی بار پیشنهادی مورد تجزیه و تحلیل و با روش‌های دیگر مقایسه شده است. از این رو چندین ساختار متفاوت کم عمق و عمیق برای مقایسه در نظر گرفته شده است. روش‌های ANN و KNN به عنوان روش کم عمق و روش CNN به عنوان یک روش عمیق در نظر گرفته شده‌اند. شبیه‌سازی‌های انجام شده در TensorFlow انجام شده است.

#### ۴-۱- داده‌های شبیه‌سازی

در این مقاله، داده‌های واقعی شبکه‌ی شیراز، ایران مورد استفاده قرار گرفته است. این داده‌های عملی که از [۲۶] گرفته شده است. این اطلاعات از تاریخ ۱۰ مارچ سال ۲۰۱۶ تا ۱۰ مارچ سال ۲۰۱۷ از شبکه‌ی برق ایران و شبکه‌ی شیراز گرفته شده است. این اطلاعات شامل اطلاعات بار مصرفی، فشار اتمسفر، دما، رطوبت و سرعت باد است. حدود ۷۰٪ از این داده‌ها برای آموزش و ۳۰٪ برای آزمون استفاده شده است.

#### ۴-۲- معیارهای دقت

برای ارزیابی عملکرد روش‌های پیش‌بینی، از معیارهای دقت درصد قدر

که  $X_s^A$  و  $f^{\theta}$  به ترتیب ورودی‌ها در سرتاسر یک گراف و و فیلترهای با وزن  $\theta$  را نشان می‌دهند. ماتریس‌های انتقال مستقیم و معکوس به ترتیب با عبارت‌های  $T_0^{-1}\omega$  و  $T_1^{-1}\omega^T$  نشان داده شده است. عملگر کانولوشن با علامت  $\otimes$  نشان داده شده است.

ساختارهای مبتنی بر گراف زمان محاسبات بالایی دارند. برای رفع این مشکل یک عبارت واسط تعریف شده است:

$$D_k(\theta^z) = (\theta^z)(T_0^{-1}\omega)^k \quad (6)$$

که ماتریس انتقال مستقیم به شکل زیر در می‌آید:

$$(\theta^z)(T_0^{-1}\omega)^k = \theta_k^z D_k(X_s^A) \quad (7)$$

به این دلیل که  $D_{k+1}(\theta^z) = (T_0^{-1}\omega)D_k(\theta^z)$  و  $T_0^{-1}\omega$  ماتریس‌های تنک هستند، با استفاده از روش بازگشتی در [۲۳] محاسبه می‌شود. در این روش  $O(K)$  یک ماتریس است که بر اساس یک فرآیند گام‌برداری تصادفی و نمونه‌برداری از ساختار گراف عمیق بر روی یک مسیر مشخص استفاده می‌شود. برای اطلاعات بیشتر خوانندگان به [۲۳] مراجعه نمایند.

فرآیند انتشار باعث تشکیل لایه‌های کانولوشنی انتشار می‌شود که برای نگاشت ویژگی‌های  $m$  بعدی به  $n$  بعدی تعریف شده است. اگر تانسور  $\Phi \in \mathbb{R}^{m_1 \times m_2 \times K \times z}$  در نظر گرفته شود که شامل فیلترهای کانولوشنی می‌باشد، لایه‌های کانولوشنی انتشار به صورت زیر تعریف می‌شود:

$$Y_s^A = f^{\text{active}}\left(\sum_{i=1}^N X_s^A \otimes f^{\theta}\right) \quad (8)$$

که  $Y_s^A$  خروجی لایه‌ی کانولوشنی انتشار و  $f^{\text{active}}(\cdot)$  تابع فعالیت را نشان می‌دهد که از واحد خطی یکسوساز (ReLU) [۲۴] و تابع فعالیت خطی استفاده می‌شود. در مرحله‌ی آموزش نیز از روش بهینه‌سازی Adam که یک روش گرادیان احتمالی است، استفاده شده است [۲۵].

برای بهبود یادگیری در ساختار گراف پیشنهادی، ویژگی‌های بدون جهت به ویژگی‌های جهت‌دار تبدیل می‌شوند. در این راستا از ماتریس تعریف شده‌ی  $L, L^{-\frac{1}{2}}, L^{\frac{1}{2}}$  استفاده می‌شود:

$$X_s^A \otimes f^{\theta} = \gamma F^{\theta} \gamma^T X_s^A \quad (9)$$

که  $F^{\theta}$  مقادیر ویژه گراف است. این رابطه گراف بئون جهت را به یک گراف جهت‌دار تبدیل می‌کند.

#### ۲-۳- روش LSTM جهت‌دار بر مبنای دی کودر-

##### انوکدر

علاوه بر بالابردن توانایی یادگیری ساختار مبتنی بر گراف با استفاده از لایه‌های کانولوشنی انتشار، ساختار مبتنی بر گراف عمیق بر مبنای یک واحد بازگشتی دروازه‌دار، به نام حافظه بلند مدت (LSTM) توسعه داده شده تا مشخصات زمانی در بازه‌های زمانی مختلف را استخراج نماید. روش LSTM از سه دروازه ورودی، دروازه‌ی فراموشی و دروازه‌ی


مشخص است، نتایج پیش‌بینی با داده‌های واقعی تطابق بالایی دارد که نشان از عملکرد مطلوب روش پیشنهادی دارد.

نتایج به دست آمده از روش پیشنهادی در این حالت با سه روش دیگر در جدول ۱ مقایسه شده است. بنابر نتایج به دست آمده از این جدول، ساختار پیشنهادی حدود ۴۴/۶٪ از روش CNN بر اساس معیار MAPE دقیق‌تر عمل کرده است. همچنین، این ساختار دقت دو روش ANN و KNN را به ترتیب در حدود ۸۶/۰۹٪ و ۸۸/۱۸٪ بهبود داده است.

جدول (۱): نتایج پیش‌بینی به دست آمده از روش‌های پیش‌بین مختلف در فصل بهار

روش پیش‌بینی	MAPE (%)	MAE (MW)	RMSE (MW)	NRMSE (%)
پیشنهادی	۰/۵۹۶۸	۱/۷۱۰۱	۲/۰۴۲۱	۰/۰۰۹۸
CNN [۲۱]	۱/۰۶۳۱	۵/۱۳۷۱	۹/۵۵۷۲	۰/۰۵۰۶
ANN [۷]	۴/۲۳۱۲	۲۰/۲۶۲۰	۲۶/۴۲۵۶	۰/۱۳۹۸
KNN [۲۸]	۴/۹۷۹۶	۲۴/۷۳۹۷	۳۰/۴۵۳۷	۰/۱۶۱۱

نتایج به دست آمده از روند آزمون روش پیشنهادی برای یک هفته در فصل تابستان در شکل ۲ با داده‌های واقعی مقایسه شده است و نتایج نشان‌دهنده عملکرد مطلوب روش پیشنهادی در پیش‌بینی داده‌ها در فصل تابستان است. همچنین، این نتایج در جدول ۲ با روش‌های دیگر مقایسه شده است و نتایج نشان از برتری روش پیشنهادی بر روش‌های دیگر دارد. خطای به دست آمده از روش پیشنهادی از روش‌های بر اساس معیار RMSE برابر با ۸/۸۸۶۱٪ است، در حالی مقدار RMSE به دست آمده از روش‌های ANN و KNN به ترتیب برابر با ۲۶/۵۹۲۹ و ۴۰/۶۸۰۱ است و مقدار به دست آمده از CNN حداقل سه برابر مقدار روش پیشنهادی هستند.



شکل (۲): مقایسه نتایج پیش‌بینی به دست آمده از روش پیشنهادی و داده‌های واقعی در فصل تابستان

مطلق میانگین خط (MAPE)، قدر مطلق میانگین خطا (MAE)، میانگین مجذور ریشه‌ی دوم خطا (RMSE) و مقدار نرمالیزه شده‌ی مقدار نرمالیزه‌شده میانگین مجذور ریشه‌ی دوم خطا (NRMSE) استفاده شده است [۲۷].

$$MAPE = \frac{1}{N} \sum_{t=1}^N \left| \frac{y_{re}(t) - y_f(t)}{y_f} \right| \times 100 \quad (13)$$

$$MAE = \frac{1}{N} \sum_{t=1}^N |y_{re} - y_f| \quad (14)$$

$$NRMSE = \frac{1}{N} \sqrt{\frac{\sum_{t=1}^N (y_f(t) - y_{re}(t))^2}{y_{max} - y_{min}}} \quad (15)$$

$$RMSE = \frac{1}{N} \sqrt{\sum_{t=1}^N (y_f(t) - y_{re}(t))^2} \quad (16)$$


که  $y_{re}(t)$  مقدار واقعی در سری زمانی،  $y_f(t)$  مقدار پیش‌بینی شده در سری زمانی و  $N$  تعداد نقاط سری زمانی پیش‌بینی است.

### ۳-۴- ارزیابی نتایج

در این قسمت، نتایج بر اساس تغییرات فصلی داده‌ها، عملکرد کلی سالیانه و تاثیر داده‌های آب و هوایی مورد بررسی قرار گرفته است.

#### مطالعه‌ی اول: تغییرات فصلی

بر اساس داده‌های فصلی، چهار حالت مختلف در نظر گرفته شده است. در هر حالت، داده‌های یک فصل برای آزمون و آموزش مورد استفاده قرار گرفته است. به عنوان نمونه ۳۰٪ از داده‌های فصل بهار برای آزمون و بقیه‌ی روزهای این فصل برای آموزش استفاده شده است و از این طریق عملکرد روش گراف عمیق پیشنهادی مورد ارزیابی قرار گرفته است.




شکل (۱): مقایسه نتایج پیش‌بینی به دست آمده از روش پیشنهادی و داده‌های واقعی در فصل بهار

شکل ۱ نتایج بار پیش‌بینی شده توسط ساختار پیشنهادی را برای فصل بهار در یک هفته با داده‌های واقعی مقایسه نموده است. همان طور که

روش پیشنهادی آن قدر کم است که تشخیص بین مقادیر واقعی از پیش‌بینی بسیار دشوار است.

در جدول ۴ اطلاعات مربوط به مقایسه بین روش پیشنهادی و سه روش ANN، CNN و KNN از در اختیار می‌گذارد. بر اساس چهار شاخص دقت مشخص است که روش پیشنهادی خطای کمتری در مقایسه با روش‌های دیگر دارد. به عنوان نمونه به مقادیر MAE در این جدول توجه کنید. بر اساس آن معیار دقت، روش پیشنهادی در حدود ۵۸/۵۲٪، ۸۸/۱۲٪ و ۸۰/۰۳۹٪ دقت بهتری از روش‌های ANN، CNN و KNN دارد.



شکل (۴): مقایسه نتایج پیش‌بینی به دست آمده از روش پیشنهادی و داده‌های واقعی در فصل زمستان

جدول (۴): نتایج پیش‌بینی به دست آمده از روش‌های پیش‌بینی مختلف در فصل زمستان

روش پیش‌بینی	MAPE (%)	MAE (MW)	RMSE (MW)	NRMSE (%)
پیشنهادی	۰/۶۵۴۸	۲/۷۶۴۲	۳/۵۱۸۶	۰/۰۲۰۴
[۲۱] CNN	۱/۴۲۳۱	۶/۶۳۷۰	۱۸/۷۱۲۰	۰/۰۳۸۷
[۷] ANN	۵/۲۶۹۴	۲۳/۱۷۹۹	۳۴/۵۳۷۰	۰/۰۷۱۴
[۲۸] KNN	۳/۰۹۲۶	۱۴/۰۴۱۶	۲۳/۸۱۷۴	۰/۰۴۹۳

### مطالعه‌ی دوم: عملکرد سالیانه


در این قسمت، عملکرد سالیانه روش مبتنی بر گراف پیشنهادی بررسی شده است تا عملکرد روش پیشنهادی را برای یک افق پیش‌بینی بلند مدت مورد ارزیابی قرار دهد. در این حالت نیز ۷۰٪ به آموزش و ۳۰٪ به آزمون اختصاص داده شده است.

شکل ۵ نتایج پیش‌بینی و مقادیر واقعی را برای یک بازه‌ی ۶۶۰ ساعته نشان می‌دهد. با توجه به فاصله بسیار ناچیز مقادیر واقعی از مقادیر پیش‌بینی شده می‌توان به این نتیجه رسید که روش پیشنهادی عملکرد مطلوبی در پیش‌بینی بار یک سال از خود نشان داده است. در جدول ۵ معیارهای دقت مورد استفاده قرار گرفته‌اند تا عملکرد روش پیشنهادی را با روش‌های ANN، CNN و KNN مقایسه نمایند

شکل ۳ نتایج پیش‌بینی با مقدار واقعی را برای فصل پاییز نشان می‌دهد. همچنین، نتایج به دست آمده از روش پیشنهادی با روش‌های دیگر در جدول ۳ آورده شده است. به عنوان نمونه مقدار NRMSE نشان می‌دهد که دقت روش پیشنهادی نسبت به روش‌های ANN و KNN به ترتیب ۲۳/۳۲٪، ۷۴/۶۴٪ و ۸۳/۲۵٪ بهبود یافته است.

جدول (۳): نتایج پیش‌بینی به دست آمده از روش‌های پیش‌بینی مختلف در فصل تابستان

روش پیش‌بینی	MAPE (%)	MAE (MW)	RMSE (MW)	NRMSE (%)
پیشنهادی	۰/۶۱۰۱	۱/۵۱۳۲	۱/۹۲۱۴	۰/۰۱۳۲
[۲۱] CNN	۰/۹۵۷۳	۴/۷۷۷۹	۸/۸۸۶۱	۰/۰۵۰۶
[۷] ANN	۴/۰۴۸۵	۱۹/۹۷۸۶	۲۶/۵۹۲۹	۰/۱۵۱۴
[۲۸] KNN	۶/۵۸۴۶	۳۳/۸۸۱۷	۴۰/۶۸۰۱	۰/۲۳۱۶



شکل (۳): مقایسه نتایج پیش‌بینی به دست آمده از روش پیشنهادی و داده‌های واقعی در فصل پاییز

جدول (۳): نتایج پیش‌بینی به دست آمده از روش‌های پیش‌بینی مختلف در فصل تابستان

روش پیش‌بینی	MAPE (%)	MAE (MW)	RMSE (MW)	NRMSE (%)
پیشنهادی	۰/۶۹۷۱	۳/۲۴۱۲	۴/۱۰۲۴	۰/۰۲۶۹
[۲۱] CNN	۱/۱۱۴۸	۵/۲۳۸۱	۸/۹۴۰۷	۰/۰۲۸۳
[۷] ANN	۴/۲۹۹۵	۲۰/۷۲۸۴	۲۷/۰۴۰۵	۰/۰۸۵۶
[۲۸] KNN	۶/۶۵۲۱	۳۳/۹۳۴۶	۴۰/۹۵۰۵	۰/۱۲۹۶

عملکرد روش پیشنهادی پیش‌بینی کوتاه مدت بارهای الکتریکی در آخرین فصل سال زمستان نیز نتایج مشابه با فصول قبل از خود نشان می‌دهد. در این حالت نیز شکل ۴ نتایج پیش‌بینی را با مقادیر م صرف واقعی در شکل ۴ مقایسه می‌کند. همان طور که مشخص است، خطای

داده های اقلیمی خطای بین داده های واقعی و پیش بینی به تدریج کاهش یافته است که با مقایسه بین شکل های ۶(الف) تا ۶(د) این موضوع مشخص است.

در جدول ۶ مقادیر به دست آمده از پیش بینی در چهار حالت بر اساس داده های ورودی با یکدیگر مقایسه شده است. در حالتی که تنها بار مصرفی و سرعت باد به عنوان ورودی در نظر گرفته شده اند، مقدار MAPE برابر با ۱/۵۵۸۱٪ است. در حالی که با اضافه کردن فشار دقت ۳۹/۰۲٪، با اضافه کردن فشار و دما دقت ۵۴/۲۰٪ بهبود می یابد. در حالت آخر نیز دقت نسبت به حالت اول حدود ۵۵/۶۱٪ بهبود یافته است.


جدول (۶): تاثیر داده های اقلیمی بر روی روش پیشنهادی مبتنی بر گراف

داده های ورودی	MAPE (%)	MAE (MW)	RMSE (MW)	NRMSE (%)
بار+باد+فشار+رطوبت+دما	۰/۶۹۱۲	۳/۲۱۳	۴/۲۰۸	۰/۰۱۵۲
بار+باد+فشار+دما	۰/۷۱۹۲	۳/۳۳۸۹	۴/۲۷۸۹	۰/۰۱۵۶
بار+باد+فشار	۰/۰۹۶۱۲	۴/۴۵۸۶	۵/۸۹۱۲	۰/۰۱۹۸
بار+باد	۱/۵۵۸۱	۷/۳۹۱۲	۱۰/۰۵۵۲	۰/۰۳۴۲

## ۵- نتیجه گیری

یک روش جدید یادگیری عمیق مبتنی بر گراف در این مقاله برای مسئله پیش بینی بارهای مصرف ارائه شده است. که برای برنامه ریزی های کوتاه/بلند مدت در سیستم های قدرت ضروری است. در این مقاله، از ساختار CNN برای استخراج ویژگی های مقاوم و مکانی استفاده شده است، در حالی که از LSTM دو طرفه برای درک ویژگی های زمانی استفاده شده است. سپس این ساختار با استفاده از یک انکودر-دی کورد قدرت یادگیری آن افزایش یافته است. علاوه بر این ساختار فوق به صورت یک ساختار مبتنی بر گراف در آمده است تا همگرایی و شباهت های رفتاری بین مشخصات اقلیمی و بارهای مصرفی را مدل نماید و زا این طریق دقت پیش بینی بار مصرفی را افزایش دهد. این ساختار بر روی داده های واقعی شبکه ی برق شیراز، ایران مورد ارزیابی قرار گرفته است. نتایج با روش های ANN، CNN و KNN مقایسه شده است و در اکثر حالت ها بیش از ۵۰٪ بهبود دقت مشاهده گردید. روش پیشنهادی به صورت فصلی و سالیانه نیز مورد ارزیابی قرار گرفته است. همچنین، تاثیر پارامترهای آب و هوایی بر روی عملکرد روش پیشنهادی نشان می دهد که می توان با اضافه نمودن مشخصات آب و هوایی دقت را به صورت چشمگیری در حدود ۵۰٪ بهبود بخشید.

همان طور که مشخص است روش پیشنهادی دقت مطلوب تری از روش های دیگر دارد. به عنوان نمونه، تقریباً ۶۵/۸۲٪، ۸۵/۴۸٪ و ۸۷/۹۴٪ بهبود دقت را در روش پیشنهادی نسبت به روش های ANN، CNN و KNN می توان مشاهده نمود.



شکل (۵): مقایسه نتایج پیش بینی به دست آمده از روش پیشنهادی و داده های واقعی در یک سال


جدول (۵): نتایج پیش بینی به دست آمده از روش های پیش بینی مختلف در یک سال

روش پیش بینی	MAPE (%)	MAE (MW)	RMSE (MW)	NRMSE (%)
پیشنهادی	۰/۶۹۱۲	۳/۲۱۳	۴/۲۰۸	۰/۰۱۵۲
CNN [۲۱]	۱/۱۴۰۸	۵/۴۵۳۲	۱۲/۲۵۹۲	۰/۰۲۱۷
ANN [۷]	۴/۴۶۴۸	۲۱/۰۴۹۸	۲۸/۸۶۵۹	۰/۰۵۱۲
KNN [۲۸]	۵/۳۲۸۸	۲۶/۶۵۷۵	۳۴/۷۴۶۹	۰/۰۶۱۶

## مطالعه ی سوم: تاثیرات پارامترهای اقلیمی

یکی از اهداف پیشنهاد روش عمیق مبتنی بر گراف، یادگیری همگرایی و شباهت های رفتاری بین پارامترهای اقلیمی و بار مصرفی در روش است. از این رو، این در این حالت عملکرد روش پیشنهادی بر اساس چهار دسته متفاوت از اطلاعات پیشین مورد بررسی در نظر گرفته شده است که شامل: (۱) بار مصرفی + سرعت باد، (۲) بار مصرفی + سرعت باد+فشار، (۳) بار مصرفی + سرعت باد+فشار، (۴) بار مصرفی + سرعت باد+فشار+رطوبت. مشخص است که در هر کدام از این چهار حالت یک مشخصه ی اقلیمی اضافه شده است تا روش پیشنهادی با یادگیری همگرایی و بر اساس رفتار این پارامتر های محیطی دقت روش پیشنهادی را افزایش بدهند. همچنین، در این مطالعه، عملکرد سالیانه مورد بررسی قرار گرفته است.

شکل ۶ مقادیر واقعی را با مقادیر پیش بینی شده در هر چهار حالت مقایسه نموده است. همان طور که مشخص است با اضافه نمودن



شکل (۶): مقایسه بین مقادیر واقعی و پیش‌بینی سالیانه با ورودی‌های مختلف: الف) بار مصرفی+سرعت باد، ب) بر مصرفی+سرعت باد+فشار، ج) بار مصرفی+سرعت باد+دما، د) بار مصرفی+سرعت باد+فشار+دما

[6] M. Khodayar and J. Wang, "Spatio-Temporal Graph Deep Neural Network for Short-Term Wind Speed Forecasting," *IEEE Transactions on Sustainable Energy*, vol. 10, no. 2, pp. 670-681, 2019.

[7] I. Drezga and S. Rahman, "Short-term load forecasting with local ANN predictors," *IEEE Transactions on Power Systems*, vol. 14, no. 3, pp. 844-850, 1999.

[8] W. Sun and Y. Liang, "Least-Squares Support Vector Machine Based on Improved Imperialist Competitive Algorithm in a Short-Term Load Forecasting Model," *Journal of Energy Engineering*, vol. 141, no. 4, p. 04014037, 2015.

[9] A. Lahouar and J. Ben Hadj Slama, "Day-ahead load forecast using random forest and expert input selection," *Energy Conversion and Management*, vol. 103, pp. 1040-1051, 2015.

[10] Y. Chen et al., "Short-Term Load Forecasting: Similar Day-Based Wavelet Neural Networks," *IEEE Transactions on Power Systems*, vol. 25, no. 1, pp. 322-330, 2010.

[11] S. Afrasiabi, M. Afrasiabi, B. Parang, and M. Mohammadi, "Integration of Accelerated Deep Neural Network Into Power Transformer Differential Protection," *IEEE Transactions on Industrial Informatics*, vol. 16, no. 2, pp. 865-876, 2020.

[1] Z. Li, Y. Li, Y. Liu, P. Wang, R. Lu, and H. B. Gooi, "Deep Learning Based Densely Connected Network for Load Forecasting," *IEEE Transactions on Power Systems*, pp. 1-1, 2020.

[2] M. Afrasiabi, M. Mohammadi, M. Rastegar, L. Stankovic, S. Afrasiabi, and M. Khazaei, "Deep-Based Conditional Probability Density Function Forecasting of Residential Loads," *IEEE Transactions on Smart Grid*, vol. 11, no. 4, pp. 3646-3657, 2020.

[3] M. Afrasiabi, M. Mohammadi, M. Rastegar, and A. Kargarian, "Multi-agent microgrid energy management based on deep learning forecaster," *Energy*, vol. 186, p. 115873, 2019.

[4] M. Afrasiabi, M. Mohammadi, M. Rastegar, and S. Afrasiabi, "Advanced Deep Learning Approach for Probabilistic Wind Speed Forecasting," *IEEE Transactions on Industrial Informatics*, vol. 17, no. 1, pp. 720-727, 2021.

[5] M. Khodayar, O. Kaynak, and M. E. Khodayar, "Rough Deep Neural Architecture for Short-Term Wind Speed Forecasting," *IEEE Transactions on Industrial Informatics*, vol. 13, no. 6, pp. 2770-2779, 2017.

## مراجع



## رزومه



**مهتاب گنجوری** در شی‌راز متولد شده است (۱۳۶۹). تحصیلات دانشگاهی خود را در مقاطع کارشناسی از دانشگاه آزاد اسلامی واحد علوم و تحقیقات، کارشناسی ارشد از دانشگاه صنعتی شاهرود سپری کرده است و هم‌اکنون دانشجوی دکتری دانشگاه آزاد اسلامی واحد مرودشت می‌باشد.

فعالیت‌های پژوهشی و علاقه‌مندی‌های ایشان در زمینه یادگیری عمیق، شناسایی الگوریتم‌های بهینه‌سازی سیستم‌های قدرت و کنترل فازی است و در حال حاضر مدرس دانشکده فنی و حرفه‌ای باهنر شی‌راز و استادیار مدعو دانشگاه آزاد اسلامی واحد شی‌راز می‌باشد.



**مردا معطری** در شیراز متولد شده است (۱۳۵۹). تحصیلات دانشگاهی خود را در مقطع کارشناسی مهندسی برق از دانشگاه صنعتی اصفهان، کارشناسی ارشد مهندسی برق از دانشگاه شیراز و دکتری مهندسی برق از دانشگاه تربیت مدرس سپری کرده است.

فعالیت‌های پژوهشی و علاقه‌مندی‌های ایشان در زمینه سیستم‌های کنترل، کنترل مشارکتی، هوش مصنوعی و بینایی ماشین است و در حال حاضر استادیار گروه برق دانشگاه آزاد اسلامی واحد مرودشت می‌باشد.



**احمد فروزان تبار** در شیراز متولد شده است (۱۳۶۱). تحصیلات دانشگاهی خود را در مقطع کارشناسی مهندسی پزشکی از دانشگاه صنعتی سهند تبریز، کارشناسی ارشد مهندسی برق از دانشگاه صنعتی مالک اشتر و دکتری مهندسی برق از دانشگاه آزاد اسلامی واحد علوم و تحقیقات سپری کرده است.

فعالیت‌های پژوهشی و علاقه‌مندی‌های ایشان در زمینه کنترل مشارکتی، هوش مصنوعی و بینایی ماشین است و در حال حاضر استادیار گروه مهندسی برق دانشگاه آزاد اسلامی واحد مرودشت می‌باشد.



**محمد آزادی** در شیراز متولد شده است (۱۳۵۹). تحصیلات دانشگاهی خود را در مقاطع کارشناسی، کارشناسی ارشد و دکتری مهندسی مکانیک از دانشگاه شیراز سپری کرده است. فعالیت‌های پژوهشی و علاقه‌مندی‌های ایشان در زمینه سیستم‌های دینامیکی، ارتعاشات و کنترل، سازه‌های هوشمند و رباتیک است و در حال حاضر استادیار گروه مهندسی مکانیک دانشگاه آزاد اسلامی واحد مرودشت می‌باشد.

- [12] N. T. Nguyen, V. T. Phan, and Z. Malarad, "Nonlinear grey bernoulli model based on fourier transformation and its application in forecasting the electricity consumption in vietnam," *Journal of Intelligent & Fuzzy Systems*, no. Preprint, pp. 1-11.
- [13] M. S. Sadeghi, "A hybrid intelligent-based linear-nonlinear model for accurate daily peak load forecasting," *Journal of Intelligent & Fuzzy Systems*, vol. 26, no. 6, pp. 3013-3020, 2014.
- [14] J. Liu, P. Wang, Y. Huang, P. Wu, Q. Xu, and H. Chen, "Power load combination forecasting based on triangular fuzzy discrete difference equation forecasting model and PSO-SVR," *Journal of Intelligent & Fuzzy Systems*, no. Preprint, pp. 1-10.
- [15] I. P. Panapakidis and A. S. Dagoumas, "Day-ahead natural gas demand forecasting based on the combination of wavelet transform and ANFIS/genetic algorithm/neural network model," *Energy*, vol. 118, pp. 231-245, 2017.
- [16] E. Ogliairi, A. Gandelli, F. Grimaccia, S. Leva, and M. Mussetta, "Neural forecasting of the day-ahead hourly power curve of a photovoltaic plant," in *2016 International Joint Conference on Neural Networks (IJCNN)*, 2016, pp. 654-659.
- [17] H. Moeeni and H. Bonakdari, "Impact of Normalization and Input on ARMAX-ANN Model Performance in Suspended Sediment Load Prediction," *Water Resources Management*, journal article vol. 32, no. 3, pp. 845-863, 2018.
- [18] M. Afrasiabi, M. Mohammadi, M. Rastegar, and S. Afrasiabi, "Deep learning architecture for direct probability density prediction of small-scale solar generation," *IET Generation, Transmission & Distribution*, vol. 14, no. 11, pp. 2017-2025, 2020.
- [19] C. Fan, F. Xiao, and Y. Zhao, "A short-term building cooling load prediction method using deep learning algorithms," *Applied Energy*, vol. 195, pp. 222-233, 2017.
- [20] S. Ryu, J. Noh, and H. Kim, "Deep Neural Network Based Demand Side Short Term Load Forecasting," *Energies*, vol. 10, no. 1, p. 3, 2017.
- [21] F. Wang et al., "Generative adversarial networks and convolutional neural networks based weather classification model for day ahead short-term photovoltaic power forecasting," *Energy Conversion and Management*, vol. 181, pp. 443-462, 2019.
- [22] M. Hutter, "Distribution of mutual information," in *Advances in neural information processing systems*, 2002, pp. 399-406.
- [23] D. Cheng, Y. Cheng, Y. Liu, R. Peng, and S.-H. Teng, "Efficient sampling for Gaussian graphical models via spectral sparsification," in *Conference on Learning Theory*, 2015, pp. 364-390.
- [24] V. Nair and G. E. Hinton, "Rectified linear units improve restricted boltzmann machines," in *Proceedings of the 27th international conference on machine learning (ICML-10)*, 2010, pp. 807-814.
- [25] D. P. Kingma and J. Ba, "Adam: A method for stochastic optimization," *arXiv preprint arXiv:1412.6980*, 2014.
- [26] I. R. M. Commission, "Energy Surplus Instruction 88, available in: www," *IGMC. ir*.
- [27] H. Samet, S. Ketabipoor, M. Afrasiabi, S. Afrasiabi, and M. Mohammadi, "Deep Learning Forecaster based Controller for SVC: Wind Farm Flicker Mitigation," *IEEE Transactions on Industrial Informatics*, pp. 1-1, 2020.
- [28] X. Lv, X. Cheng, YanShuang, and Y.-m. Tang, "Short-term Power Load Forecasting Based on Balanced KNN," *IOP Conference Series: Materials Science and Engineering*, vol. 322, p. 072058, 2018.

# Short-term Load Forecasting Using a Graph-based Deep Learning Structure

Mahtab Ganjouri<sup>1</sup>, Mazda Moattari<sup>2\*</sup>, Ahmad forouzantabar<sup>3</sup>, Mohammad Azadi<sup>4</sup>

- 1- PhD Student, Department of Electrical Engineering, Marvdasht Branch, Islamic Azad University, Marvdasht, Iran, mahtab.ganjouri@miau.ac.ir
- 2- Assistant Professor, Department of Electrical Engineering, Marvdasht Branch, Islamic Azad University, Marvdasht, Iran, moattari@miau.ac.ir
- 3- Assistant Professor, Department of Electrical Engineering, Marvdasht Branch, Islamic Azad University, Marvdasht, Iran, a.forouzantabar@miau.ac.ir
- 4- Assistant Professor, Department of Engineering, Marvdasht Branch, Islamic Azad University, Marvdasht, Iran, mazadi@miau.ac.ir

**Abstract:** Prior knowledge about the load data in the shape of future information plays a pivotal role in the optimal operation and planning in the electrical networks. In this paper, we design a deep learning-based network to characterize the load for the next hours. With emerging new technologies and a high growth rate of the population, short-term load forecasting (STLF) has reformed to a more complicated problem rather than in the traditional electrical networks, therefore, designing a structure that can capture spatial-temporal features is a challenging and essential task. To this end, we aim to develop a new deep learning structure, which is able to handle high volatility time series including load sequences. The designed network is composed of three different types of deep networks, convolutional neural network (CNN) as a strong spatial feature extractor, bidirectional long short-term memory unit as a suitable temporal feature learner, and encoder-decoder to enhance accuracy, which are formed in a graph-based deep network to inherently learn features of a time series and corresponding meteorological data. The proposed method is directly applicable to raw data and enhances the level of accuracy in terms of several metrics. The simulation results on actual load time series, in Shiraz, Iran, are compared with a number of well-known shallow and deep-based networks to verify the effectiveness and superiority of the designed deep network. Furthermore, the proposed STLF structure is tested in different seasons and the impact of the meteorological data is analyzed.

**Keywords:** Encoder-decoder, Bidirectional long short-term memory, short-term load consumption forecasting, convolutional neural network, deep graph learning.