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

Mahtab Ganjouri¹, Ph.D. Student, Mazda Moattari^{1,2*}, Assistant Professor, Ahmad forouzantabar¹, 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

طراحی شبکه باقی مانده عصبی عمیق چند سطحی برای پیش بینی کوتاه مدت بارهای الکتریکی در سیستم های قدرت

نوع مطالعه: پژوهشی

مهتاب گنججوری^۱، دانشجوی دکتری، مزدا معطری^{۱،۲*}، استادیار، احمد فروزان تبار^۱، استادیار، محمد آزادی^۳، استادیار

۱- دانشکده مهندسی برق، واحد مرودشت، دانشگاه آزاد اسلامی، مرودشت، ایران

۲- مرکز تحقیقات مکترونیک 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 می باشد. مسئله‌ی پیش بینی بار با ظهور مفاهیم جدید در شبکه های برق و تجدید ساختار سیستم های قدرت روز به روز پیچیده تر می شود. این مقاله یک شبکه باقی مانده عصبی را برای پیش بینی با دقت بالای بارهای الکتریکی پیشنهاد می کند. در شبکه‌ی طراحی شده با ترکیب دو شبکه‌ی باقی مانده عمیق قدرتمند توانایی یادگیری ارتقا یافته و همچنین از مشکلاتی همچون بیش برآزش و کاهش/افزایش گرادیان جلوگیری شده است. همچنین، برای یادگیری کامل مشخصات زمانی و مکانی، شبکه‌ی عصبی کانولوشنی (CNN) و واحد بازگشتی حافظه دار (GRU) ترکیب شده و در ساختار چندسطحی باقی مانده ادغام شده است. تحلیل ها فصلی و تحقیق بر روی چندین مورد مختلف با استفاده از داده های بار مصرفی واقعی در شهر شیراز، ایران مؤثر بودن روش را تایید می کند و برتری روش پیشنهاد از طریق مقایسه با روش های پیشین نشان داده شده است.

واژه های کلیدی: پیش بینی کوتاه مدت بار، شبکه‌ی عصبی باقی مانده عمیق چند سطحی، شبکه بازگشتی حافظه دار، 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

۱- مقدمه

(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 می‌شود. 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 بارهای مصرفی در سیستم‌های قدرت امروزه این روش عملاً ناکارآمد است (Afrasiabi, Mohammadi, Rastegar & Kargarian, 2019).

(۲) روش‌های فیزیکی: روش‌های فیزیکی معمولاً 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 می‌شود. یافتن یک رابطه‌ی ریاضی برای پیش‌بینی یک سری زمانی غیرخطی همچون بارهای مصرفی بسیار دشوار و زمان‌بر است. از این رو، این روش برای پیش‌بینی‌های کوتاه مدت توصیه نمی‌شود (Afrasiabi, Mohammadi, Rastegar, Stankovic, Afrasiabi & Khazaee, 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 عمدتاً از خانواده‌ی مدل‌های همبسته (AR) می‌باشند. از این مدل‌ها می‌توان به مدل میانگین خودهمبسته یکپارچه (ARIMA) (Lu, Niu & Jia, 2004)، مدل شرطی خودهمبسته با واریانس نا همگون (ARCH) (Chen, Wan, Zhang, Li & Wang, 2010)، مدل ARIMA با ورودی‌های گزینشی (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 نمی‌توان با دقت مطلوب به صورت خطی مدل نمود (Afrasiabi, Afrasiabi, Parang & Mohammadi, 2020).

(۴) روش‌های هوش مصنوعی: غیرایستنا 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

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 سیستم‌های بار دارد. 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 داشته که بتوان میزان تولید را با آن تطابق داد و این تعادل را برقرار ساخت (Afrasiabi, Mohammadi, Rastegar & Kargarian, 2019; Afrasiabi, Mohammadi, Rastegar & Kargarian, 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 کیلوولت 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+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 روش‌ها را می‌توان به پنج دسته‌ی: (۱) روش پایدار، (۲) روش‌های فیزیکی، (۳) روش‌های آماری، (۴) روش‌های هوش مصنوعی، (۵) روش‌ها ترکیبی تقسیم نمود.

توربین‌های بادی (Afrasiabi, Afrasiabi, Parang, Mohammadi, 2020) کنترل‌کننده توربین‌های بادی (Kahourzade & Mahmoudi, 2020) Samet, Ketabipour, Afrasiabi, Afrasiabi & Mohammadi, 2020) و ... به کار گرفته شده است. این پژوهش نیز یادگیری عمیق را مبنای کار خود قرار داده است. روش‌های یادگیری عمیق را می‌توان به ماشین‌های یولترن (BM)، روش‌های خودکار (AE)، شبکه‌های بازگشتی (RNN) و شبکه‌های عصبی کانولو شنی تقسیم‌بندی نمود. روش‌های AE و BM به ترتیب برای پیش‌بینی بار الکتریکی در (Kong, Li, Zheng & Wang, 2019) و (Chen, Wang, Wang & Li, 2019) به کار گرفته شده‌اند. این روش‌ها با وجود قدرت خودکار استخراج ویژگی در یادگیری کامل مشخات زمانی و مکانی با محدودیت‌های جدی مواجه هستند (Afrasiabi, Parang, Mohammadi, Kahourzade & Mahmoudi, 2020). روش‌های RNN، مخصوصاً روش‌های حافظه‌دار بازگشتی همچون حافظه‌ی بلندمدت و کوتاه مدت (LSTM) و واحدهای بازگشتی حافظه‌دار (GRU)، قدرت بالایی در یادگیری مشخصات زمانی سری‌های زمانی دارند، هر چند این روش‌ها دارای ایراداتی 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 ناشی از مشکلاتی همچون برآزش بیش از حد و کاهش و افزایش ناگهانی داده‌ها می‌باشد، باعث شده است که راه‌کارهایی 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 بارهای 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 برآزش داده‌ها و تغییرات ناگهانی گراد یان 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 داده‌های 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 مشخصات 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،

کلی مدل‌های کم عمق و عمیق تقسیم‌بندی نمود (Afrasiabi, Parang & Mohammadi, 2019). مدل‌های کم‌عمق به صورت گسترده‌ای در پیش‌بینی بار مورد استفاده قرار گرفته‌اند. از میان این روش‌های کم‌عمق می‌توان 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. روش‌های کم‌عمق به مدل فیزیکی نیازی ندارند و قابلیت مدل‌سازی رفتار غیرخطی را دارند. در این روش‌ها تنها داده‌های پیشین و قدرت یادگیری اهمیت دارد. این روش‌ها در تعداد لایه‌های یادگیری با محدودیت مواجه هستند. از این رو قادر به استخراج و انتخاب ویژگی کامل از سری زمانی‌های پیچیده را ندارند. برای غلبه بر این مشکل دو راه کار وجود دارد: (۱) استفاده از ترکیب این روش‌ها با روش‌های دیگر (۲) استفاده از یادگیری عمیق.

(۵) روش‌های ترکیبی: یکی از راه‌کارهایی که برای حل مشکل روش‌های پیشین همچون روش‌های کم‌عمق به کار گرفته می‌شود، ترکیب این روش‌ها با روش‌های دیگر است. برای افزایش توانایی یادگیری از روش‌های هم‌چون تبدیل موجک (El-López, Hendawi & Wang, 2020)، کاربرد مولفه‌های ذاتی (López, Zhong & Zheng, 2017)، مشخصات آماری (Liang, Niu & Hong, 2019) و ... استفاده می‌شود. هر چند روش‌های 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 روش‌ها نام برد. به طور کلی روش‌های ترکیبی و عمدتاً 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. روش‌های یادگیری عمیق با تغییر تعداد لایه‌های پنهان از یک عدد به چندین عدد، دقت عملکرد خود را در مسائل مختلف تا حدود زیادی بهبود بخشیدند 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)،

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

$$f^*(X_{input}, Y_{out}) = f(X_{input}, Y_{out}) + X_{input} \quad (2)$$

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. در حالی که در شبکه‌های باقی‌مانده عمیق، وزن‌های بهینه‌ی $f_N^* - f_{N-1}^*$ 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 $f_N(X_{input}, Y_{out}) + \dots + f_1(X_{input}, Y_{out}) + X_{input}$ نوشت.

۳- مدل DRT پیشنهادی برای پیش‌بینی بار

در این مقاله برای جابردن 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, 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:

$$f_N^*(X_{input}, Y_{out}) = f_N(X_{input}, Y_{out}) \parallel f_{N-1}^*(X_{input}, Y_{out}) \parallel \dots \parallel f_1(X_{input}, Y_{out}) \parallel X_{input} \quad (3)$$

علامت \parallel به معنای الحاق (اتصال) می‌باشد.

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

$$f_N^*(X_{input}, Y_{out}) = f_{N-1}(X_{input}, Y_{out}) + f^{act}(Y^{CNN}(f_{N-1}^*(X_{input}, Y_{out}))) + f^{act}(Y^{CNN}(X_{input})) \quad (4)$$

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:

• 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. 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 شبکه عصبی باقی‌مانده عمیق

فرض کنید $X_{in} = \{X_t, X_{t-1}, \dots, X_{t-N}\}$ و $X_{out} = \{Y_{t+1}, Y_{t+2}, \dots, Y_{t+M}\}$ 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 شده است.

از مزایای اصلی شبکه‌های عمیق نسبت به شبکه‌های اصلی قابلیت اتصال تعداد بسیار جالبی 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, 2021) داشته باشد. در حین فرآیند آموزش بالا رفتن تعداد لایه‌ها، تعداد وزن‌ها و بایاس‌ها در آن متعاقباً افزایش می‌یابند. در حین فرآیند بدست آوردن وزن‌های بهینه یادگیری، این امکان وجود دارد که با افزایش و کاهش شدید ناگهانی مقدار گرادیان مواجه شویم. در این حالت بدست آوردن 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 $f(X_{input}, Y_{out})$ تابع نگاشت ایده‌آل به صورت زیر تعریف شود:

$$f^*(X_{input}, Y_{out}) = f(X_{input}, Y_{out}) \quad (1)$$

می باشد (Afrasiabi, Mohammadi, Rastegar & Afrasiabi, 2020):

$$y(m,L) = f\{\omega(m,L)P(x(m,L-1))\} + b(m,L) \quad \forall m=1,\dots,y_{wi} \quad (7)$$

که $b(m,L)$ و $P(m,L)$ به ترتیب تابع جمع آوری و ماتریس بایاس لایه های جمع آوری L ام برای نگاشت ویژگی m ام را نشان می دهند.

۳-۲- ساختار GRU

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

$$u(m,L,t) = f[W_u y(m,L,t) + R_u h(L,t-1) + B_u(m,L)] \quad (8)$$

$$r(m,L,t) = f[W_r y(m,L,t) + R_r h(L,t-1) + B_r(m,L)] \quad (9)$$

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 روزسانی در مدل GRU نشان می دهد. 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 می دهند.

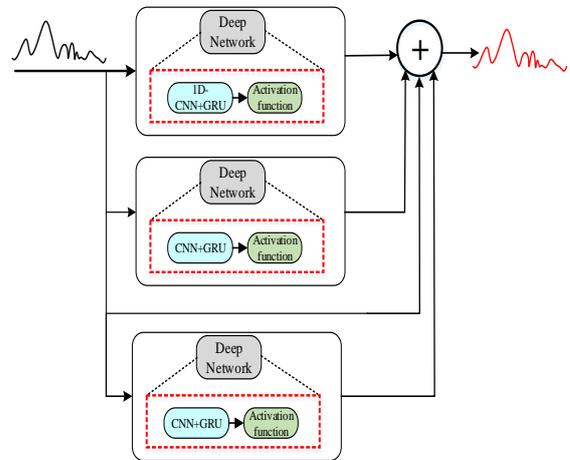
همچنین، حالت مخفی و حالت کاندید برای لایه L ام و در زمان t ام، $h(L,t)$ و $h'(L,t)$ به صورت زیر توصیف می شوند (Afrasiabi, Mohammadi, Rastegar, Stankovic, Afrasiabi & Khazaei, 2020):

$$h(L,t) = [1 - u(m,L,t)]h(L,t-1) + u(m,L,t)h'(L,t) \quad (10)$$

$$h'(L,t) = f[W_h y(m,L,t) + R_h h(L,t-1) + B_h(m,L)] \quad (11)$$

که W_h ، R_h و $B_h(m,L)$ به ترتیب نشان دهنده وزن ماتریس ها، پارامتر بازگشتی و بایاس ماتریس ها حالت مخفی در مدل GRU هستند. شکل ۲ ساختار درونی مدل GRU را نشان می دهد.

$$f_N^*(X_{input}, Y_{out}) = f_{N-1}^* \left(\left\| \begin{matrix} \text{fact} \left(Y_{N-1}^{CNN} \left(f_{N-1}^* \left(X_{input}, Y_{out} \right) \right) \right) \\ f_{N-1}^* \left(X_{input}, Y_{out} \right) \end{matrix} \right\| \right) \quad (5)$$



شکل ۱: ساختار پیشنهادی برای پیش بینی بار

۳-۱- ساختار CNN

از میان شبکه های مبتنی بر یادگیری عمیق، شبکه های CNN ابزار قدرتمندی برای استخراج ویژگی های مکانی می باشد. با توجه به این مشخصات محیطی از مکان های مختلفی جمع آوری می شوند، این مشخحات و همگرایی آن ها با بار مصرفی اهمیت ویژه ای در مسئله پیش بینی سری زمانی بار دارد. پس از این که ورودی به شبکه داده شد، دو مرحله پردازش توسط CNN انجام می شود. در مرحله اول داده ها به داده های دو بعدی تبدیل شده و عملگر کانولوشن بر روی آن ها پیاده می شود. سپس، میان ویژگی های استخراج شده توسط لایه کانولوشنی، ویژگی های مطلوب توسط لایه جمع آوری انتخاب می شوند.

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

$$y(m,L) = f\{[W \otimes x(n,L-1)] + B(m,L)\} \quad \forall m=1,\dots,y_{wi} \quad \forall n=1,\dots,y_{he} \quad (6)$$

که $f\{\cdot\}$ تابع فعال سازی، $B(m,L)$ ماتریس بایاس لایه کانولوشن در نگاشت خروجی m و لایه L ام هستند. W و $x(n,L-1)$ به ترتیب گام زمانی فیلتر، ماتریس وزن های لایه کانولوشن و ورودی های n ام از لایه پیشین است. اندیس های w_i و h_e به ترتیب پهنا و ارتفاع فیلتر را در فیلتر نشان می دهد. علامت \otimes عملگر کانولوشن را نشان می دهد.

با استفاده از کاهش ابعاد لایه جمع آوری کننده حداکثر از Over-fitting نیز جلوگیری می نماید. نگاشت خروجی m ام در لایه L ام لایه جمع آوری کننده حداکثر، به صورت زیر

$$\text{NRMSE} = \frac{1}{y_{re}^{max}} \sqrt{\frac{1}{N} \sum_{i=1}^N (y_{se}^i - y_{re}^i)^2} \quad (13)$$

$$\text{MAPE} = \frac{1}{N} \sum_{i=1}^N \left| \frac{y_{se}^i - y_{re}^i}{y_{re}^i} \right| \times 100 \quad (14)$$

$$\text{MAE} = \frac{1}{N} \sum_{i=1}^N |y_{se}^i - y_{re}^i| \quad (15)$$

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

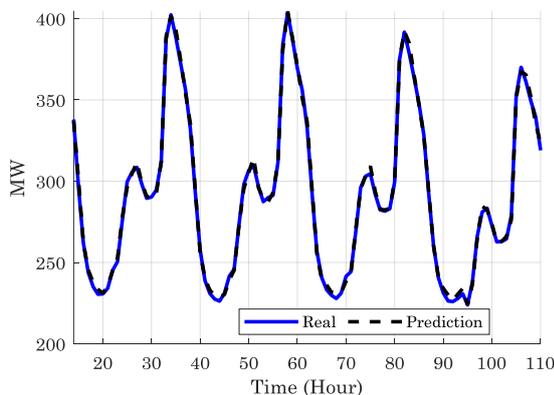
۴-۱- ارزیابی نتایج

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.

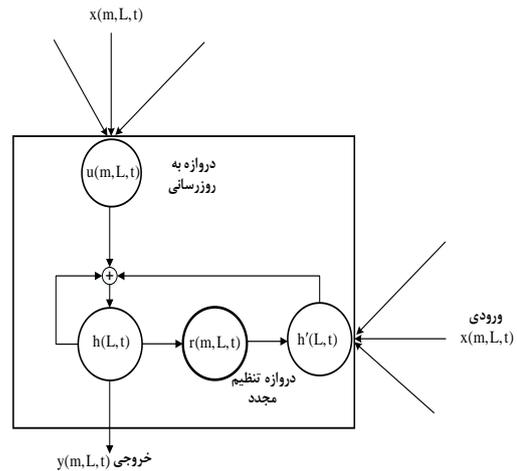
برای ارزیابی فصلی نتایج دو فصل تابستان و زمستان انتخاب شده است. در هر دو فصل داده‌های با فاصله‌ی زمانی یک ساعت برای پیش‌بینی در نظر گرفته شده است و حدود ۳۰٪ از داده‌ها به تست و ۷۰٪ به آموزش روش پیشنهادی و روش‌های دیگر پرداخته شده است.

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. همان‌طور 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 می‌باشد که مدت زمان پاسخ تست آن زیر صدمی از ثانیه رخ می‌دهد و در زمان آفلاین حدود ۱ الی ۲ دقیقه می‌باشد.



شکل ۳: مقایسه‌ی بین مقادیر پیش‌بینی شده و واقعی: فصل تابستان



شکل ۲: ساختار درونی مدل GRU

۴-۲ نتایج عددی

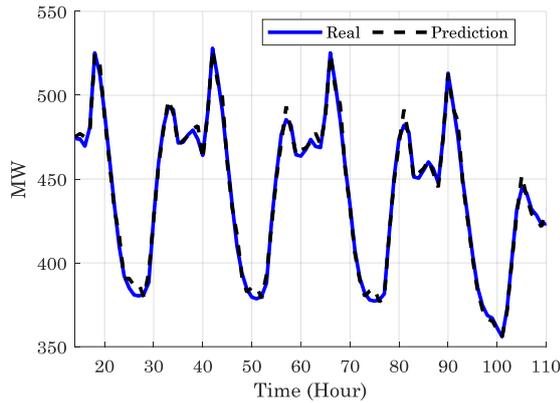
برای ارزیابی روش پیشنهادی از داده‌های واقعی استفاده می‌شود. این داده‌ها برگرفته از (I. R. M. Commission) می‌باشد. این اطلاعات بار شبکه‌ی برق شهر شیراز، ایران را دربرمی‌گیرد. از میان این داده‌های واقعی، اطلاعات یک سال شامل بارهای مصرفی خرداد ماه سال ۱۳۹۴ تا اواخر اردیبهشت ۱۳۹۵ جدا شده است. اطلاعات مورد 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 تأیید عملکرد روش پیشنهادی، این روش با روش‌های زیر مقایسه شده است:

- 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 شبیه‌سازی از نرم‌افزار python و یک سیستم با مشخصات Intel® Core, 16GB RAM و CPU i7-4770™ انجام شده است.

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

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_{se}^i - y_{re}^i)^2} \quad (12)$$



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

به عنوان نمونه به مقادیر MAE بدست آمده توجه نماید. 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، می‌توان عمل کرد 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	۰/۰۰۵
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 شده است. 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 روش‌های دیگر استفاده شده است. یک بازه‌ی زمانی ۱۱۰ ساعته از داده‌های 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 واقعی و پیش‌بینی شده قائل شد. مقایسه‌ی عملکرد سالیانه با روش‌های دیگر بر مبنای معیارهای دقت در جدول (۳) آورده شده است. دقت روش پیشنهادی با بیشتر شدن بازه‌ی زمانی نسبت به ارزیابی‌های فصلی کمی کاهش یافته است.

از سوی دیگر، نتایج مقایسه‌ی این روش با روش‌های 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 روش‌ها که بین $۰/۶۹\%$ الی $۶/۵۹\%$ می‌باشد 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 بارهای 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	۰/۰۲۴
ANN	۴/۰۵	۱۹/۹۸	۲۶/۶۰	۰/۰۱۶

شکل (۴) بین بار پیش‌بینی شده و مقادیر واقعی در یک بازه‌ی زمانی ۱۱۰ ساعته 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 می‌توان تفاوت نتایج را مشاهده نمود. این موضوع نشان‌دهنده‌ی دقت بالای روش پیشنهادی در پیش‌بینی بار در فصل زمستان می‌باشد.

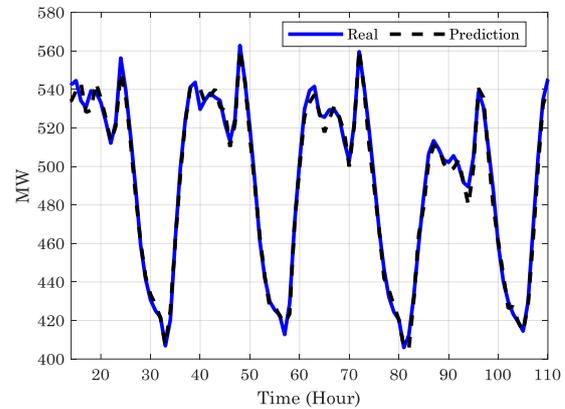
نتایج برای کل داده‌های تست در فصل زمستان در این قسمت تحلیل شده است. نتایج بدست آمده از چهار معیار دقت متفاوت در جدول (۲) آورده شده است. تفاوت چشمگیر بین مقادیر خطای پیش‌بینی بدست آمده از روش پیشنهادی نسبت به روش‌های دیگر بسیار پایین‌تر است.

پیش‌بینی بار می‌شود، به خاطر همگرایی این مشخصات بار مصرفی با ویژگی‌های محیطی کاملاً مشخص است. نتایج این موضوع را نشان می‌دهد که روش پیشنهادی در مقاله حاضر این قابلیت را دارد که این مشخصات و همگرایی بین آن‌ها را استخراج کرده و به صورت مطلوبی در فرآیند یادگیری مورد استفاده قرار دهد که از مزیت‌های روش پیشنهادی می‌باشد. همچنین، مقادیر معیارهای دقت در جدول (۴) آورده شده است که بتوان تغییرات عددی ناشی از اضافه نمودن مشخصات آب و هوایی را به عنوان ورودی در ساختار پیش‌بینی بار پیشنهادی نشان داد.

جدول ۴: تأثیرات مشخصات 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

با وجود اینکه این کاهش مقادیر قابل نادیده گرفته شدن است، دلیل آن بیشتر شدن نوسانات و پیچیده‌تر شدن رفتار سری زمانی بارهای الکتریکی با زیاد شدن اندازه‌ی توالی‌های این سری زمانی می‌باشد. با این وجود مقدار خطا در روش پیشنهادی نسبت به سه روش دیگر کاملاً محسوس می‌باشد.

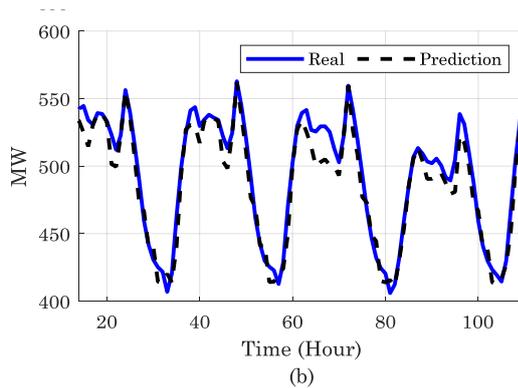
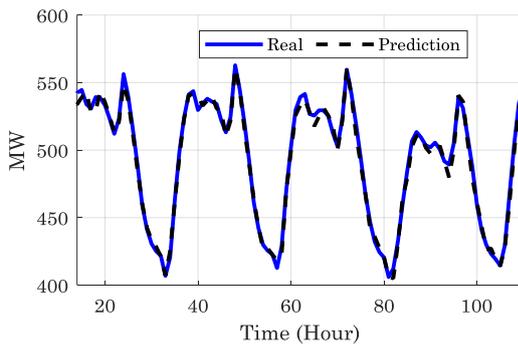


شکل ۵: مقایسه‌ی بین مقادیر پیش‌بینی شده و واقعی: عملکرد سالیانه

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

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



یکی از عوامل تأثیرگذار در روش پیشنهادی قابلیت یادگیری مشخصات آب و هوایی می‌باشد و تأثیر این مشخصات در بهبود پیش‌بینی بارهای الکتریکی مشخص شود. برای ارزیابی تأثیرات آب و هوایی چهار حالت متفاوت برای ورودی‌ها در آموزش و تست برای بازه‌ی زمانی یک ساله در نظر گرفته شده است:

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

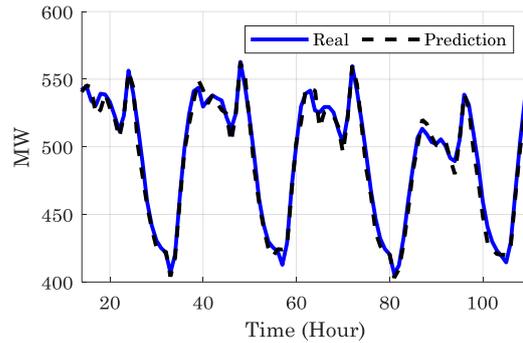
شکل (۵) مقادیر واقعی و پیش‌بینی شده را در این چهار حالت متفاوت با یکدیگر مقایسه نموده است. میزان اختلاف بین مقادیر واقعی و پیش‌بینی شده با افزایش مشخصات آب و هوایی به داده‌ها از شکل (۵-الف) تا شکل (۵-د) به ترتیب کاهش می‌یابد. در نتیجه افزایش مشخصات آب و هوایی باعث بهبود دقت روش پیشنهادی می‌شوند. هر چند این موضوع که مشخصات آب و هوایی باعث بهبود دقت در

الکتریکی نشان می‌دهد.

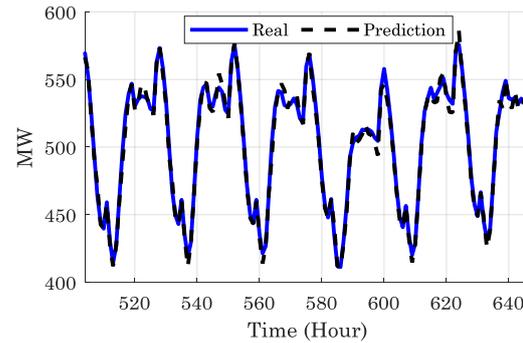
در این پژوهش هدف ارائه‌ی یک روش شناسایی پارامترهای بار بر اساس سیستم اندازه‌گیری گسترده بود که بر اساس یک تکنیک یادگیری عمیق با دقت بسیار مطلوبی این پارامترهای تخمین زده می‌شوند. مقدار خطای روش پیشنهادی با وجود نویز کمتر از ۰.۰۶٪ است که نشان دهنده‌ی عملکرد مطلوب آن است.

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



(c)



(d)

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 سال‌ها اخیر رخ داده است و وابستگی روزافزون سیستم‌های صنعتی به انرژی الکتریکی، برنا مهریزی و بهره‌برداری سیستم‌های قدرت شکل پیچیده‌ای به خود گرفته است. یکی از عناصرا 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 روش‌های 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 ۰.۱٪ 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 بارهای

- 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.

- 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.