Iranian Electric Industry Journal
Quality & Productivity
P.P 1-11

Vol. 12/ No. 2/ Summer 2023
ISSN 2322-2344
EISSN 2717-1639

Designing a multilevel deep neural residual network for short-term prediction of electrical loads in power systems

Mahtab Ganjouri[1], Ph.D. Student, Mazda Moattari[1,2*], Assistant Professor, Ahmad forouzantabar[1], Assistant Professor, Mohammad Azadi[2,3], Assistant Professor

1-Department of Electrical Engineering, Marvdasht Branch, Islamic Azad University, Marvdasht, Iran
2-Mechatronic and Artificial Intelligence Research Center, Marvdasht Branch, Islamic Azad University, Marvdasht, Iran
3-Department of Engineering, Marvdasht Branch, Islamic Azad University, Marvdasht, Iran
mahtab.ganjouri@miau.ac.ir, moattari@miau.ac.ir, a.forouzantabar@miau.ac.ir, mazadi@miau.ac.ir

Abstract:
To establish a production-consumption balance, it is necessary to design a method that provides basic information for the consumption load in the coming hours with a high level of accuracy and reliability. The problem of load forecasting is growingly becoming more complicated with the emergence of new concepts in power grids and the restructuring of power systems. This paper proposes a residual neural network for the highly accurate prediction of electric charges. In the network designed by combining two powerful deep residual networks, learning ability has been improved and problems such as overfitting and gradient reduction/increase have been avoided. Also, to fully learn the temporal and spatial features, a convolutional neural network (CNN) and a memory-based recurrent unit (GRU) are combined and integrated into the residual multilevel structure. Seasonal analyses and research on several different cases using real load data in Shiraz, Iran confirm the effectiveness of the method, and the superiority of the proposed method is demonstrated by comparison with previous methods.

Keywords: short-term load forecasting, multi-level deep residual neural network, recurrent memory network, convolutional neural network.

Submit date: 2022/07/11
Accepted date: 2023/06/27

Corresponding author's name: Mazda Moattari
Corresponding author's address: Department of Electrical Engineering, Marvdasht Branch, Islamic Azad University, Marvdasht, Iran

[Downloaded from ieijqp.ir on 2026-11-24]

[DOR: 20.1001.1.23222344.1402.12.2.1.2]

Iranian Electric Industry Journal
Quality & Productivity
ص.ص ۱۱-۱

Vol. 12 / No. 2/ Summer 2023
ISSN 2322-2344
EISSN 2717-1639

طراحی شبکه باقی‌مانده عصبی عمیق چند سطحی برای پیش‌بینی کوتاه‌مدت بارهای الکتریکی در سیستم‌های قدرت

نوع مطالعه: پژوهشی

مهتاب گنجوری[۱]، دانشجوی دکتری، مزدا معطری[۱،۲]*، استادیار، احمد فروزان‌تبار[۱]، استادیار، محمد آزادی[۲،۳]، استادیار

۱- دانشکده مهندسی برق، واحد مرودشت، دانشگاه آزاد اسلامی، مرودشت، ایران
۲- مرکز تحقیقات مکاترونیک و هوش مصنوعی، واحد مرودشت، دانشگاه آزاد اسلامی، مرودشت، ایران
۳- دانشکده مهندسی، واحد مرودشت، دانشگاه آزاد اسلامی، مرودشت، ایران
mahtab.ganjouri@miau.ac.ir, moattari@miau.ac.ir, a.forouzantabar@miau.ac.ir, mazadi@miau.ac.ir

چکیده: برای برقراری تعادل تولید-مصرف، طراحی یک روش که اطلاعات اولیه را برای بار مصرفی در ساعات آتی با سطح دقت و قابلیت اطمینان مطلوبی ضروری می‌باشد. مسئله‌ی پیش‌بینی بار با ظهور مفاهیم جدید در شبکه‌های برق و تجدید ساختار سیستم‌های قدرت روز به روز پیچیده‌تر می‌شود. این مقاله یک شبکه باقی‌مانده عصبی را برای پیش‌بینی با دقت بالای بارهای الکتریکی پیشنهاد می‌کند. در شبکه‌ی طراحی شده با ترکیب دو شبکه‌ی باقی‌مانده عمیق قدرتمند توانایی یادگیری ارتقا یافته و همچنین از مشکلاتی همچون بیش برازش و کاهش/افزایش گرادیان جلوگیری شده است. همچنین، برای یادگیری کامل مشخصات زمانی و مکانی، شبکه‌ی عصبی کانولوشنی (CNN) و واحد بازگشتی حافظه‌دار (GRU) ترکیب شده و در ساختار چندسطحی باقی‌مانده ادغام شده است. تحلیل‌ها فصلی و تحقیق بر روی چندین مورد مختلف با استفاده از داده‌های بار مصرفی واقعی در شهر شیراز، ایران مؤثر بودن روش را تایید می‌کند و برتری روش پیشنهاد از طریق مقایسه با روش‌های پیشین نشان داده شده است.

واژه‌های کلیدی: پیش‌بینی کوتاه‌مدت بار، شبکه‌ی عصبی باقی‌مانده عمیق چند سطحی، شبکه بازگشتی حافظه‌دار، شبکه‌ی عصبی کانولوشنی.

تاریخ ارسال مقاله: ۱۴۰۱/۰۴/۲۰
تاریخ پذیرش مقاله: ۱۴۰۲/۰۴/۰۶

نام نویسنده‌ی مسئول : مزدا معطری
نشانی نویسنده‌ی مسئول : دانشکده مهندسی برق، واحد مرودشت، دانشگاه آزاد اسلامی، مرودشت، ایران

[Downloaded from ieijqp.ir on 2026-11-24]

[DOR: 20.1001.1.23222344.1402.12.2.1.2]

۱- مقدمه

پیش‌بینی بار از آغاز ظهور صنعت برق از اهمیت بسیار زیادی برخوردار بوده است. پیش‌بینی بار در واقع پیش‌بینی بار در آینده است که نقش بسیار پررنگی در مدیریت انرژی سیستم و برنامه‌ریزی هرچه بهتر برای بهره‌برداری از سیستم بازی می‌کند. یکی از اساسی‌ترین اهداف در سیستم‌های قدرت برقراری تعادل بین تولید و مصرف است. برای رسیدن به این هدف نیاز است تا یک مقدار تخمینی مطلوب از بار در ساعات آتی در اختیار داشت که بتوان میزان تولید را با آن تطابق داد و این تعادل را برقرار ساخت (Afrasiabi, Mohammadi, Rastegar & Kargarian, 2019; Afrasiabi, Mohammadi, Rastegar & Afrasiabi, 2020). از این رو، یک تکنیک دقیق در پیش‌بینی بار مصرفی در شبکه‌های قدرت یکی از ضروریات اساسی در این شبکه‌ها می‌باشد که این امر در پست ۴۰۰ کیلو ولت انجام شده است. این روش باید قادر باشد:

الف) مشخصات زمانی و مکانی را با دقت بالایی در فرآیند پیش‌بینی بار لحاظ نماید.

ب) تأثیر مشخصات آب و هوایی که امروزه به راحتی در دسترس عموم قرار دارد و بر روی عملکرد شبکه تأثیر زیادی دارد را در فرآیند پیش‌بینی بار به صورت مطلوب در نظر بگیرد.

یکی از اهداف پیشنهاد روش عمیق مبتنی بر گراف، یادگیری همگرایی و شباهت‌های رفتار بین پارامترهای اقلیمی و بار مصرفی در این روش است. از این رو، 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+دما+رطوبت. مشخص است که در هر کدام از این چهار حالت یک مشخصه‌ی اقلیمی اضافه شده است تا روش پیشنهادی با یادگیری همگرایی و بر اساس رفتار این پارامترهای محیطی دقت روش پیشنهادی را افزایش بدهند. همچنین، در این مطالعه، عملکرد سالیانه در شکل ۵ این مقاله مورد بررسی قرار گرفته است.

ج) ساختار آن به نحوی باشد که عمومیت داشته باشد و قادر به یادگیری اتوماتیک مشخصات باشد. از این رو، در این مقاله هدف اصلی ارائه‌ی یک ساختار برای رفع چالش‌های اساسی بیان شده می‌باشد.

تاکنون مسئله‌ی پیش‌بینی کوتاه‌مدت بارهای الکتریکی به صورت گسترده مورد مطالعه قرار گرفته است (Samet, Ketabipour, Afrasiabi, Afrasiabi & Mohammadi, 2021). این روش ها را می‌توان به پنج دسته‌ی: ۱) روش پایدار، ۲) روش های فیزیکی، ۳) روش‌های آماری، ۴) روش‌های هوش مصنوعی، ۵) روش ها ترکیبی تقسیم نمود.

۱) روش پایدار: این روش با توجه به این که ماهیت متفاوتی از روش‌های دیگر دارد، در یک دسته‌بندی متفاوت قرار می‌گیرد و بیشتر به عنوان یک مدل برای مقایسه به کار گرفته می شود. اصول این روش بسیار ساده است و در آن مقدار بار مصرفی در بازه‌ی زمانی بعدی با مقدار آن در بازه‌ی زمانی پیشین آن برابر در نظر گرفته می‌شود. با افزایش بازه‌ی زمانی پیش‌بینی و در یک سری زمانی با تغییرات بالا هم چون بار های مصرفی در سیستم‌های قدرت امروزی این روش عملاً ناکارآمد است (Afrasiabi, Mohammadi, Rastegar & Kargarian, 2019).

۲) روش‌های فیزیکی: روش‌های فیزیکی معمولا به دنبال استخراج یک رابطه‌ی ریاضی بین بار مصرفی در ساعات آتی و میزان مصرفی در بازه‌ی زمانی فعلی و پیشین می‌باشد. با افزایش ورودی‌ها این مدل نیز به شدت پیچیده می‌شود. مدل پیش‌بینی عددی آب و هوا (NWP) یک مدل فیزیکی است که در پیش‌بینی آب و هوا به کار گرفته می شود. یافتن یک رابطه‌ی ریاضی برای پیش‌بینی یک سری زمانی غیرخطی همچون بارهای مصرفی بسیار دشوار و زمان‌بر است. از این رو، این روش برای پیش‌بینی های کوتاه مدت توصیه نمی شود (Afrasiabi, Mohammadi, Rastegar, Stankovic, Afrasiabi & Khazaei, 2020).

۳) روش‌های آماری: مدل‌های آماری با استفاده از اندازه‌گیری یک رابطه‌ی خطی را بین مقدار تابع در ساعات آتی و ساعات پیشین مدل می‌نمایند. این مدل‌ها که عمدتا از خانواده‌ی مدل‌های همبسته (AR) می‌باشند. از این مدل‌ها می‌توان به مدل میانگین خودهمبسته یکپارچه (ARIMA) (Lu, Niu & Jia, 2004)، مدل شرطی خود همبسته با واریانس ناهمگون (ARCH) (Chen, Wan, Zhang, Li & Wang, 2010)، مدل ARIMA با ورودی اگزوژن (ARIMAX) (Cui, & Peng, 2015) که در پیش‌بینی بار الکتریکی به کار گرفته شده‌اند، اشاره کرد. ایراد اساسی این مدل‌ها عملکرد بر اساس یک رابطه‌ی خطی است. سری‌های زمانی پیچیده همچون بارهای مصرفی را نمی توان با دقت مطلوب به صورت خطی مدل نمود (Afrasiabi, Afrasiabi, Parang & Mohammadi, 2020).

۴) روش‌های هوش مصنوعی: غیرایستا بودن و غیرخطی بودن سری‌های زمانی نام برده شده باعث شده است که مدل‌های مبتنی بر یادگیری ماشین بر مدل‌های پیشین برتری داشته باشند. در مدل‌های یادگیری ماشین هدف تقریب یک تابع برای تخمین سری‌های زمانی در بازه‌های زمانی آینده است. به طور کلی مدل‌های مبتنی بر یادگیری ماشین را می‌توان به دو دسته‌ی

[Downloaded from ieijqp.ir on 2026-11-24]

[DOR: 20.1001.1.23222344.1402.12.2.1.2]

کلی مدل‌های کم عمق و عمیق تقسیم‌بندی نمود (Afrasiabi, Afrasiabi, Parang & Mohammadi, 2019). مدل‌های کم‌عمق به صورت گسترده‌ای در پیش‌بینی بار مورد استفاده قرار گرفته‌اند. از میان این روش های کم‌عمق می توان به شبکه‌ی عصبی مصنوعی (ANN) (Chen, Canizares & Singh, 2001)، بردار پشتیبان ماشین (SVM) (Selakov, Cvijetinović, Milović, Mellon & Bekut, 2014)، درخت تصمیم‌گیری (Zhang, Wu, Wang & Bi, 2015)، جنگل تصادفی (Cheng, Chan & Qiu, 2012) و ... اشاره نمود. روش های کم‌عمق به مدل فیزیکی نیازی ندارند و قابلیت مدل‌سازی رفتار غیرخطی را دارند. در این روش‌ها تنها داده های پیشین و قدرت یادگیری اهمیت دارد. این روش ها در تعداد لایه‌های یادگیری با محدودیت مواجه هستند. از این رو قادر به استخراج و انتخاب ویژگی کامل از سری زمانی‌های زمانی پیچیده را ندارند. برای غلبه بر این مشکل دو راه کار وجود دارد: ۱) استفاده از ترکیب این روش‌ها با روش های دیگر ۲) استفاده از یادگیری عمیق.

۵) روش‌های ترکیبی: یکی از راه‌کار هایی که برای حل مشکل روش‌های پیشین هم چون روش های کم‌عمق به کار گرفته می‌شود، ترکیب این روش‌ها با روش‌های دیگر است. برای افزایش توانایی یادگیری از روش های هم چون تبدیل موجک (El-Hendawi & Wang, 2020)، کابرد مولفه‌های ذاتی (López, Zhong & Zheng, 2017)، مشخصات آماری (Liang, Niu & Hong, 2019) و ... استفاده می‌شود. هر چند روش هی ترکیبی به ترکیب استخراج ویژگی و شبکه‌های عصبی کم‌عمق محدود نمی‌شود. ترکیب روش‌های آماری و شبکه‌ی عصبی (Jagait, Fekri, Grolinger & Mir, 2021)، مدل‌های فیزیکی و مدل‌های کم‌عمق (Dong, Sun, Tan, Li, Zhang & Zhao, 2021) را می‌توان به عنوان نمونه‌ای از این روش ها نام برد. به طور کلی روش‌های ترکیبی و عمدتا روش‌های مبتنی بر استخراج ویژگی علاوه بر افزایش زمان محاسبات، به علت حساسیت بالا به نویز یک راه حل کلی برای پیش‌بینی محسوب نمی‌شوند.

راه‌کاری که ایرادات روش‌های پیشین را تا حدودی برطرف نموده است، شبکه‌های عصبی عمیق می‌باشند. روش ها یادگیری عمیق با تغییر تعداد لایه‌های پنهان از یک عدد به چندین عدد، دقت عملکرد خود را در مسائل مختلف تا حدود زیادی بهبود بخشیند و امروزه به یکی از مباحث جدی در علم مختلف تبدیل شده‌اند. سیستم‌های قدرت نیز از این قاعده مستثنی نیستند. در سیستم‌های قدرت، یادگیری عمیق برای تشخیص خطا در ماشین‌های الکتریکی (Afrasiabi, Mohammadi, Afrasiabi & Parang, 2021)، سیستم‌های انتقال (Afrasiabi, Afrasiabi, Mohammadi & Parang, 2020)، توربین‌های بادی (Afrasiabi, Afrasiabi, Parang, Mohammadi, Kahourzade & Mahmoudi, 2020)، کنترل‌کننده‌ی توربین های بادی (Samet, Ketabipour, Afrasiabi, Afrasiabi & Mohammadi, 2020) و ... به کار گرفته شده است. این پژوهش نیز یادگیری عمیق را مبنای کار خود قرار داده است. روش های یادگیری عمیق را می‌توان به ماشین‌های بولتزمن (BM)، روش های خودکار (AE)، شبکه‌های بازگشتی (RNN) و شبکه‌های عصبی کانولوشنی تقسیم‌بندی نمود. روش‌های BM و AE به ترتیب برای پیش‌بینی بار الکتریکی در (Kong, Li, Zheng & Wang, 2019) و (Chen, Wang, Wang & Li, 2019) به کار گرفته شده‌اند. این روش ها با وجود قدرت خودکار استخراج ویژگی در یادگیری کامل مشخات زمانی و مکانی با محدودیت‌های جدی مواجه هستند (Afrasiabi, Afrasiabi, Parang, Mohammadi, Kahourzade & Mahmoudi, 2020). روش‌های RNN، مخصوصا روش‌های حافظه‌دار بازگشتی همچون حافظه‌ی بلندمدت و کوتاه مدت (LSTM) و واحد بازگشتی حافظه‌دار (GRU)، قدرت بالایی در یادگیری مشخصات زمانی سری‌های زمانی دارند، هر چند این روش ها دارای ایرادا تی در یادگیری کامل مشخات ذاتی و مکانی یک سری زمانی و داده دارند. بر خلاف RNN، ساختار CNN قدرت بسیار بالایی در یادگیری مشخصات مکانی دارند، در حالی که در درک مشخصات زمانی با مشکل مواجه هستند. از سوی دیگر، محدودیت‌هایی که نا شی از مشکلاتی همچون برازش بیش از حد و کاهش و افزایش ناگهانی داده‌ها می‌باشد، باعث شده است که راه‌کار هایی مبتنی بر یادگیری عمیق همچنان با مشکلاتی مواجه باشند.

این مقاله یک ساختار یادگیری عمیق را ارائه نموده است که قادر به یادگیری کامل مشخصات زمانی و مکانی سری‌های زمانی بار های الکتریکی را داشته باشد. در این راستا، ابتدا یک ساختار باقی‌مانده عمیق جدید بر اساس ترکیب دو ساختار پیشین طراحی شده است تا علاوه بر افزایش قدرت یادگیری در سری زمانی و یادگیری تأثیر مشخصات آب و هوایی بر روی بار الکتریکی، قادر به جلوگیری از بروز مشکلاتی همچون بیش برازش داده‌ها و تغییرات ناگهانی گرادیان در حین روند آموش را داشته باشد. نکته‌ی دوم در مورد این روش، استفاده از ترکیب CNN و GRU برای یادگیری مشخصات زمانی و مکانی سری‌های زمانی است. نتایج این روش بر روی داده های واقعی شهر شیراز، ایران نشان از عملکرد مطلوب روش پیشنهادی دارد. به صورت خلاصه، می‌توان نوآوری‌های این مقاله را به صورت زیر خلاصه نمود:

- ارائه‌ی یک شبکه‌ی باقی‌مانده عصبی عمیق چند سطحی جدید در راستای افزایش قدرت یادگیری مشخات سری‌های زمانی پیچیده همچون بارهای الکتریکی،
- قابلیت یادگیری کامل مشخات زمانی با ترکیب CNN و GRU و ادغام آن در ساختار یادگیری عمیق چند سطحی ارائه شده،

[Downloaded from ieijqp.ir on 2026-11-24]

[DOR: 20.1001.1.23222344.1402.12.2.1.2]

- قابلیت مدل‌سازی تأثیر مشخصات آب و هوایی و فصلی در رفتار بار مصرفی،

این مقاله علاوه بر این قسمت از چهار قسمت دیگر تشکیل شده است: در قسمت دوم، مبانی شبکه‌ی عصبی باقی‌مانده عمیق آورده شده است. جزییات 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 شبکه عصبی باقی‌مانده عمیق

فرض کنید $X_{in}=\{X_t,X_{t-1},\cdots,X_{t-N}\}$ و خروجی $Y_{out}=\{Y_{t+1},Y_{t+2},\cdots,Y_{t+M}\}$ در سری زمانی مصرف بار باشد. در یک ساختار مبتنی بر داده، هدف تقریب یک تابع $f(X_{input},Y_{out})$ می‌باشد که قادر باشد یک مجموعه $\tilde{Y}_{out}$ را نگاشت نماید تا تفاوت بین $\tilde{Y}_{out}$ و Y_{out} کمینه باشد. برای اینکه این مقدار کمینه بدست آید. این مقاله یک ساختار مبتنی بر شبکه‌ی عصبی باقی‌مانده عمیق را پیشنهاد داده است. در این قسمت ابتدا مبانی شبکه‌ی عصبی باقی‌مانده عمیق ارائه شده است. سپس، ساختار طراحی شده معرفی شده‌است.

از مزایای اصلی شبکه‌های عمیق نسبت به شبکه‌های اصلی قابلیت اتصال تعداد بسیار بالایی از لایه‌های پنهان به یکدیگر است. این مشخصه باعث می‌شود که شبکه‌های یادگیری عمیق قدرت یادگیری بیشتری داشته باشند و بتوان به آن‌ها قدرت اتوماتیک استخراج/انتخاب ویژگی‌ها را اضافه نمود. با این وجود ممکن است که مشکلاتی از قبیل افزایش/ کاهش شدید مقدار گرادیان (Afrasiabi, Afrasiabi, Parang, Mohammadi, Samet & Dragicevic, 2021) و برازش بیش از حد (Afrasiabi, Afrasiabi, Behdani, Mohammadi, Javadi, Osório & Catalão, 2021) داشته باشد. در حین فرآیند آموزش بالا رفتن تعداد لایه‌ها، تعداد وزن‌ها و بایاس ها در آن متعاقبا افزایش می‌یابند. در حین فرآیند بدست آوردن وزن های بهینه یادگیری، این امکان وجود دارد که با افزایش و کاهش شدید ناگهانی مقدار گرادیان مواجه شویم. در این حالت بدست‌آوردن مقدار بهینه‌ی وزن‌های یادگیری دشوار خواهد بود. یک راه‌حل برای رفع این مشکل ساختار باقی‌مانده عمیق است.

ایده‌ی اصلی در شبکه‌ی عصبی باقی‌مانده استفاده از خروجی تعدادی از لایه به عنوان ورودی برای لایه‌های پیشین خود می‌باشد. در صورتی که تابع $f(X_{input},Y_{out})$ و تابع نگاشت ایده‌آل به صورت زیر تعریف شود:

$$f^*(X_{input},Y_{out})=f(X_{input},Y_{out}) \qquad (۱)$$

برای یک شبکه‌ی عصبی باقی‌مانده عمیق، این رابطه به صورت زیر تغییر می‌یابد:

$$f^*(X_{input},Y_{out})=f(X_{input},Y_{out})+X_{input} \qquad (۲)$$

مقدار اضافه شده در ساختار شبکه‌ی باقی‌مانده عمیق این ساختار را به یک ساختار پیش‌رو-پسرو تبدیل می‌کند. یک شبکه‌ی عمیق با N لایه‌ی مختلف می‌باشد. شبکه‌ی عمیق متداول تنها یک تابع برای تقریب رابطه‌ی بین X_{input} و f_N^* می‌باشد. درحالی که در شبکه‌های باقی‌مانده عمیق، وزن‌های بهینه‌ی $f_{N-1}^*-f_N^*$ بدست می‌آید. از این رو، بدست آوردن وزن‌های بهینه در این شبکه‌ها ساده‌تر می‌باشد و با افزایش تعداد لایه‌ها احتمال بروز مشکلاتی از قبیل افزایش/ کاهش شدید گرادیان و برازش بیش از حد را نیز می‌کاهد. همچنین، خروجی شبکه‌ی باقی‌مانده عمیق را می‌توان به صورت $f_N(X_{input},Y_{out})+\cdots+f_1(X_{input},Y_{out})+X_{input}$ نوشت.

۳- مدل DRT پیشنهادی برای پیش‌بینی بار

در این مقاله برای بالابردن دقت پیش‌بینی و غلبه بر مشکلات ساختارهای پیشین باقی‌مانده عمیق در پیش‌بینی بار مصرفی دو ساختار ارائه شده از ترکیب دو ساختار (Huang, Liu, Van Der Maaten & Weinberger, 2017) و (Zhang, Sun, Han, Yuan, Guo & Liu, 2017) اضافه شده است. شکل ۱ اول اولیه به کار گرفته شده در این شبکه را نشان می‌دهد. در ساختار تمام لایه باقی‌مانده ارائه شده در (Huang, Liu, Van Der Maaten & Weinberger, 2017) خروجی برابر است با:

$$f_N^*(X_{input},Y_{out})=f_N(X_{input},Y_{out})||f_{N-1}^*(X_{input},Y_{out})||f_{N-2}^*(X_{input},Y_{out})||\cdots||X_{input} \qquad (۳)$$

علامت $||$ به معنای الحاق (اتصال) می‌باشد.

ساختار خروجی در شبکه‌ی عصبی چندسطحی باقی‌مانده‌ی عمیق در (Afrasiabi, Afrasiabi, Parang & Mohammadi, 2019) نیز برابر است با:

$$f_N^*(X_{input},Y_{out})=f_{N-1}(X_{input},Y_{out})+f^{act}\left(Y^{CNN}\left(f_{N-1}^*(X_{input},Y_{out})\right)\right)+f^{act}\left(Y^{CNN}(X_{input})\right) \qquad (۴)$$

که f^{act} و Y^{CNN} به ترتیب تابع فعالیت و خروجی CNN را نشان می‌دهند.

ساختار ترکیبی باقی‌مانده‌ی پیشنهادی در این مقاله با ترکیب دو رابطه‌ی (۳) و (۴) برابر هستند با:

[Downloaded from ieijqp.ir on 2026-11-24]

[DOR: 20.1001.1.23222344.1402.12.2.1.2]

$$f_N^*(X_{input},Y_{out})=f'_{N-1}\left\|\begin{matrix}f^{act}(Y^{CNN}(f'_{N-1}))\|f_N^*(X_{input},Y_{out})\|X_{input}\|f_N^*(X_{input},Y_{out})\\ \|f_{N-1}^*(X_{input},Y_{out})\|\end{matrix}\right\| \quad (۵)$$

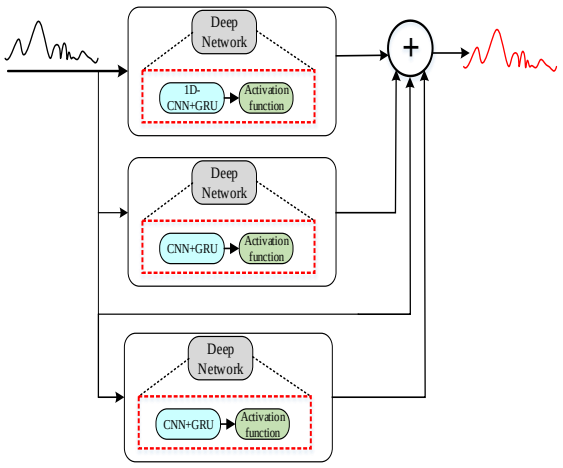

شکل ۱: ساختار پیشنهادی برای پیش‌بینی بار

۳-۱- ساختار CNN

از میان شبکه‌های مبتنی بر یادگیری عمیق، شبکه‌های CNN ابزار قدرتمندی برای استخراج ویژگی‌های مکانی می‌باشد. با توجه به این مشخصات محیطی از مکان های مختلفی جمع‌آوری می شوند، این مشخات و همگرایی آن‌ها با بار مصرفی اهمیت ویژه‌ای در مسئله‌ی پیش‌بینی سری زمانی بار دارد. پس از این که ورودی به شبکه داده شد، دو مرحله پردازش توسط CNN انجام می شود. در مرحله‌ی اول داده‌ها به داده‌های دو بعدی تبدیل شده و عملگر کانولوشن بر روی آن‌ها پیاده می‌شود. سپس، مهیان ویژگی های استخراج شده توسط لایه‌ی کانولوشنی، ویژگی‌های مطلوب توسط لایه‌ی جمع‌آوری انتخاب می‌شوند.

برای لایه‌ی L ام و خروجی m ام، خروجی لایه‌ی کانولوشنی برابر است با (Afrasiabi, Afrasiabi, Parang & Mohammadi, 2019):

$$y(m,L)=f\left\{\left[W\otimes x(n,L\text{-}1)+B(m,L)\right]\right\}\quad \forall m=1,...,y_{wi}\quad \forall n=1,...,y_{he} \quad (۶)$$

که $f\{.\}$ تابع فعال سازی، $B(m,L)$ ماتریس بایاس لایه‌ی کانولوشن در نگاشت خروجی m و لایه‌ی L ام هستند. S، W و $x(n,L\text{-}1)$ به ترتیب گام زمانی فیلتر، ماتریس وزن های لایه‌ی کانولوشن و ورودی‌های nام از لایه‌ی پیشین است. اندیس‌های wi و he به ترتیب پهنا و ارتفاع را در فیلتر نشان می‌دهند. علامت $\otimes$ عملگر کانولوشن را نشان می‌دهد.

با استفاده از کاهش ابعاد لایه‌ی جمع‌آوری کننده حداکثر از Over-fitting نیز جلوگیری می‌نماید. نگاشت خروجی m ام در لایه‌ی L ام لایه‌ی جمع‌آوری کننده حداکثر، به صورت زیر می‌باشد (Afrasiabi, Mohammadi, Rastegar & Afrasiabi, 2020):

$$y(m,L)=f\{[\omega(m,L)P(x(m,L-1))]+b(m,L)\}\quad \forall m=1,...,y_{wi} \quad (۷)$$

که $P(m,L)$ و $b(m,L)$ به ترتیب تابع جمع‌آوری و ماتریس بایاس لایه‌های جمع‌آوری L ام برای نگاشت ویژگی m ام را نشان می‌دهند.

۳-۲- ساختار GRU

شبکه‌ی GRU یک شبکه‌ی قدرتمند در استخراج ویژگی های پارامترهای متغیر با زمان است که از دو دروازه به نام‌های به‌روزسانی و تنظیم مجدد تشکیل شده است که (Afrasiabi, Afrasiabi, Jarrahi & Mohammadi, 2022):

$$u(m,L,t)=f\left[W_u y(m,L,t)+R_u h(L,t-1)+B_u(m,L)\right] \quad (۸)$$

$$r(m,L,t)=f\left[W_r y(m,L,t)+R_r h(L,t-1)+B_r(m,L)\right] \quad (۹)$$

که W_u، R_u و $B_u(m,L)$ به ترتیب ماتریس وزن، پارامتر بازگشتی و ماتریس بایاس لایه L ام و نگاشت m ام را برای دروازه به روزرسانی در مدل GRU نشان می‌دهند. همچنین، W_r، R_r و $B_r(m,L)$ به ترتیب ماتریس وزن، پارامتر بازگشتی و ماتریس بایاس لایه L ام و نگاشت m ام را برای دروازه تنظیم مجدد در مدل GRU نشان می‌دهند.

همچنین، حالت مخفی و حالت کاندید برای لایه‌ی L ام و در زمان t ام، $h(L,t)$ و $h'(L,t)$ به صورت زیر توصیف می‌شوند (Afrasiabi, Mohammadi, Rastegar, Stankovic, Afrasiabi & Khazaei, 2020):

$$h(L,t)=[1-u(m,L,t)h(L,t-1)]+u(m,L,t)h'(L,t) \quad (۱۰)$$

$$h'(L,t)=f\left[W_h y(m,L,t)+R_h h(L,t-1)+B_h(m,L)\right] \quad (۱۱)$$

که W_h، R_h و $B_h(m,L)$ به ترتیب نشان‌دهنده‌ی وزن ماتریس‌ها، پارامتر بازگشتی و بایاس ماتریس‌ها حالت مخفی در مدل GRU هستند. شکل ۲ ساختار درونی مدل GRU را نشان می‌دهد.

[Downloaded from ieijqp.ir on 2026-11-24]

[DOR: 20.1001.1.23222344.1402.12.2.1.2]

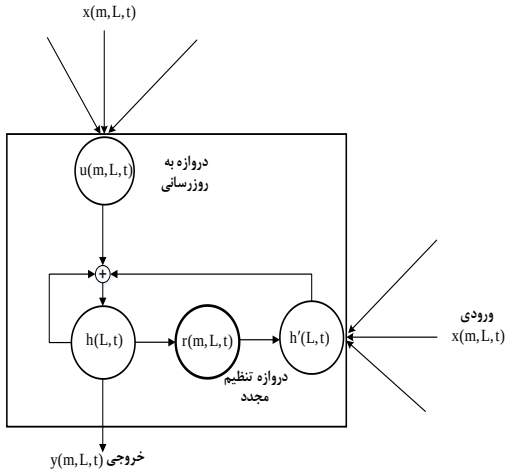

شکل ۲: ساختار درونی مدل GRU

۴- نتایج عددی

برای ارزیابی روش پیشنهادی از داده‌های واقعی استفاده می‌شود. این داده‌ها برگرفته از (I. R. M. Commission) می‌باشد. این اطلاعات بار شبکه‌ی برق شهر شیراز، ایران را دربرمی‌گیرد. از میان این داده‌های واقعی، اطلاعات یک سال شامل بارهای مصرفی خرداد ماه سال ۱۳۹۴ تا اواخر اردیبهشت ۱۳۹۵ جدا شده است. اطلاعات مورد استفاده قرار گرفته شده تنها شامل بارهای مصرفی نمی‌شود، بلکه شامل اطلاعات آب و هوایی شامل دمای محیط، فشار، سرعت باد و رطوبت هوا می‌شود. برای تایید عملکرد روش پیشنهادی، این روش با روش‌های زیر مقایسه شده‌است:

- شبکه‌ی عصبی کانولوشنی (CNN)
- شبکه‌ی عصبی نزدیک‌ترین همسایگی (kNN)
- شبکه‌ی عصبی مصنوعی (ANN)

در تمامی این شبکه‌ها حدود ۷۰٪ داده‌ها به آموزش و حدود ۳۰٪ داده‌ها به تست اختصاص داده شده است. برای شبیه سازی از نرم‌افزار python و یک سیستم با مشخصات 16GB RAM، Intel® Core ™i7-4770 CPU انجام شده‌است.

برای مقایسه بین روش‌های مختلف میانگین خطای جذر میانگین مربعات (RMSE)، میانگین خطای جذر میانگین مربعات نرمالیزه شده (NRMSE)، درصد میانگین قدر مطلق خطا (MAPE) و میانگین قدر مطلق خطا (MAE) می‌توانند، مورد استفاده قرارگیرند که رابطه‌های آن‌ها عبارتند از(Samet, Ketabipour, Afrasiabi, Afrasiabi & Mohammadi, 2021; Samet, Ketabipour, Afrasiabi, Afrasiabi & Mohammadi, 2020):

$$RMSE = \sqrt{\frac{1}{N}\sum_{i=1}^{N}\left(y_{se}^{i} - y_{re}^{i}\right)^{2}} \qquad (۱۲)$$

$$NRMSE = \frac{1}{y_{re}^{max}}\sqrt{\frac{1}{N}\sum_{i=1}^{N}\left(y_{se}^{i} - y_{re}^{i}\right)^{2}} \qquad (۱۳)$$

$$MAPE = \frac{1}{N}\sum_{i=1}^{N}\left|\frac{y_{se}^{i} - y_{re}^{i}}{y_{re}^{i}}\right| \times 100 \qquad (۱۴)$$

$$MAE = \frac{1}{N}\sum_{i=1}^{N}\left|y_{se}^{i} - y_{re}^{i}\right| \qquad (۱۵)$$

که N تعداد داده، y_{se}^{i} و y_{re}^{i} به ترتیب مقادیر تخمین زده شده و واقعی i ام هستند.

۴-۱- ارزیابی نتایج

در این قسمت نتایج بدست آمده از روش پیشنهادی مورد تجزیه و تحلیل قرار گرفته است. برای تحلیل نتایج، ساختار DTR پیشنهادی در دو قالب کلی متفاوت ارزیابی شده است که شامل آنالیز فصلی و تأثیرات مختلف مشخصات آب و هوایی می‌باشد.

برای ارزیابی فصلی نتایج دو فصل تابستان و زمستان انتخاب شده است. در هر دو فصل داده‌های با فاصله‌ی زمانی یک ساعت برای پیش‌بینی در نظر گرفته شده است و حدود ۳۰٪ از داده‌ها به تست و ۷۰٪ به آموزش روش پیشنهادی و روش‌های دیگر پرداخته شده‌است. شکل (۳) مقادیر واقعی را با مقادیر پیش‌بینی شده برای بازه‌ی زمانی حدود ۱۱۰ ساعت از روزهای فصل تابستان نشان می‌دهد. بر اساس این شکل، دقت روش پیشنهادی بسیار مطلوب می‌باشد. همان طور که از شکل نیز مشهود است، مقادیر بدست آمده از روش DTR پیشنهادی به مقادیر واقعی بسیار نزدیک است، حتی تشخیص این مقادیر از یکدیگر بسیار دشوار است.

زمان آموزش این روش ۸۷۶۰ ساعت می باشد که مدت زمان پاسخ تست آن زیر صدمی از ثانیه رخ می دهد و در زمان آفلاین حدود ۱ الی ۲ دقیقه می باشد.

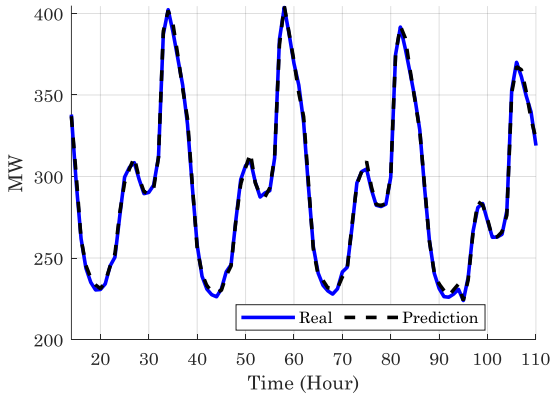

شکل ۳: مقایسه‌ی بین مقادیر پیش‌بینی‌شده و واقعی: فصل تابستان

[Downloaded from ieijqp.ir on 2026-11-24]

[DOR: 20.1001.1.23222344.1402.12.2.1.2]

از سوی دیگر، نتایج مقایسه‌ی این روش با روش های دیگر در جدول (۱) آورده شده است. مقدار MAPE کمتر از یک درصد به تنهایی می‌تواند نشان‌دهنده‌ی عملکرد بسیار مطلوب روش پیشنهادی در مقایسه با روش‌های دیگر باشد. بر اساس مقادیر MAPE، روش پیشنهادی حدود ۵/۵ ٪ از بقیه روش ها که بین ۰/۶۹ ٪ الی ۶/۵۹٪ می باشد عملکرد آن بهتر است که با وجود نوسانات زیاد انرژی الکتریکی در فصل تابستان بنا به موقعیت و شرایط آب و هوایی فصل شهر شیراز، روش پیشنهادی پتانسیل بالایی برای پیش‌بینی بار های الکتریکی دارد.

جدول ۱: مقایسه‌ی روش پیشنهادی با روش‌های CNN، kNN و ANN: فصل تابستان

روش	MAPE (%)	MAE (MW)	RMSE (MW)	NRMSE (%)
پیشنهادی	۰/۶۷	۱/۵۴	۲/۰۹	۰/۰۱۸
CNN	۰/۹۶	۴/۷۸	۸/۸۹	۰/۰۵۱
kNN	۶/۵۹	۳۳/۸۸	۴۰/۶۸	۰/۲۴
ANN	۴/۰۵	۱۹/۹۸	۲۶/۶۰	۰/۱۶

شکل (۴) بین بار پیش‌بینی شده و مقادیر واقعی در یک بازه‌ی زمانی ۱۱۰ ساعتی یک مقایسه انجام می‌دهد. این مقادیر بر اساس داده‌های فصل زمستان و شبکه‌ی آموزش داده شده بر اساس داده‌های فصل زمستان بدست آمده است. البته این نتایج تست روش پیشنهادی می‌باشند و این داده‌ها برای آموزش استفاده نشده‌اند. همانطور که از شکل (۴) مشخص است، به سختی می توان تفاوت نتایج را مشاهده نمود. این موضوع نشان‌دهنده‌ی دقت بالای روش پیشنهادی در پیش‌بینی بار در فصل زمستان می‌باشد.

نتایج برای کل داده‌های تست در فصل زمستان در این قسمت تحلیل شده است. نتایج بدست آمده از چهار معیار دقت متفاوت در جدول (۲) آورده شده‌است. تفاوت چشمگیر بین مقادیر خطای پیش‌بینی بدست آمده از روش پیشنهادی نسبت به روش های دیگر بسیار پایین‌تر است.

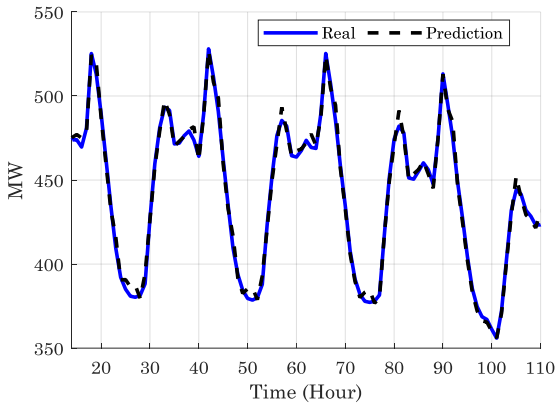

شکل ۴: مقایسه‌ی بین مقادیر پیش‌بینی‌شده و واقعی: فصل زمستان

به عنوان نمونه به مقادیر MAE بدست آمده توجه نمایید. بر اساس این معیار دقت، حدود ۵۶/۴۸ ٪، ۷۹/۴۲ ٪ و ۸۷/۵۳ ٪ روش پیشنهادی دقت مطلوب‌تری به ترتیب نسبت به CNN، kNN و ANN از خود در فصل زمستان نشان داده است. این دقت مطلوب عملکرد مطلوب روش پیشنهادی را در پیش‌بینی بارهای الکتریکی در فصل زمستان را نشان می‌دهد. با توجه به نتایج بدست آمده از روش پیشنهادی برای فصل زمستان و تابستان، می توان عملکرد و دقت مطلوب روش پیشنهادی را در پیش‌بینی بارهای الکتریکی به صورت فصلی تایید نمود.

جدول ۲: مقایسه‌ی روش پیشنهادی با روش‌های CNN، kNN و ANN: فصل زمستان

روش	MAPE (%)	MAE (MW)	RMSE (MW)	NRMSE (%)
پیشنهادی	۰/۶۹	۲/۸۹	۳/۹۱	۰/۰۲۳
CNN	۱/۴۳	۶/۶۴	۱۸/۷۱	۰/۰۴۱
kNN	۳/۰۹	۱۴/۰۴	۲۳/۸۲	۰/۰۵
ANN	۵/۲۷	۲۳/۱۸	۳۴/۵۴	۰/۰۷۲

در ادامه‌ی این قسمت، ارزیابی شبکه‌ی طراحی شده برای پیش‌بینی بار کل یک سال به صورت کامل بررسی شده‌است. برای این منظور حدود ۷۰٪ از داده‌های سالیانه برای آموزش و حدود ۳۰٪ از این داده‌ها برای تست شبکه‌ی طراحی شده و مقایسه‌ی آن با روش های دیگر استفاده شده است. یک بازه‌ی زمانی ۱۱۰ ساعتی از داده های تست در شکل (۵) انتخاب شده است تا مقادیر واقعی و پیش‌بینی شده را با یکدیگر مقایسه نمایند. مشابه با نتایج فصلی بدست آمده، در عملکرد سالیانه نیز دقت روش پیشنهادی به قدری مطلوب است که به سختی می‌توان تفاوتی بین مقادیر اقعی و پیش‌بینی شده قائل شد.

مقایسه‌ی عملکرد سالیانه با روش‌های دیگر بر مبنای معیار های دقت در جدول (۳) آورده شده است. دقت روش پیشنهادی با بیشتر شدن بازه‌ی زمانی نسبت به ارزیابی‌های فصلی کمی کاهش یافته است.

[Downloaded from ieijqp.ir on 2026-11-24]

[DOR: 20.1001.1.23222344.1402.12.2.1.2]

با وجود اینکه این کاهش مقادیر قابل نادیده گرفته شدن ا ست، دل یل آن بیشتر شدن نوسانات و پیچیده‌تر شدن رفتار سری ز مانی بار های الکتریکی با زیاد شدن اندازه‌ی توالی‌های این سری زمانی می‌با شد. با این وجود مقدار خطا در روش پیشنهادی ن سبت به سه روش دی گر کاملا محسوس می‌باشد.

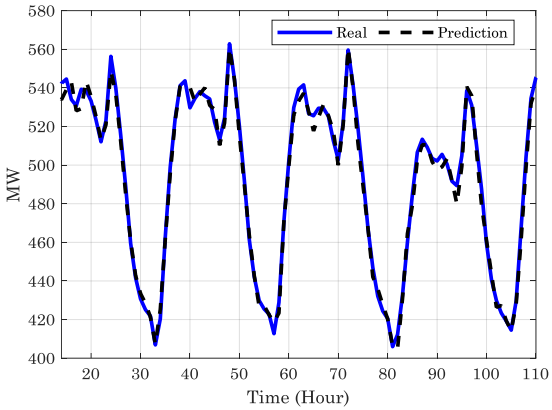

شکل ۵: مقایسه‌ی بین مقادیر پیش‌بینی‌شده و واقعی: عملکرد سالیانه

جدول ۳: مقایسه‌ی روش پیشنهادی با روش‌های CNN، kNN و ANN: فصل تابستان

روش	MAPE (%)	MAE (MW)	RMSE (MW)	NRMSE (%)
پیشنهادی	۰/۷۱	۳/۳۱	۴/۵۲	۰/۰۱۴
CNN	۱/۱۵	۵/۴۶	۱۲/۲۶	۰/۰۲۷
kNN	۵/۳۳	۲۶/۶۶	۳۴/۷۵	۰/۰۶۲
ANN	۴/۴۷	۲۱/۰۵	۲۸/۸۷	۰/۰۵۲

ی کی از عوا مل تأثیر گذار در روش پی شنهادی قابل یت یادگیری مشخ صات آب و هوایی می‌با شد و تأثیر ا ین مشخ صات در به بود پیش‌بینی بارهای الکتریکی مشخص شود. برای ارزیابی تأثیرات آب و هوایی چهار حالت متفاوت برای ورودی ها در آ موزش و ت ست برای بازه‌ی زمانی یک ساله در نظر گرفته شده است:

- بارهای مصرفی و سرعت باد
- بارهای مصرفی، سرعت باد و فشار اتمسفر
- ببارهای مصرفی، سرعت باد، فشار اتمسفر و دمای محیط
- بارهای مصرفی، سرعت باد، فشار اتمسفر، دما و رطوبت محیط

شکل (۵) مقادیر واقعی و پیش‌بینی شده را در ا ین چ هار حا لت متفاوت با یکدیگر مقایسه نموده است. میزان اختلاف بین مقادیر واقعی و پیش‌بینی شده با افزایش مشخصات آب و هوایی به داده ها از شکل (۵-الف) تا شکل (۵-د) به ترتیب کاهش می‌یا بد. در نتی جه ا فزایش مشخصات آب و هوایی باعث بهبود دقت روش پیشنهادی می‌شوند. هر چند این موضوع که مشخ صات آب و هوایی با عث به بود د قت در پیش‌بینی بار می‌شود، به خاطر همگرایی این مشخصات بار مصرفی با ویژگی‌های محیطی کاملاً مشخص است. ن تایج ا ین مو ضوع را ن شان می‌دهد که روش پیشنهادی در مقاله حاضر این قابلیت را دارد که ا ین مشخصات و همگرایی بین آن‌ها را استخراج کرده و به صورت مط لوبی در فرآیند یادگیری مورد ا ستفاده قرار د هد که از مزیت های روش پیشنهادی می‌باشد. همچنین، مقادیر معیار های د قت در جدول (۴) آورده شده است که ب توان تغی یرات عددی نا شی از ا ضافه ن مودن مشخصات آب و هوایی را به ع نوان ورودی در ساختار پیش‌بی نی بار پیشنهادی نشان داد.

جدول ۴: تأثیرات مشخات آب و هوایی بر روی دقت روش پیشنهادی در چهار حالت مختلف

ورودی	MAPE (%)	MAE (MW)	RMSE (MW)	NRMSE (%)
بار- باد	۱/۷۵	۷/۷۴	۱۰/۲۱	۰/۰۳۲
بار-باد-فشار	۰/۹۵	۴/۴۴	۵/۸۸	۰/۰۱۹
بار-باد-فشار-دما	۰/۷۹	۳/۵۳	۵/۲۷	۰/۰۱۷

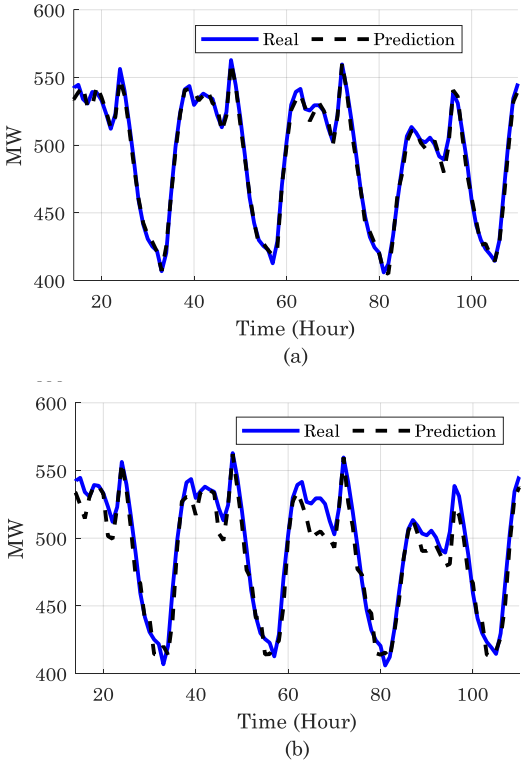

[Downloaded from ieijqp.ir on 2026-11-24]

[DOR: 20.1001.1.23222344.1402.12.2.1.2]

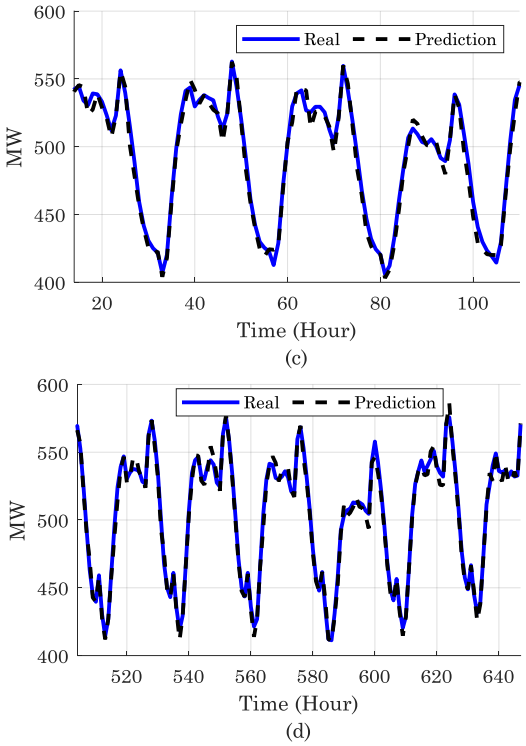

شکل ۵: مقایسه‌ی مقادیر واقعی و پیش‌بینی شده برای داده‌های یکسال با ورودی‌های مختلف : الف- بار-باد، ب- بار، باد و فشار، ج – بار، باد، فشار و دما، د – بار، باد، فشار، دما و رطوبت

۵- نتیجه‌گیری

با تغییرات عمده‌ای که در ساختار سیستم‌های قدرت در سال‌های اخیر رخ داده است و وابستگی روزافزون سیستم‌های صنعتی به انرژی الکتریکی، برنامه‌ریزی و بهره‌برداری سیستم‌های قدرت شکل پیچیده‌ای به خود گرفته است. یکی از عناصر اصلی در سیستم‌های قدرت که از اهمیت ویژه‌ای برخوردار است، بارهای الکتریکی می‌باشند. برقراری تعادل بین بار و مصرف یکی از اهداف اساسی سیستم‌های قدرت می‌باشند. از این رو، نیاز است که بارهای مصرفی با دقت بالایی پیش‌بینی شوند تا بتوان تعادل بین مصرف و تولید را برقرار نمود. با تغییرات به وجود آمده در سیستم‌های قدرت و افزایش تنوع در بین مصرف‌کنندگان انرژی الکتریکی، رفتارهای بارهای الکتریکی پیچیدگی خاصی به خود گرفته است که روش های کنونی قادر به پیش‌بینی دقیق بارهای الکتریکی نیستند. از این رو، در این مقاله یک ساختار مبتنی بر یادگیری عمیق طراحی شده است که قادر به یادگیری مشخصات زمانی و مکانی سری زمانی بارهای الکتریکی می‌باشند. نتایج عددی بر روی داده‌های واقعی شهر شیراز نشان می‌دهند که روش پیشنهادی دارای خطای کمتر از ۱٪ می‌باشد. همچنین در مقایسه با روش‌ها قدرتمندی همچون CNN، kNN و ANN حداقل اختلاف ۳۰٪ را از خود نشان می‌دهد. این نتایج پتانسیل بالای روش پیشنهادی در این مقاله را برای استفاده به عنوان یک موتور پیش‌بینی بار های الکتریکی نشان می‌دهد.

در این پژوهش هدف ارائه‌ی یک روش شناسایی پارامترهای بار بر اساس سیستم اندازه‌گیری گسترده بود که بر اساس یک تکنیک یادگیری عمیق با دقت بسیار مطلوبی این پارامترهای تخمین زده می‌شوند. مقدار خطای روش پیشنهادی با وجود نویز کمتر از ۰/۰۶ ٪ است که نشان دهنده‌ی عملکرد مطلوب آن است.

۶- مراجع

Afrasiabi, M., Afrasiabi, S., Parang, B., & Mohammadi, M. (2019). Power transformers internal fault diagnosis based on deep convolutional neural networks. *Journal of Intelligent & Fuzzy Systems*, *37*(1), 1165-1179.

Afrasiabi, M., Mohammadi, M., Rastegar, M., & Afrasiabi, S. (2020). Stochastic distributed microgrid energy management based on over-relaxed alternative direction method of multipliers. *IET Renewable Power Generation*, *14*(14), 2639-2648.

Afrasiabi, M., Mohammadi, M., Rastegar, M., & Afrasiabi, S. (2020). Advanced deep learning approach for probabilistic wind speed forecasting. *IEEE Transactions on Industrial Informatics*, *17*(1), 720-727.

Afrasiabi, M., Mohammadi, M., Rastegar, M., & Kargarian, A. (2019). Multi-agent microgrid energy management based on deep learning forecaster. *Energy*, *186*, 115873.

Afrasiabi, M., Mohammadi, M., Rastegar, M., & Kargarian, A. (2019). Probabilistic deep neural network price forecasting based on residential load and wind speed predictions. *IET Renewable Power Generation*, *13*(11), 1840-1848.

Afrasiabi, M., Mohammadi, M., Rastegar, M., Stankovic, L., Afrasiabi, S., & Khazaei, M. (2020). Deep-based conditional probability density function forecasting of residential loads. *IEEE Transactions on Smart Grid*, *11*(4), 3646-3657.

Afrasiabi, S., Afrasiabi, M., Behdani, B., Mohammadi, M., Javadi, M. S., Osório, G. J., & Catalão, J. P. (2021, September). Detection and localization of transmission line faults based on a hybrid two-stage technique considering wind power generation. In *2021 IEEE International Conference on Environment and Electrical Engineering and 2021 IEEE Industrial and Commercial Power Systems Europe (EEEIC/I&CPS Europe)* (pp. 1-5). IEEE.

Afrasiabi, S., Afrasiabi, M., Jarrahi, M. A., & Mohammadi, M. (2022). Fault location and faulty line selection in transmission networks: Application of

[Downloaded from ieijqp.ir on 2026-11-24]

[DOR: 20.1001.1.23222344.1402.12.2.1.2]

Cui, H., & Peng, X. (2015). Short-term city electric load forecasting with considering temperature effects: an improved ARIMAX model. *Mathematical Problems in Engineering*, *2015*.

Dong, W., Sun, H., Tan, J., Li, Z., Zhang, J., & Zhao, Y. Y. (2021). Short-term regional wind power forecasting for small datasets with input data correction, hybrid neural network, and error analysis. *Energy Reports*, *7*, 7675-7692.

El-Hendawi, M., & Wang, Z. (2020). An ensemble method of full wavelet packet transform and neural network for short term electrical load forecasting. *Electric Power Systems Research*, *182*, 106265.

Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q. (2017). Densely connected convolutional networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 4700-4708).

I. R. M. Commission, "Energy Surplus Instruction 88, available in: www," *IGMC. ir*.

Jagait, R. K., Fekri, M. N., Grolinger, K., & Mir, S. (2021). Load forecasting under concept drift: Online ensemble learning with recurrent neural network and ARIMA. *IEEE Access*, *9*, 98992-99008.

Kong, X., Li, C., Zheng, F., & Wang, C. (2019). Improved deep belief network for short-term load forecasting considering demand-side management. *IEEE transactions on power systems*, *35*(2), 1531-1538.

Liang, Y., Niu, D., & Hong, W. C. (2019). Short term load forecasting based on feature extraction and improved general regression neural network model. *Energy*, *166*, 653-663.

López, C., Zhong, W., & Zheng, M. (2017). Short-term electric load forecasting based on wavelet neural network, particle swarm optimization and ensemble empirical mode decomposition. *Energy Procedia*, *105*, 3677-3682.

Lu, J. C., Niu, D. X., & Jia, Z. Y. (2004, August). A study of short-term load forecasting based on ARIMA-ANN. In *Proceedings of 2004 International Conference on Machine Learning and Cybernetics (IEEE Cat. No. 04EX826)* (Vol. 5, pp. 3183-3187). IEEE.

Samet, H., Ketabipour, S., Afrasiabi, M., Afrasiabi, S., & Mohammadi, M. (2020). Deep learning forecaster-based controller for SVC: Wind farm flicker mitigation. *IEEE Transactions on Industrial Informatics*, *18*(10), 7030-7037.

Samet, H., Ketabipour, S., Afrasiabi, S., Afrasiabi, M., & Mohammadi, M. (2021). Prediction of wind farm reactive power fast variations by adaptive one-dimensional convolutional neural network. *Computers & Electrical Engineering*, *96*, 107480.

Selakov, A., Cvijetinović, D., Milović, L., Mellon, S., & Bekut, D. (2014). Hybrid PSO–SVM method for short-term load forecasting during periods with improved gated recurrent unit. *IEEE Systems Journal*, *16*(3), 5056-5066.

Afrasiabi, S., Afrasiabi, M., Mohammadi, M., & Parang, B. (2020). Fault localisation and diagnosis in transmission networks based on robust deep Gabor convolutional neural network and PMU measurements. *IET Generation, Transmission & Distribution*, *14*(26), 6484-6492.

Afrasiabi, S., Afrasiabi, M., Parang, B., & Mohammadi, M. (2019). Integration of accelerated deep neural network into power transformer differential protection. *IEEE Transactions on Industrial Informatics*, *16*(2), 865-876.

Afrasiabi, S., Afrasiabi, M., Parang, B., & Mohammadi, M. (2020). Designing a composite deep learning based differential protection scheme of power transformers. *Applied Soft Computing*, *87*, 105975.

Afrasiabi, S., Afrasiabi, M., Parang, B., Mohammadi, M., Kahourzade, S., & Mahmoudi, A. (2020, December). Two-stage deep learning-based wind turbine condition monitoring using SCADA data. In *2020 IEEE International Conference on Power Electronics, Drives and Energy Systems (PEDES)* (pp. 1-6). IEEE.

Afrasiabi, S., Afrasiabi, M., Parang, B., Mohammadi, M., Kahourzade, S., & Mahmoudi, A. (2020, December). Two-stage deep learning-based wind turbine condition monitoring using SCADA data. In *2020 IEEE International Conference on Power Electronics, Drives and Energy Systems (PEDES)* (pp. 1-6). IEEE.

Afrasiabi, S., Afrasiabi, M., Parang, B., Mohammadi, M., Samet, H., & Dragicevic, T. (2021). Fast GRNN-based method for distinguishing inrush currents in power transformers. *IEEE Transactions on Industrial Electronics*, *69*(8), 8501-8512.

Afrasiabi, S., Mohammadi, M., Afrasiabi, M., & Parang, B. (2021). Modulated Gabor filter based deep convolutional network for electrical motor bearing fault classification and diagnosis. *IET Science, Measurement & Technology*, *15*(2), 154-162.

Chen, H., Canizares, C. A., & Singh, A. (2001, January). ANN-based short-term load forecasting in electricity markets. In *2001 IEEE power engineering society winter meeting. Conference proceedings (Cat. No. 01CH37194)* (Vol. 2, pp. 411-415). IEEE.

Chen, H., Wan, Q., Zhang, B., Li, F., & Wang, Y. (2010, July). Short-term load forecasting based on asymmetric ARCH models. In *IEEE PES General Meeting* (pp. 1-6). IEEE.

Chen, H., Wang, S., Wang, S., & Li, Y. (2019). Day-ahead aggregated load forecasting based on two-terminal sparse coding and deep neural network fusion. *Electric Power Systems Research*, *177*, 105987.

Cheng, Y. Y., Chan, P. P., & Qiu, Z. W. (2012, July). Random forest based ensemble system for short term load forecasting. In *2012 international conference on machine learning and cybernetics* (Vol. 1, pp. 52-56). IEEE.

[Downloaded from ieijqp.ir on 2026-11-24]

[DOR: 20.1001.1.23222344.1402.12.2.1.2]

significant temperature variations in city of Burbank. *Applied Soft Computing*, *16*, 80-88.

Zhang, K., Sun, M., Han, T. X., Yuan, X., Guo, L., & Liu, T. (2017). Residual networks of residual networks: Multilevel residual networks. *IEEE Transactions on Circuits and Systems for Video Technology*, *28*(6), 1303-1314.

Zhang, P., Wu, X., Wang, X., & Bi, S. (2015). Short-term load forecasting based on big data technologies. *CSEE Journal of Power and Energy Systems*, *1*(3), 59-67.

[Downloaded from ieijqp.ir on 2026-11-24]

[DOR: 20.1001.1.23222344.1402.12.2.1.2]