

<https://dorl.net/dor/20.1001.1.23223871.1402.14.56.3.3>

Research Article

## **Electrical Load Parameter Identification using Multi-Variant Structure Based on Deep Learning**

**Omid Izadi-Ghaforkh<sup>1</sup>, Ph.D. Student, Mazda Moattari<sup>1,2</sup>, Assistant Professor, Ahmad Forouzantabar<sup>1</sup>, Assistant Professor**

<sup>1</sup>Department of Electrical Engineering- Marvdasht Branch, Islamic Azad University, Marvdasht, Iran

<sup>2</sup>Mechatronic and Artificial Intelligence Research Center- Marvdasht Branch, Islamic Azad University, Marvdasht, Iran

omid.izadi@miau.ac.ir, moattari@miau.ac.ir, a.forouzantabar@miau.ac.ir

### **Abstract**

Electrical load modeling has been considered an essential task in power system studies. With the recent development of power systems, load modeling is becoming more and more challenging. The previous methods on load modeling are suffered from: i) high sensitivity to noise; ii) neglecting the load correlation in a power system, iii) high computational burden, and iv) dependency on the local measurement devices. To address these problems, this paper develops a deep neural network-based structure that can identify a large number of parameters simultaneously with fast performance as well as high accuracy. The designed network can fully understand the temporal features using a gated recurrent neural network-based structure. Furthermore, to provide the ability to estimate a large number of load parameters, a technique to assign the learning weight has been developed. Consequently, to enhance the robustness of the designed network considering noisy conditions, a loss function has been developed in this paper. The numerical results on the IEEE 68-bus system demonstrate the effectiveness and superiority of the proposed network in comparison with several shallow-based and deep-based structures.

**Keywords:** gated recurrent network, load modeling, loss function, multi-variant deep learning, wide-area measurement system

**Received:** 24 July 2021

**Revised:** 28 January 2022

**Accepted:** 14 June 2022

**Corresponding Author:** Dr. Mazda Moattari

**Citation:** O. Izadi-Ghaforkh<sup>1</sup>, M. Moattari, A. Forouzantabar, "Electrical load parameter identification using multi-variant structure based on deep learning", Journal of Intelligent Procedures in Electrical Technology, vol. 14, no. 56, pp. 43-58, March 2024 (in Persian).

<https://dorl.net/dor/20.1001.1.23223871.1402.14.56.3.3>

مقاله پژوهشی

## شناسایی پارامترهای بارهای الکتریکی با استفاده از ساختار چند متغیره مبتنی بر یادگیری عمیق

امید ایزدی قهفرخی<sup>۱</sup>، دانشجوی دکتری، مزدا معطری<sup>۲</sup>، استادیار، احمد فروزان تبار<sup>۱</sup>، 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  
omid.izadi@miau.ac.ir, moattari@miau.ac.ir, a.forouzantabar@miau.ac.ir

چکیده: مدل‌سازی بار یکی از وظایف ضروری در مطالعات سیستم‌های قدرت محسوب می‌شوند. با توسعه سیستم‌های قدرت این مسئله بیش از پیش پیچیده‌تر شده است. روش‌های پیشین مدل‌سازی بار دارای عیوب اساسی مانند (الف) حساسیت بالا به نویز، (ب) عدم لحاظ همگرایی بارهای الکتریکی در یک شبکه، (ج) وابستگی به مدل ریاضی، (د) بار محاسباتی بالا و (ه) وابستگی به اندازه‌گیری محلی هستند. برای رفع این مشکلات، در این مقاله یک ساختار مبتنی بر یادگیری عمیق توسعه داده شده است که قادر به شناسایی تعداد زیادی از پارامترهای بار به صورت همزمان با سرعت و دقت مطلوب است. ساختار طراحی شده قادر به درک کامل ویژگی‌های زمانی بر مبنای یک ساختار حافظه‌دار بازگشته است. همچنین، برای تخمین تعداد متغیرهای زیاد یک روش اختصاص‌دهی وزن برای این مدل توسعه داده شده است. نهایتاً، یکتابع تلفات فرمول‌بندی شده است تا مقاوم بودن ساختار در برابر با نویز را افزایش دهد. مطالعات عددی بر روی شبکه IEEE ۶۸-شینه موثور بودن و برتری روش پیشنهادی را در مقایسه با تعدادی از روش‌های کم-عمق و عمیق را نشان می‌دهد.

کلمات کلیدی: تابع تلفات، ساختار یادگیری عمیق چند متغیره، سیستم اندازه‌گیری گستردگی، شبکه بازگشته حافظه‌دار، مدل‌سازی بار

تاریخ ارسال مقاله: ۱۴۰۰/۵/۲

تاریخ بازنگری مقاله: ۱۴۰۰/۱۱/۸

تاریخ پذیرش مقاله: ۱۴۰۱/۳/۲۴

نام نویسنده‌ی مسئول: دکتر مزدا معطری  
نشانی نویسنده‌ی مسئول: مرودشت-دانشگاه آزاد اسلامی واحد مرودشت-دانشکده مهندسی- گروه کنترل

## ۱- مقدمه

بارهای الکتریکی از مهم‌ترین و اساسی‌ترین اجزای سیستم‌های قدرت به شمار می‌روند. بارهای الکتریکی از تغییرات پارامترهای مانند فرکانس، ولتاژ و جریان تاثیر می‌پذیرند و متناسب رفتار بارهای الکتریکی در تغییرات این پارامترها به شدت زیاد است. در پایداری سیستم‌های قدرت که یکی از اهداف اساسی در طراحی و بهره‌برداری هر یک از شبکه‌های قدرت است، برقراری تعادل تولید-بار است [۱]. مدل‌سازی بار موضوعی است که در تمامی بخش‌های سیستم قدرت مانند توزیع و انتقال یک امر کاملاً حیاتی به حساب می‌آید. در مسئله مدل‌سازی بار دو گام اساسی وجود دارد. انتخاب مدل و نحوه تخمین پارامترهای بار این دو گام را تشکیل داده‌اند. مدل‌های بار به سه دسته استاتیکی، دینامیکی و ترکیبی تقسیم‌بندی می‌شوند [۲]. برای پوشش دقیق رفتار بارهای الکتریکی مدل‌های ترکیبی گزینه‌های مطلوبی هستند. مدل ترکیبی امپدانس-جریان-توان<sup>۱</sup> (ZIP) و موتور القایی با وجود سادگی نسبت به مدل‌های ترکیبی دیگر، قادر به پوشش رفتار دینامیکی و استاتیکی بار مصرفی است [۲]. از این‌رو مدل ترکیبی ZIP و موتور القایی در این پژوهش در نظر گرفته شده است. مسئله مدل‌سازی بار در واقع یک مسئله شناسایی پارامترهای بار است. روش‌های شناسایی بار به دو دسته کلی روش‌های مبتنی بر اجزای تشکیل دهنده و اندازه‌گیری تقسیم‌بندی می‌شود [۲]. در روش‌های مبتنی بر اجزای تشکیل دهنده بار اساس کار استفاده از اطلاعات مربوط به اجزای تشکیل دهنده بار است. در این دسته از روش‌ها مولفه‌های مختلف بار با یکدیگر جمع می‌شوند و یک مدل تجمعی را تشکیل می‌دهند. این روش‌ها نیاز به اطلاعاتی در مورد ترکیب بارها شامل درصد مصرف توان هر کدام از مولفه‌های بار دارد [۳]. مهم‌ترین چالش در مدل‌سازی بار بر اساس این روش تعیین ترکیب بار است. به‌طوری که می‌توان محاسبه مصرفی جزیی هر مولفه بار را در یک سیستم قدرت را حتی غیرممکن دانست. همچنین ترکیب بار تحت تاثیر موقعیت جغرافیایی و شرایط آب و هوایی قرار می‌گیرد. پروفیل مصرف تجهیزات متفاوت در فصل‌های مختلف سال تفاوت دارد. از این‌رو حتی با وجود کنترلرهای هوشمند که اندازه‌گیری توان تجهیزات و لوازم مختلف را تا حدودی میسر ساخته، به‌دست آوردن ترکیب بار بسیار دشوار و زمانبر است و یک راه کار کلی برای مدل‌سازی بار به حساب نمی‌آید. از این‌رو، تمرکز اصلی پژوهش‌های اخیر بر روی روش‌های مبتنی بر اندازه‌گیری استوار است. در روش‌های مبتنی بر اندازه‌گیری یک مدل فشرده برای بار متصل به شین مدد نظر است.

مدل‌های مبتنی بر اندازه‌گیری بر اساس آزمایش‌های گستردۀ عملی و مطالعات چندین سال تعیین شده‌اند.

مراحل اصلی مدل‌سازی بار بر اساس اندازه‌گیری شامل ۱) به‌دست آوردن اطلاعات اندازه‌گیری، ۲) انتخاب ساختار مدل، ۳) شناسایی پارامترهای مدل و ۴) اعتبارسنجی مدل است. مدل‌سازی مبتنی بر اندازه‌گیری از اندازه‌گیری واقعی برای ترسیم مدل بار استفاده می‌کند. این اندازه‌گیری‌ها باید در شرایط مختلف و تحت اغتشاش‌های متفاوت به‌دست آیند. پارامترهای مدل با کمینه‌سازی بین مدل بار و اندازه‌گیری‌های واقعی انجام می‌شود [۴]. روش‌های مدل‌سازی بار به سه دسته مختلف تقسیم می‌شوند که عبارتند از: ۱) روش‌های مبتنی بر بهینه‌سازی، ۲) روش‌های مبتنی بر مدل‌سازی فیزیکی و ۳) روش‌های مبتنی بر داده. در دسته اول از روش‌های شناسایی پارامتر بار الکتریکی، مبنای اساسی کمینه‌سازی یک تابع هزینه است. در این تابع هزینه بر اساس مقادیر اندازه‌گیری شده و پارامترهای نامعلوم مدل بار تعیین می‌شود. این تابع هزینه مبتنی بر فاصله بین مقادیر نامعلوم بار و مقادیر اندازه‌گیری شده است. هر چقدر اختلاف این مقادیر کمینه شود، پارامترهای تخمینی مدل بار دقیق‌تر خواهند بود. برای کمینه‌سازی این اختلاف فاز است تا تابع هدف مبتنی بر فاصله با استفاده از یک روند مطلوب فرمول‌بندی شود. سپس، این روند با استفاده از یک الگوریتم بهینه‌سازی مطلوب کمینه می‌شود. بر این اساس تاکنون تحقیقات مختلفی تاکنون ارائه شده است. دو دسته روش‌های بهینه‌سازی فرآبتكاری<sup>۲</sup> و روش‌های کلاسیک بهینه‌سازی<sup>۳</sup> در این زمینه استفاده شده‌اند. از الگوریتم‌های فرآبتكاری مورد استفاده قرار گرفته در این زمینه می‌توان به الگوریتم فرآبتكاری ژنتیک که در مرجع [۵] برای مدل‌سازی بار مورد استفاده قرار گرفته است، اشاره نمود. در این راستا روش‌های بهینه‌سازی ازدحام ذرات در مرجع [۶] و همچنین الگوریتم شبیه‌سازی تبرید در مرجع [۷] اشاره شده است. از میان روش‌های کلاسیک نیز می‌توان به روش‌های بهینه‌سازی مارکوارت-لونبرگ در مرجع [۸] و همچنین فرمول‌بندی ارائه شده در مرجع [۹] برای مدل‌سازی بار اشاره نمود که روش ارائه شده در مرجع [۹] بر مبنای حداقل مربعات حل می‌شود. همچنین، یک روش مبتنی بر حداقل

مربعات که در آن مدل بارهای ZIP متصل به ادوات الکترونیک قدرت برای مدل‌سازی مورد استفاده قرار گرفته‌اند در مرجع [۱۰] بیان شده است. روش‌های مبتنی بر بهینه‌سازی دارای چندین ایراد اساسی هستند که می‌توان به دو مورد زیر اشاره کرد: ۱) بار محاسباتی بالا: پارامترهای بار متغیر با زمان هستند. روش‌های مبتنی بر بهینه‌سازی، برای هر نقطه و برای هر زمان خاص باید یک بهینه‌سازی انجام دهنند. با توجه به این که هر بهینه‌سازی مدت زمانی را در برمی‌گیرد، از این‌رو برای تخمین پارامترهای بار که با زمان تغییر می‌کنند، هزینه محاسباتی بالایی را در بر می‌گیرند.

۲) حساسیت به نویز: با توجه به این که در این دسته از روش‌ها به پارامترهای اندازه‌گیری واپستگی زیادی دارند، نویز به عنوان یک پدیده غیرقابل اجتناب بر دقت روش تاثیر می‌گذارد و باعث می‌شود تا به صورت چشم‌گیری دقت کاهش یابد.

دسته دوم از روش‌های مدل‌سازی بار، روش‌های فیزیکی و یا مبتنی بر مدل هستند. در این روش‌ها، مسئله شناسایی پارامتر به صورت یک مدل فضای حالت توصیف می‌شود. این بیان ریاضی مبنای شناسایی پارامترهای مدل بار است. قالب روش‌های مبتنی بر مدل فیزیکی را روش‌های مبتنی بر فیلتر کالمون تشکیل می‌دهند. از تحقیقات انجام گرفته بر مبنای روش‌های فیزیکی می‌توان به مرجع [۱۱] اشاره نمود که در آن فیلتر کالمون برای تخمین پارامترهای مدل ترکیبی بار مشکل از مدل موتور القایی و مدل استاتیکی (مدل ZIP) مورد استفاده قرار گرفته است. فیلتر کالمون در حالت کلی تنها قادر به شناسایی مدل‌های خطی است. از این‌رو، مدل‌های توسعه یافته بر مبنای فیلترهای کالمون نیز برای شناسایی پارامترهای بار مورد استفاده قرار گرفته‌اند. در این راستا، می‌توان به فیلتر کالمون اشاره نمود که در مرجع [۱۲] مورد استفاده قرار گرفته است. فیلترهای کالمون و مدل‌های توسعه یافته آن‌ها با بالا رفتن تعداد پارامترها (بالا رفتن عدد بار در شناسایی پارامترهای بار بر مبنای سیستم اندازه‌گیری گسترده) دقت آن‌ها تحت تاثیر قرار می‌گیرد. مشکل دیگر روش‌های مبتنی بر مدل، واپستگی به مدل نویز است. در روش‌ها فیزیکی که در شناسایی پارامترهای بار مورد استفاده قرار می‌گیرند، باید مدل نویز نیز از پیش تعیین شده باشد، در حالی که در واقعیت این امر عملاً میسر نیست. دسته سوم روش‌های مدل‌سازی بار را روش‌های مبتنی بر داده تشکیل می‌دهند. از میان روش‌های داده محور، روش‌های مبتنی بر یادگیری ماشین<sup>۴</sup> و هوش مصنوعی<sup>۵</sup> در زمینه‌ی مدل‌سازی بار به کار گرفته می‌شوند. این روش بر مبنای یک روند آموزش و تست عمل می‌کنند. به این صورت که ابتدا بر اساس داده‌های پیشین یک ساختار با پارامترهای مختلف طراحی می‌شود. سپس این ساختار آموزش داده شده، به صورت یک مazzoول از پیش آموزش داده شده به کار گرفته می‌شود. این ساختار از پیش آموزش داده شده و یا داده محور این قابلیت را دارد که با سرعت بسیار و بدون واپستگی به مدل نویز، پارامترهای بار را شناسایی نمایند. روش‌های داده محور را می‌توان به دو دسته کم-عمق و عمیق تقسیم‌بندی نمود [۱۳]. تفاوت عمده میان روش‌های کم-عمق و روش‌های عمیق در تعداد لایه‌های پنهان آن‌ها است. شبکه‌های کم-عمق از یک مجموعه ورودی، خروجی و یک لایه‌های پنهان تشکیل شده است، در حالی که تعداد لایه‌های پنهان در ساختارهای عمیق می‌تواند تعدادی بیشتر از یک باشد. از میان روش‌های کم-عمق که تاکنون در مسئله مدل‌سازی بار به کار گرفته شده است، می‌توان به شبکه عصبی مصنوعی<sup>۶</sup> [۱۴]، شبکه مدل محلی<sup>۷</sup> [۱۵]، و ماشین بردار پشتیبان<sup>۸</sup> [۱۶] اشاره نمود. همچنین، روش درخت تصمیم‌گیری برای مدل‌سازی بارهای دینامیکی در مرجع [۱۷] ارائه شده است. روش ترکیبی k-نزدیک‌ترین همسایگی<sup>۹</sup> (kNN) و جنگل تصادفی<sup>۱۰</sup> برای شناسایی پارامترهای مدل ZIP در مرجع [۱۸] پیشنهاد شده است. از میان روش‌های مبتنی بر یادگیری عمیق نیر روش حافظه بلند کوتاه-مدت<sup>۱۱</sup> (LSTM) [۱۹] استفاده شده است که برای شناسایی مدل‌های ترکیبی استفاده شده که در مرجع [۲۰] از روش SVM برای شناسایی پارامترهای این مدل استفاده شده است. محدود بودن تعداد لایه‌های پنهان به یک عدد باعث شده تا دقت روش‌های کم-عمق در مواجه با سری‌های زمانی پیچیده و غیرخطی کاهش یابد که این پیچیدگی در شبکه‌های قدرت امروزی افزایش یافته است. یکی دیگر از مواردی که در تحقیقات انجام شده در زمینه مدل‌سازی بار باید در نظر گرفت، نحوه پیاده‌سازی آن است. مدل‌سازی بار می‌تواند بر اساس اندازه‌گیری محلی و یا بر اساس سیستم‌های اندازه‌گیری امروزی انجام داد. در شناسایی پارامترهای بار بر اساس اندازه‌گیری‌های محلی، تنها مجموع بارهای متصل به یک شین مدل‌سازی می‌شوند. در این حالت مسئله شناسایی پارامترهای بار آسان‌تر است، هر چند در صورت به وجود آمدن اختلال، نویز و یا خراب شدن یک تجهیز باعث می‌شود تا دیگر مدل‌سازی بار میسر نیاشد. از سوی دیگر، در پیاده‌سازی عملی برای مدل‌سازی بار در هر شین باید یک مazzoول اختصاص یابد، این امر

باعث بالا رفتن هزینه‌ها می‌شود. در اندازه‌گیری بر مبنای سیستم‌های اندازه‌گیری وسیع، مسئله شناسایی پارامترهای بار بسیار پیچیده می‌شود. از سوی دیگر همگرایی بین بارهای الکتریکی در شناسایی پارامترهای بار بر مبنای اندازه‌گیری‌های محلی نادیده گرفته می‌شود. هر چند، تنها یک مژول برای شناسایی بار کافی است و سیستم‌های اندازه‌گیری با تعدادی محدود از تجهیزات اندازه‌گیری قادر به انجام شناسایی بار هستند. از این‌رو، در پیاده‌سازی عملی استفاده از اندازه‌گیری‌های وسیع مورد مطلوب‌تری محسوب می‌شود. در استفاده از اندازه‌گیری‌های وسیع در جهت شناسایی پارامترهای بار، استفاده از روش‌های مبتنی بر بهینه‌سازی باعث بالارفتن هزینه‌های محاسباتی می‌شود و همچنین، بالارفتن تعداد متغیرهای تصمیم (تعداد پارامترهایی که باید شناسایی شوند). بالا رفته و دقت نیز متعاقباً کاهش می‌باید. مدل‌سازی ریاضی یک شبکه گسترده نیز از سوی دیگر بسیار دشوار است که از این روش‌های فیزیکی نیز در این مسائل قابل استفاده نیستند. همچنین، همگرایی بین بارهای در شناسایی پارامترهای بار بر مبنای روش‌های فیزیکی و مبتنی بر بهینه‌سازی نادیده گرفته می‌شود. این پیچیدگی تنها بر روش‌های مبتنی بر مدل و بهینه‌سازی تاثیرگذار نیست، بلکه روش‌های کم‌عمق نیز دقت آن‌ها با بالا رفتن تعداد متغیرهای قابل تخمین بار کاهش می‌باید. مطالب بیان شده در جدول (۱) به صورت خلاصه آمده است. از سوی دیگر همان‌طور که پیش‌تر نیز بیان شد، روش‌های یادگیری عمیق دارای این ظرفیت هستند که ایرادهای روش‌های پیشین را کاهش دهند. یادگیری عمیق نتایج مطلوبی در پیش‌سری‌های زمانی مانند بارهای الکتریکی [۲۱]، قیمت بازار برق [۲۲]، توان بادی [۲۳] و خورشیدی [۲۴] ارائه شده است. همچنین، یادگیری عمیق برای تشخیص خطا در ماشین‌های الکتریکی [۲۵]، سیستم‌های انتقال [۲۶]، توربین‌های بادی [۲۷]، کنترل‌کننده توربین‌های بادی [۲۸] و ... به کار گرفته شده است. از این‌رو، این پژوهش یادگیری عمیق را مبنای کار خود قرار داده است. هر چند ساختارهای متداول یادگیری عمیق دارای ایرادهایی است که می‌توان به موارد زیر اشاره نمود:

۱- ساختار باید قابلیت تخمین چندین متغیر را به صورت همزمان داشته باشد. در نتیجه باید یک ساختار چند-متغیره طراحی شود.

۲- ساختارهای متداول در برابر نویز چندان مقاوم نیستند. از این‌رو باید در ساختار طراحی شده، مکانیزمی تعییه شود تا این ساختار مبتنی بر یادگیری در برابر با نویزهای اندازه‌گیری که پدیده‌ای غیرقابل اجتناب در سیستم‌های اندازه‌گیری است، مقاوم باشد.

۳- قابلیت یادگیری پارامترهای متغیر با زمان را داشته باشد و در نتیجه قدرت بالایی در یادگیری مشخصات زمانی داشته باشند.

این مقاله یک ساختار چند متغیره یادگیری عمیق را برای تخمین بار بر مبنای اندازه‌گیری سیستم‌های گسترده قدرت پیشنهاد داده است. در این راستا یک فرآیند وزن‌دهی مورد استفاده قرار گرفته تا ساختار یادگیری عمیق پیشنهادی قادر به تخمین تعداد خروجی‌های زیادی باشد که به عنوان ساختار مبتنی بر یادگیری عمیق چند متغیره مورد استفاده قرار بگیرد.

Table (1): Summary of previous researches

جدول (۱): خلاصه تحقیقات پیشین

روش	توصیف	مزیت	عيوب
مبتنی بر بهینه‌سازی	کمینه‌سازی فاصله‌ی بین مقادیر نامعلوم بار و مقادیر اندازه‌گیری	عدم وابستگی به مدل ریاضی شبکه	بار محاسباتی بالا حساسیت بالا به نویز نادیده گرفتن همگرایی بین بارها
مبتنی بر مدل فیزیکی	شناسایی پارامترهای بار بر مبنای مدل	سرعت مطلوب و پیاده‌سازی آسان	وابستگی به مدل ریاضی نویز باید از پیش تعیین شود
مبتنی بر داده	مبتنی بر داده‌های پیشین و روند آموزش و تست	سرعت بالا عدم وابستگی به مدل ریاضی نادیده گرفتن همگرایی بین بارها	حساسیت به نویز کاهش دقت با بالارفتن تعداد متغیر

برای یادگیری مشخصات زمانی و ویژگی‌های متغیر با زمان بهصورت مطلوب از یک ساختار حافظه‌دار بازگشتی عمیق استفاده شده که قادر به یادگیری مشخصات متغیر با زمان است. همچنین، برای افزایش مقاوم بودن روش در برابر با نویز، یک تابع تلفات ارائه شده است. بهطور خلاصه می‌توان نوآوری‌های این مقاله را بهصورت زیر بیان نمود:

- روش‌های یادگیری عمیق ابزار قدرتمندی در تخمین به شمار می‌روند، از این‌رو یکی از نوآوری‌های این پژوهش ارائه روشهای دقت بالا و سرعت مطلوب است.

- در این پژوهش سعی در استفاده از داده‌های خام است. بر این اساس روش ارائه شده قابلیت عمومی بودن خود را نشان می‌دهد و به روش استخراج ویژگی دیگری نیاز ندارد.

- روش مبتنی بر یادگیری عمیق ارائه شده قادر خواهد بود که ویژگی‌های وابسته به زمان را از یک سری زمانی بلند بهطور مطلوب و تنها متنکی بر ساختار خود استخراج نماید.

- روش پیشنهادی قادر به استخراج کامل مشخصات زمانی و مکانی است و همچنین در مقابل تغییرات و نویز نیز مقاوم‌سازی شده است.

ساختار مقاله در ادامه به این شرح است. پس از بیان مسئله در مرور تحقیقات گذشته در این قسمت، در قسمت دوم، مدل بار اشاره شده است. جزییات روش پیشنهادی یادگیری عمیق در قسمت سوم بیان شده است. نتایج عددی در قسمت چهارم مورد تجزیه و تحلیل قرار گرفته و در نهایت در قسمت پنجم نتیجه‌گیری آورده شده است.

## ۲- مدل بار بر مبنای اندازه‌گیری سیستم گستردگ

مدل متغیر با زمان در این پژوهش متشکل از دو مولفه اصلی استاتیکی و دینامیکی است تا بتواند تا حد ممکن رفتار بار را دقیق مدل نماید. شکل (۱) مدار معادل مدل را نشان می‌دهد.

### ۲-۱- مدل موتور القایی

مدل متغیر با زمان موتور القایی (IM) بهصورت مشابه با ماشین سنکرون تعريف می‌شود. در این پژوهش از مدل متداول موتور تک روتوری قفس سنجابی استفاده می‌شود. پارامترهای مدل موتور القایی در جدول (۲) آمده است. معادلات حالت مدل IM برابر است با:

$$\dot{v}_t^d = \frac{-r_R^t}{x_R^t + x_m^t} \left[ v_t^d + \frac{(x_m^t)^2}{x_m^t + x_R^t} i_q^t \right] + s^t v_q^t \quad (1)$$

$$\dot{v}_q^q = \frac{-r_R^t}{x_R^t + x_m^t} \left[ v_q^q - \frac{(x_m^t)^2}{x_m^t + x_R^t} i_d^t \right] - s^t v_d^t \quad (2)$$

$$\dot{s}_t = \frac{1}{2H^t} \left[ T_m (1-s_t)^2 - v_d^t i_d^t - v_q^t i_q^t \right] \quad (3)$$

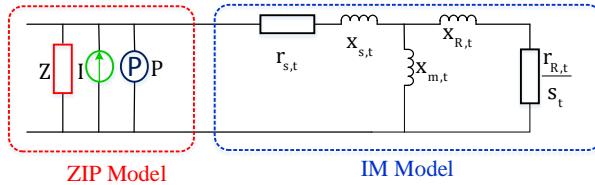
جريان استاتور در راستای محورهای  $d$  و  $q$  عبارتند از:

$$i_d^t = \frac{r_s^t (u_d^t - v_d^t) + x_{sh}^t (u_q^t - v_q^t)}{(r_s^t)^2 + (x_{sh}^t)^2} \quad (4)$$

$$i_q^t = \frac{r_s^t (u_q^t - v_q^t) - x_{sh}^t (u_d^t - v_d^t)}{(r_s^t)^2 + (x_{sh}^t)^2} \quad (5)$$

همچنین رابطه زیر برای ولتاژ باس در راستای محورهای  $d$  و  $q$  برقرار است:

$$(V_b^t)^2 = (u_d^t)^2 + (u_q^t)^2 \quad (6)$$



شکل (۱): مدار معادل مدل ترکیبی امپدانس-جریان-توان و موتور القایی [۱۹]  
Figure (1): Equivalent circuit of the ZIP hybrid model of induction motor [19]

Table (2): Induction motor model parameters

جدول (۲): پارامترهای مدل موتور القایی

پارامتر	کمیت
ولتاژ گذرا در راستای محور d	$V_d^t$
ولتاژ گذرا در راستای محور q	$V_q^t$
لغزش	$S^t$
مقاومت روتور	$r_R^t$
راکتانس روتور	$X_R^t$
اینرسی موتور	$H^t$
گشتاور مکانیکی	$T_m$
جریان استاتور در راستای محورهای d و q	$i_d^t, i_q^t$
ولتاژ بس در راستای محورهای d و q	$u_d^t, u_q^t$
زمان	t
توان اکتیو مدل ZIP	$P_t^{ZIP}$
توان راکتانس مدل ZIP	$Q_t^{ZIP}$
درصد توان اکتیو در مدل ZIP	$\alpha_t^P \gamma_t^P \beta_t^P$
درصد توان راکتانس در مدل ZIP	$\alpha_t^Q \gamma_t^Q \beta_t^Q$

مدل بار ترکیبی متغیر با زمان یک مدل پیچیده است که بین پارامترهای مدل بار و پارامترهای اندازه‌گیری رابطه غیرخطی وجود دارد. به طور کلی می‌توان این رابطه را به صورت زیر توصیف نمود:

$$X_{sh}^t = X_s^t + \frac{X_m^t X_R^t}{X_m^t + X_R^t} \quad (7)$$

توان اکتیو و راکتانس در مدل IM بر اساس پارامترهای متغیر با زمان، متغیرهای حالت و ولتاژ بس‌های متصل به بار به دست می‌آیند.

$$P_{IM}^t = \frac{\left\{ r_s^t \left[ \left( u_d^t \right)^2 + \left( u_q^t \right)^2 - u_d^t v_d^t - u_q^t v_q^t \right] - X_{sh}^t \left( u_d^t v_q^t - u_q^t v_d^t \right) \right\}}{\left( r_s^t \right)^2 + \left( X_{sh}^t \right)^2} \quad (8)$$

$$Q_{IM}^t = \frac{\left\{ X_{sh}^t \left[ \left( u_d^t \right)^2 + \left( u_q^t \right)^2 - u_d^t v_d^t - u_q^t v_q^t \right] - r_s^t \left( u_d^t v_q^t - u_q^t v_d^t \right) \right\}}{\left( r_s^t \right)^2 + \left( X_{sh}^t \right)^2} \quad (9)$$

## ۲-۲- مدل امپدانس-جریان-توان

رفتار استاتیکی بارهای الکتریکی بر مبنای مدل ZIP مدل می‌شود. توان اکتیو و راکتانس مصرفی در مدل ZIP برابرند با:

$$P_t^{ZIP} = \alpha_t^P \left( \frac{V_t}{V_b} \right)^2 + \beta_t^P \left( \frac{V_t}{V_b} \right) + \gamma_t^P \quad (10)$$

$$Q_t^{ZIP} = \alpha_t^Q \left( \frac{V_t}{V_b} \right)^2 + \beta_t^Q \left( \frac{V_t}{V_b} \right) + \gamma_t^Q \quad (11)$$

در تخمین پارامترهای مدل ZIP باید توجه داشت که:

$$\alpha_t^P + \beta_t^P + \gamma_t^P = 1 \quad (12)$$

$$\alpha_t^Q + \beta_t^Q + \gamma_t^Q = 1 \quad (13)$$

### ۲-۳- مدل ترکیبی متداول

مدل ترکیبی بر اساس توان اکتیو و راکتیو مصرفی توصیف می‌شود. مدل توان اکتیو و راکتیو بار ترکیبی متغیر با زمان برابر است با:

$$P_{com}^t = P_{ZIP}^t + P_{IM}^t \quad (14)$$

$$Q_{com}^t = Q_{ZIP}^t + Q_{IM}^t \quad (15)$$

از این‌رو می‌توان پارامترهای بار و پارامترهایی را که براساس سیستم اندازه‌گیری در هر شین می‌توان به دست آورد را به صورت زیر بیان نمود:

$$\Theta_{d^0}^t = [r_s^t, x_s^t, x_m^t, x_R^t, r_R^t, H^t, \alpha_t^P, \alpha_t^Q, \beta_t^P, \beta_t^Q] \quad (16)$$

$$\Psi_{d^0}^t = [P_{com}^t, Q_{com}^t, V_b^t] \quad (17)$$

### ۲-۴- مدل ترکیبی بر مبنای اندازه‌گیری گستردگی سیستم

پارامترهای متغیر با بار و پارامترهای قابل اندازه‌گیری برای یک پنجره زمانی دارای اطلاعات زمانی N بازه زمانی پیشین به ترتیب برابرند با:

$$\Theta^t = (\Theta^{t-1}, \Theta^{t-2}, \dots, \Theta^{t-N}) \quad (18)$$

$$\Psi^t = (\Psi^{t-1}, \Psi^{t-2}, \dots, \Psi^{t-N}) \quad (19)$$

با در نظر گرفتن ابعاد،  $d^0$  و  $d^{\Psi}$  ابعاد پارامترهای مدل ترکیبی متغیر با زمان و پارامترهای اندازه‌گیری را نشان می‌دهند، مدلی که در سیستم وسیع باید شناسایی شود بر مبنایتابع زیر مدل می‌شود:

$$\Theta_{d^0}^t = f(\Psi_{d^0}^t) + e_{\Psi} \quad (20)$$

اگر چه این تابع را نمی‌توان به صورت تحلیلی حل و پارامترهای بار متغیر با زمان را تخمین زد. از این‌رو از یادگیری عمیق برای رفع این مشکل استفاده می‌شود.

### ۳- ساختار روش یادگیری عمیق چند متغیره برای مدل‌سازی بار بر مبنای سیستم اندازه‌گیری گستردگی

در این قسمت توضیحات ساختار توسعه یافته مبتنی بر روش ارائه شده در مرجع [۲۸] و در این مقاله توسعه داده شده است. در مرجع [۲۸] که برای استفاده در ترجمه‌های هوشمند کامپیوترا طراحی شده موضوع نویز در نظر گرفته نشده است و ساختار بر مبنای روش بازگشتی ساده است که دارای سه ایراد عدمه زیر است:

۱- دسترسی به اطلاعات بازه‌های پیشین وجود ندارد، زیرا برای شبکه حافظه تعییه نشده است.

۲- ورودی‌های بعدی برای بهبود فرآیند یادگیری و عملکرد لحاظ نمی‌شوند.

۳- ویژگی‌هایی که زائد هستند و در فرآیند یادگیری خلل ایجاد می‌کنند، در شبکه حفظ می‌شوند.

پارامترهای به کار برده شده در روابط ساختار یادگیری عمیق در جدول (۳) معرفی شده‌اند. در این ساختار بردار ورودی به عنوان بردار  $c$  در نظر گرفته می‌شود. همچنین حالت پنهان  $h_t$  در زمان  $t$  به صورت زیر تعریف می‌شود:

$$h_t = f^{act}(x_t, h_{t-1}) \quad (21)$$

که  $c$  بردار خروجی در تخمین پارامترهای متغیر با زمان بار برابر است با:

$$c = u(\{h_1, \dots, h_N\}) \quad (22)$$

در این پژوهش از واحد بازگشتی حافظه‌دار<sup>۱۲</sup> (GRU) استفاده شده است. شبکه GRU یک شبکه قدرتمند در استخراج ویژگی‌های پارامترهای متغیر با زمان مانند متغیرهای مدل ترکیبی بار است. شبکه GRU دارای دو دروازه فراموشی و به روزرسانی است که در آن داریم:

$$u_{m,l}^t = f[\omega^u y_{m,l}^t + r^u h_l^{t-1} + \beta^u] \quad (23)$$

$$r_{m,l}^t = f[\omega^r y_{m,l}^t + r^r h_l^{t-1} + \beta^r] \quad (24)$$

همچنین، پارامترهای  $y$ ،  $r$  و  $h$  به ترتیب ماتریس وزن‌ها، خروجی، پارامتر بازگشتی، حالت پنهان و ماتریس بایاس را نشان می‌دهند. همچنین اندیس‌ها و بالانویس‌های  $l$  و  $m$  به ترتیب نشان‌دهنده شماره لایه و نگاشت است. همچنین، حالت مخفی  $h$  و حالت کاندید نیز در لایه  $l$  و زمان  $t$  به صورت به روزرسانی می‌شوند:

$$h_l^t = [1 - u_{m,l}^t]h_l^{t-1} + u_{m,l}^t \tilde{h}_l^t \quad (25)$$

$$\tilde{h}_l^t = f[\omega^h y_{m,l}^t + r^h h_l^{t-1} + \beta^h] \quad (26)$$

سپس برای ارتقای دقت روش در شناسایی پارامترهای بار، این ساختار با ساختار انکودر-دی‌کودر<sup>۱۳</sup> ادغام شده است. در این مقاله، دی‌کودر برای شناسایی  $y$  که پارامترهای مدل بار هستند، مورد استفاده قرار می‌گیرند. دی‌کودر به عنوان یکتابع توزیع خروجی بر روی سری زمانی پارامترهای بار و اندازه‌گیری تعریف می‌شود که به صورت مجموع توابع توزیع احتمالی تعریف می‌شود:

$$P^{y^t} = \prod_{t=1}^T P(y^t | \{y^1, \dots, y^{t-1}\}, c) \quad (27)$$

بر اساس شبکه‌ی عصبی بازگشتی، هر توزیع احتمالی شرطی به صورت زیر مدل می‌شود:

Table (3): Deep learning structure parameters

جدول (۳): پارامترهای ساختار یادگیری عمیق

پارامتر	نماد
ورودی‌های شبکه عصبی در عملکرد داده‌های اندازه‌گیری	$X_{d \times (k_a+1), i}^t$
پارامترهای مدل در بازه‌های زمانی پیشین	$\Theta_{d^{\theta} \times k_\theta}^t$
خروچی مسئله	$\Theta_{d^{\theta} \times k_\theta}^{t+k_\theta}$
بردار ورودی	$X_{in} = \{X_1, X_2, \dots, X_N\}$
تابع فعال‌سازی	$f^{act}$
شبکه بازگشتی حافظه‌دار	$U$
دوازه به روزرسانی	$u_{m,l}^t$
دوازه فراموشی	$r_{m,l}^t$
حالت کاندید	$\tilde{h}$
تخمین‌گر هابر	$\tilde{Y}_{ph}$
مقدار حداقل مقادیر ورودی	$X_{max}^i$
مقدار حداقل مقادیر ورودی	$X_{min}^i$

$$P\left(y^t \mid \{y^1, \dots, y^{t-1}\}, c\right) = G\left(y^{t-1}, h^t, c\right) \quad (28)$$

که  $G$  تابع چند لایه و غیر خطی است که احتمال  $y^t$  را مشخص می‌کند. بردار  $c$  در این حالت به ماهیت تغییرات پارامترهای متغیر با زمان مدل بار بستگی دارد. بردار  $c$  به صورت مجموع ضرایب وزنی حالت‌های پنهان تعیین می‌شود:

$$c = \sum_{j=1}^N \alpha_j h_j \quad (29)$$

ضریب‌های وزنی  $\alpha_i$  به صورت زیر محاسبه می‌شود:

$$\alpha_j = \frac{\exp(e_j)}{\sum_{k=1}^N \exp(e_k)} \quad (30)$$

که داریم:

$$e_j = f^{\text{score}}(h_{j-1}, h_j) \quad (31)$$

ساختار روش پیشنهادی در شکل (۲) نشان داده شده است.

### ۳-۱- تابع تلفات

معمولًا برای روش‌های شناسایی از تابع تلفات‌های مبتنی بر مجدد خطا استفاده می‌شوند. اگرچه این تابع ممکن است باعث شوند پارامترهای بار تخمین زده شده به مقادیر میانگین و یا واریانس داده‌ها میل داده شوند. در شرایط نویزدار این مشخص می‌تواند باعث شود که دقت روش کاهش یابد. برای غلبه بر این مشکل در این پژوهش یک تابع تلفات اصلاح شده ارائه شده است. از این‌رو تابع تلفات به صورت زیر تعریف می‌شود:

$$f_{\text{loss}}^{\text{PH}} = \sum_{t=1}^T \left[ \varphi^2 \sqrt{\frac{\varphi^2 - y_t^2}{\varphi^2}} \right] - \varphi^2 \quad (32)$$

این تابع تلفات در حین آموزش و کمینه‌سازی مقدار  $y^2/2$  را تولید می‌کند. این مقدار باعث می‌شود تا خطا ناشی از نویز کاهش یابد. از این‌رو این تابع تلفات باعث مقاوم شدن شبکه طراحی شده در برابر با نویز می‌شود. برای آموزش شبکه طراحی شده، ضریب‌های وزنی در لایه  $l$  به صورت زیر به روزرسانی می‌شود:

$$\theta_l^{\text{PH}}(X) = \frac{\theta_l(X)}{\sqrt{1 + \left( \frac{\tilde{Y}_{\text{PH}} - Y_l}{C} \right)}} \quad (33)$$

که تخمین‌گر هابر<sup>۱۴</sup> برابر است با:

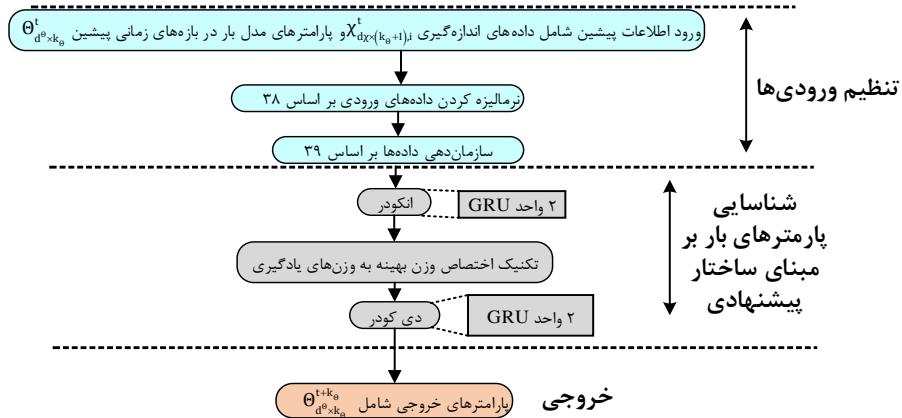
$$\tilde{Y}_{\text{PH}} = \frac{\sum_{t=1}^T \theta_l^{\text{PH}}(X) Y_l}{\sum_{t=1}^T \theta_l^{\text{PH}}(X)} \quad (34)$$

برای بهینه‌سازی این تابع تلفات از روش بهینه‌سازی تخمین گشتاور تطبیقی<sup>۱۵</sup> (Adam) استفاده شده است که در مرجع [۲۹] ارائه شده و جزئیات آن در مرجع [۳۰] آمده است.

### ۳-۲- تنظیم ورودی

پارامترهای بار و اندازه‌گیری به عنوان ورودی با  $x$  نشان داده شده و به صورت زیر نرمالیزه می‌شود:

$$X^i = \frac{X^i - X_{\min}^i}{X_{\max}^i - X_{\min}^i} \quad (35)$$



شکل (۲): ساختار روش پیشنهادی برای شناسایی پارامترهای بارهای الکتریکی

Figure (2): Structure of the proposed method for identifying electrical load parameters

مقادیر ورودی در ساختار طراحی شده به صورت زیر مرتب می‌شوند:

$$\text{input} \left[ \text{samples}, 10, \left( \Theta_{d^0 \times k_0}^{t+k_0} \right) \right] \quad (36)$$

نمونه به صورت بسته‌های با تعداد ۳۲ داده تنظیم می‌شوند. همچنین، خروجی‌ها نیز به صورت  $\text{output} = (\text{samples}, 10)$  هستند.

#### ۴- نتایج عددی

مطالعات بر روی شبکه استاندارد IEEE-۶۸-شینه شبیه‌سازی‌ها در دو نرمافزار انجام شده است. برای تولید داده‌ها از نرمافزار متلب استفاده شده است و روش‌های مبتنی بر یادگیری عمیق در نرمافزار پایتون شبیه‌سازی شده‌اند. سیستم کامپیوتراً مورد استفاده قرار گرفته برای انجام شبیه‌سازی یک سیستم Core i-7-50960 X CPU@3.00 GHz و دارای ۳۲-گیگا بایتی است. برای نشان دادن موثر بودن روش و برتری آن نسبت به روش‌های پیشین داده محور، روش پیشنهادی با روش‌های LSTM و LSTM چند متغیره از مرجع [۱۹] و روش SVM از مرجع [۲۰]، به عنوان روش‌هایی که تاکنون در زمینه شناسایی پارامترهای بارهای الکتریکی ارائه شده‌اند، مقایسه شده است.

#### ۴-۱- تولید داده‌ها

همان‌طور که بیان شد، سیستم مورد مطالعه شبکه IEEE-۶۸-شینه استاندارد IEEE است. شکل دیاگرام تک خطی ۶۸ شینه استاندارد IEEE در شکل (۳) نشان داده شده است. اطلاعات این شبکه در مرجع [۳۱] آمده است. این شبکه دارای ۶۸ خط و ۱۶ ژنراتور سنکرون است. برای استخراج اطلاعات از جعبه‌افزار سیستم قدرت (PST) در نرمافزار متلب استفاده شده است. این جعبه‌افزار برای شبیه‌سازی سیستم‌های قدرت با زمان نمونه‌برداری در هر ۰/۱ ثانیه است. در این پژوهش، برای این که یک بانک اطلاعاتی جامع تولید شود، داده‌ها در دو حالت مختلف تولید می‌شوند. ابتدا ۸۵ حالت خطاب برای هر یک از خطوط که در هر کدام از این حالت‌ها یک خط از مدار خارج می‌شود، در نظر گرفته شده است. روندی مشابه برای هر بار در نظر گرفته شده است. در این شبکه ۳۴ بار مختلف در نظر گرفته شده است. در حالت دوم هر یک از بارهای مختلف از شین متصل به ان قطع می‌شود و مجموعه‌ای از داده‌ها در این دو حالت تولید می‌شود. به طور کلی ۵۹۵۰ داده مختلف در این پژوهش تولید شده‌اند. حدود ۷۰ درصد از داده‌ها برای آموزش، ۱۵ درصد برای ارزیابی و ۱۵ درصد برای تست روش مورد استفاده قرار گرفته‌اند. همچنین، یک نویز گوسی با انحراف معیار ۱۰ درصد میانگین به تمامی داده‌ها اضافه شده تا مقاوم بودن روش پیشنهادی در برابر با نویز را مشخص کنند. باید توجه نمود که نتایج شناسایی پارامترهای بار متصل به شین شماره ۴۴ مورد تجزیه و تحلیل قرار گرفته است. همچنین در هر سناریو دو دسته داده مورد توجه بوده است. نکته اول پارامترهای اندازه‌گیری هستند. این

پارامترها بیشترین نقش را در تغییر پارامترهای مدل بار را دارند که بر مبنای اغتشاش‌های اعمال شده در شبکه به صورت دستی در آن اعمال می‌شوند و با استفاده از جعبه‌افزار PST مقادیر مختلفی برای آن‌ها تعیین می‌شوند. برای تعیین پارامترهای بار در هر اجرا به مقادیر از پیش تعیین شده در PST برای بارها (شامل مقادیر ZIP و موتور القایی) مقادیر نویز به صورت تصادفی اضافه شده تا مجموعه داده‌های موجود تولید شود.

#### ۴-۲- معیارهای دقیق

برای ارزیابی عملکرد ساختار یادگیری عمیق ارائه شده و مقایسه این روش با ساختارهای مختلف از چهار معیار مختلف استفاده شده است. این چهار معیار شامل میانگین ریشه دوم مجذور میانگین خطای جذر میانگین مربعات (RMSE)، میانگین خطای جذر میانگین مربعات نرمالیزه شده (NRMSE)، درصد میانگین قدر مطلق خطای (MAPE) و میانگین قدر مطلق خطای (MAE) می‌توانند، مورد استفاده قرار گیرند که رابطه‌های آن‌ها عبارتند از:

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_{\text{se}}^i - y_{\text{re}}^i)^2} \quad (37)$$

$$\text{NRMSE} = \frac{1}{y_{\text{re}}^{\max}} \sqrt{\frac{1}{N} \sum_{i=1}^N (y_{\text{se}}^i - y_{\text{re}}^i)^2} \quad (38)$$

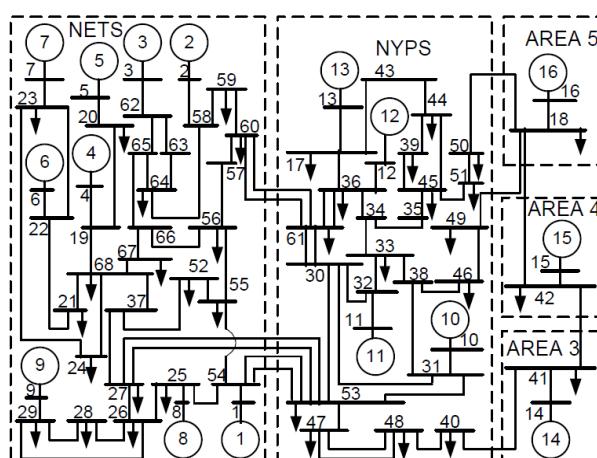
$$\text{MAPE} = \frac{1}{N} \sum_{i=1}^N \left| \frac{y_{\text{se}}^i - y_{\text{re}}^i}{y_{\text{re}}^i} \right| \times 100 \quad (39)$$

$$\text{MAE} = \frac{1}{N} \sum_{i=1}^N |y_{\text{se}}^i - y_{\text{re}}^i| \quad (40)$$

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

#### ۴-۲- ارزیابی نتایج

در این قسمت نتایج به دست آمده از روش پیشنهادی مورد تجزیه و تحلیل قرار گرفته است. برای تحلیل نتایج بار متصل به شین شماره ۲۹ [نشان داده شده در شکل (۳)] به عنوان نمونه در نظر گرفته شده‌اند. شکل (۴) نتیجه تخمین پارامتر به دست آمده از دو روش حافظه بلند کوتاه-مدت چند گانه (MLSTM) و روش پیشنهادی در این پژوهش را با مقادیر واقعی نشان می‌دهد. همان‌طور که از این شکل مشخص است، مقادیر تخمینی توسط روش پیشنهادی به مقادیر تخمینی از روش حافظه بلند کوتاه-مدت چند گانه نزدیک‌تر است. روش حافظه بلند کوتاه-مدت چند گانه از میان روش‌های دیگر به علت دقت بهتر این روش نسبت به روش‌های دیگر شبیه‌سازی شده، آورده شده است.



شکل (۱): دیاگرام تک خطی شبکه IEEE ۶۸-شینه استاندارد

Figure (3): IEEE Standard 68-bus single-line diagram

همچنین، پارامتر دیگر از مدل ترکیبی بار در شکل (۵) نشان داده شده است. نتایج به دست آمده از این شکل نیز نشان می‌دهد که مقادیر تخمینی توسط روش پیشنهادی از مقادیر تخمینی توسط روش حافظه بلند کوتاه-مدت چندگانه به مقادیر واقعی نزدیک‌تر است. از این رو می‌توان نتیجه گرفت که روش پیشنهادی تخمین‌گر مطلوب‌تری از روش حافظه بلند کوتاه-مدت چندگانه در تخمین پارامتر است. معیارهای دقت به دست آمده از روش پیشنهادی مبتنی بر یادگیری عمیق در این پژوهش در جدول (۴) آمده است. به عنوان نمونه به مقادیر MAPE توجه نمایید. مقادیر به دست آمده از روش پیشنهادی دارای درصد خطایی در ۰/۱۵ درصد است. این مقدار خطای پایین می‌توان به خودی خود ناشی از دقت بالای روش پیشنهادی باشد.

#### ۴-۲- مقایسه نتایج

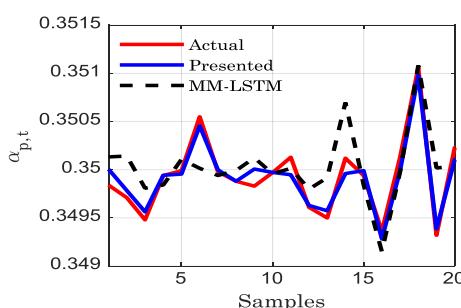
نتایج به دست آمده از تخمین پارامتر  $H$  در جدول (۵) آمده است. بر اساس این جدول روش پیشنهادی کمترین میزان خطای نسبت به دو روش مبتنی بر یادگیری عمیق LSTM و MLSTM و همچنین نسبت به روش کم عمق SVM دارد. به عنوان نمونه شاخص MAPE را در نظر بگیرید. روش پیشنهادی دقت روش‌های LSTM، MLSTM و SVM را به ترتیب در حدود ۷/۶۲ درصد و ۵۰/۹ درصد بهبود داده است. جدول (۶) معیارهای دقت به دست آمده از روش‌های پیشنهادی، LSTM و MLSTM را در تخمین یکی از پارامترها را نشان می‌دهد. دقت مطلوب‌تر روش پیشنهادی بر اساس هر چهار معیار SVM، MLSTM، LSTM و NRMSE، MAE، RMSE و MAPE کاملاً از این جدول مشخص است. به عنوان نمونه مقادیر MAE به دست آمده را در نظر بگیرید. بر اساس معیار دقت MAE، روش پیشنهادی دقت روش LSTM را در حدود ۶۸/۸۷ درصد، دقت روش SVM را حدود ۷۴/۹۹ درصد و دقت روش NRMSE را حدود ۸۶/۷۲ درصد بهبود داده که مقادیر چشم‌گیری هستند.

#### ۴-۳- تاثیر نویز

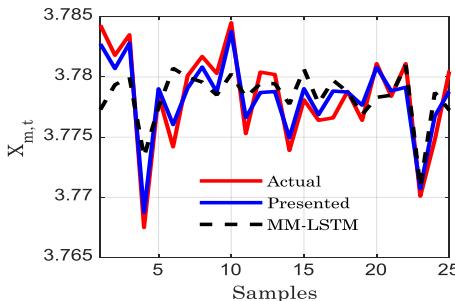
برای ارزیابی مقاوم بودن روش پیشنهادی در برابر نویز و تاثیر تابع تلفات پیشنهادی، یک مطالعه حساسیت نسبت به نویز انجام شده است. از این‌رو روش پیشنهادی و روش‌های دیگر تحت نویز با یکدیگر مقایسه شده‌اند. در این راستا، شش حالت مختلف در نظر گرفته شده است. در تمامی این حالت‌ها مقدار میانگین نویز ثابت نگه داشته شده است، در حالی که مقدار انحراف معیار نویز به ترتیب برابر با ۰/۰۰۵، ۰/۰۱۵، ۰/۰۲ و ۰/۰۳ در نظر گرفته شده است. شکل (۶) نتایج به دست آمده از روش‌های مختلف را در تخمین پارامتر بر اساس معیار MAPE با یکدیگر مقایسه نموده است. همان‌طور که مشخص است با افزایش نویز دقت روش پیشنهادی تغییر چندانی نمی‌کند. این موضوع در تخمین پارامتر دیگر بر اساس نتایج به دست آمده از RMSE نیز کاملاً مشابه است که در شکل (۷) نشان داده شده است. روش‌های کم عمق همانند SVM به خاطر محدودیت پارامتر در برابر نویز چندان مقاوم نیستند. با توجه به شکل‌های (۶) و (۷)، روش SVM تغییرات شدیدتری نسبت به روش‌های عمیق دارد. حتی میزان خطای آن به بالای یک درصد افزایش یافته که در مدل‌سازی پارامترهای بار، مقدار قابل قبولی نیست.

#### ۴-۴- زمان محاسبات

یکی از پارامترهایی که در روش‌های مدل‌سازی بار نقش اساسی دارد، بار محاسباتی روش‌های مدل‌سازی بار است.



شکل (۲): مقایسه نتایج تخمین روش پیشنهادی با روش LSTM و مقادیر واقعی  $\alpha_i^p$   
Figure (4): Comparison of the proposed method results with LSTM method and real values of  $\alpha_i^p$



شکل (۳): مقایسه نتایج تخمین روش پیشنهادی با روش MLSTM و مقادیر واقعی  $X_m^t$   
Figure (5): Comparison of the proposed method results with MLSTM method and real values of  $X_m^t$

Table (3): Accuracy criteria for load parameters estimation obtained from the proposed method

جدول (۴): معیارهای دقت به دست آمده از تخمین پارامترهای بار به دست آمده از روش پیشنهادی

پارامترها \ معیارها	MAE( $10^{-4}$ )	NRMSE	RMSE( $10^{-4}$ )	MAPE (%)
$\alpha_t^p$	۱/۱۲۴۲	۰/۰۷۵۸	۱/۱۵۶۴	۰/۰۷۳۶
$\beta_t^p$	۲/۰۱۴۵	۰/۱۷۱۲	۵/۲۵۶۱	۰/۰۷۰۱
$\alpha_t^q$	۱/۸۹۲۶	۰/۱۲۴۲	۴/۱۴۲	۰/۰۹۸۴
$\beta_t^q$	۱/۹۵۲۱	۰/۲۰۱۲	۳/۸۶۲۴	۰/۰۵۶۷
$H^t$	۶/۷۲۲۶	۰/۱۵۵۵۷	۷/۸۳۸۴	۰/۰۶۸۰۳
$r_s^t$	۰/۰۹۸۲	۰/۰۹۴۲	۰/۱۴۲۱	۰/۰۴۸۷
$X_s^t$	۰/۵۸۷۷۱	۰/۱۹۰۷۴	۰/۶۶۸۴۸	۰/۱۰۱۲
$r_r^t$	۰/۱۹۷۲	۰/۰۹۹۵	۰/۳۸۵۲	۰/۰۵۷۹
$X_r^t$	۰/۲۱۴۶	۰/۱۸۹۶	۰/۵۴۸۶	۰/۰۶۲۸
$X_m^t$	۱۱/۲۵۲	۰/۰۶۸۹	۱۳/۱۴۲	۰/۰۵۲۸

Table (4): Accuracy criteria of different methods for  $H^t$  estimation

جدول (۵): معیارهای دقت به دست آمده از روش‌های مختلف در تخمین پارامتر  $H^t$

پارامترها \ معیارها	MAPE (%)	RMSE ( $\times 10^{-4}$ )	NRMSE	MAE ( $\times 10^{-4}$ )
پیشنهادی	۰/۰۶۸۰۳	۷/۸۳۸۴	۰/۱۵۵۵۷	۶/۷۲۲۶
MLSTM	۰/۰۷۰۸۷	۳/۸۵۰۵	۰/۱۹۴۴۷	۳/۱۸۹
LSTM	۰/۰۷۳۶۴۴	۴/۰۹۸۶	۰/۲۰۷	۳/۳۱۴
SVM	۰/۱۳۶۵۹	۷/۴۳۴۳	۰/۳۷۵۶۹	۶/۰۵۰۶

Table (5): Accuracy criteria of different methods for  $X_s^t$  estimation

جدول (۶): معیارهای دقت به دست آمده از روش‌های مختلف در تخمین پارامتر  $X_s^t$

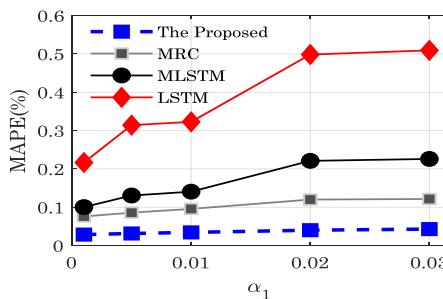
پارامترها \ معیارها	MAPE (%)	RMSE ( $\times 10^{-4}$ )	NRMSE	MAE ( $\times 10^{-4}$ )
پیشنهادی	۰/۰۲۱۱۲۴	۰/۲۲۱۷۷	۰/۰۶۱۴۳۲	۰/۱۷۹۸۹
MLSTM	۰/۰۶۷۸۷۷	۰/۶۶۰۳	۰/۱۸۲۹۱	۰/۵۷۸۰۳
LSTM	۰/۰۸۴۴۷	۰/۸۲۵۷۷	۰/۲۲۸۷۵	۰/۷۱۹۴۴
SVM	۰/۱۵۷۲۵	۱/۵۲۵۵	۰/۴۱۹۷۹	۱/۳۵۴۸

روش‌های مبتنی بر داده عملکرد بسیاری سریعی دارند. همان‌طور که اشاره شد، این روش‌ها ابتدا آموزش داده می‌شوند و سپس ساختار آموزش داده شده مدل‌سازی بار را انجام می‌دهند. با وجود این که زمان عملکرد در یک روش به سیستم کامپیوترا و عوامل بسیار زیادی بستگی دارد. در این قسمت برای این که یک مقایسه بین روش‌های پیشین و روش پیشنهادی از نظر بار

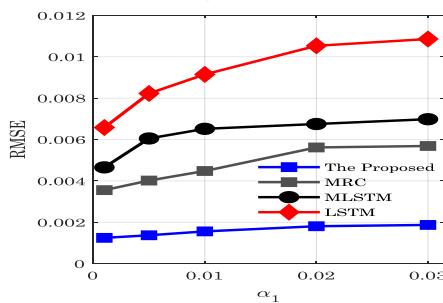
محاسباتی انجام شود، مرحله تست روش پیشنهادی حدود ۲۵۰ بار تکرار شده و سپس مقادیر کمترین، میانگین و حداکثر زمان تست برای هر روش در جدول (۷) گزارش شده است. بر اساس جدول (۷) روش ماشین بردار پشتیبان زمان محاسبات کمتری را نسبت به روش‌های مبتنی بر یادگیری عمیق از خود نشان داده است. هر چند دقت روش ماشین بردار پشتیبان در مقایسه با روش‌های دیگر قابل قبول نیست. در میان روش‌های مبتنی بر یادگیری عمیق روش پیشنهادی از بقیه روش‌ها سرعت عمل بیشتری را از خود دارد که بنا بر مطالب بیان شده در قسمت‌های پیشین این نتایج چندان دور از انتظار نبود.

##### ۵- نتیجه‌گیری

شناسایی پارامترهای بار از وظایف ضروری برای بهره‌برداران سیستم‌های قدرت در تحلیل سیستم‌های قدرت در بازه‌های زمانی کوتاه و بلند مدت است و تاثیرات اساسی بر روی فرآیند تصمیم‌گیری دارد. مدل ترکیبی بار الکتریکی که شامل دو مولفه استاتیک (مدل ZIP) و مدل دینامیک (IM) قابلیت این را دارد که رفتار بارهای متصل به یک شین را به نحوی مطلوب نشان دهد. هر چند نیاز است تا یک روش سریع، دقیق و مقاوم در برای نویز برای شناسایی پارامترهای متغیر با زمان این مدل استفاده شود. بنابراین این پژوهش یک مدل مبتنی بر یادگیری عمیق را در این راستا توسعه داده است. در این روش از یک مبنای وزن‌دهی جدید استفاده شده است تا ساختار یادگیری عمیق به صورت چند متغیره باشد. همچنین، برای یادگیری ویژگی‌ها از روش شبکه عمیق حافظه‌دار بازگشته بر مبنای انکودر-دیکودر استفاده شده است. همچنین یکتابع تلفات برای افزایش مقاوم بودن آن نسبت به نویز استفاده شده است. نتایج نشان‌دهنده دقت بالای این روش در مقایسه با روش‌های مشابه است. یکی از کاربردهای مدل‌سازی بار، مطالعات پایداری ولتاژ است. از این‌رو در تحقیقات آینده تاثیرات مدل‌سازی بار بر روی پایداری استاتیکی و دینامیکی ولتاژ به صورت گسترده مورد مطالعه قرار خواهد گرفت.



شکل ۴: مقایسه‌ی روش‌های مختلف در مقادیر مختلف نویز بر اساس معیار MAPE در تخمین پارامتر  $R_s^t$   
Figure (6): Comparison of different methods for  $R_s^t$  estimation based on MAPE criteria in presence of noise



شکل ۵: مقایسه‌ی روش‌های مختلف در مقادیر مختلف نویز بر اساس معیار RMSE در تخمین پارامتر  $R_s^t$   
Figure (7): Comparison of different methods for  $R_s^t$  estimation based on RMSE criteria in presence of noise  
Table (6): Comparison of load parameters detection time

جدول (۷): مقایسه‌ی زمان شناسایی پارامترهای بار

روش	کمترین زمان تست (میلی ثانیه)	میانگین زمان تست (میلی ثانیه)	حداکثر زمان تست (میلی ثانیه)
پیشنهادی	۱۸۲/۲۴	۱۹۴/۷۶	۲۰۱/۲۰
MLSTM	۲۴۸/۴۸	۲۶۲/۱۴	۲۹۸/۲۶
LSTM	۲۸۲/۱۶	۳۰۶/۸۶	۳۶۴/۵۹
SVM	۷۶/۵۶	۹۵/۱۴	۱۱۴/۱۰

## سپاسگزاری

این مقاله مستخرج رساله دوره دکتری در دانشگاه آزاد اسلامی واحد مرودشت است. نویسنده‌گان بر خود لازم می‌دانند مراتب تشکر صمیمانه خود را از همکاران حوزه پژوهشی دانشگاه و داوران محترم که ما را در انجام و ارتقای کیفی این مقاله یاری نموده‌اند، اعلام نمایند.

## References

## مراجع

- [1] O.I. Ghafarokhi, M. Moattari, A. Forouzantabar, "Composite load modeling by spatial-temporal deep attention network based on wide-area monitoring systems", Journal of Intelligent and Fuzzy Systems, vol. 40, no. 6, pp. 12215-12216, June 2021 (doi: 10.3233/JIFS-210296).
- [2] A. Arif, Z. Wang, J. Wang, B. Mather, H. Bashualdo, D. Zhao, "Load modeling- A review", IEEE Trans. on Smart Grid, vol. 9, no. 6, pp. 5986-5999, Nov. 2018 (doi: 10.1109/TSG.2017.2700436).
- [3] X. Zhang, D.J. Hill, C. Lu, "Identification of composite demand side model with distributed photovoltaic generation and energy storage", IEEE Trans. on Sustainable Energy, vol. 11, no. 1, pp. 326-336, Jan. 2020 (doi: 10.1109/TSTE.2019.2890868).
- [4] N.K. Neto, A.R. Abaide, V. Miranda, P.V. Gomes, L. Carvalho, J. Sumaili, D.P. Bernardon, "Load modeling of active low-voltage consumers and comparative analysis of their impact on distribution system expansion planning", International Trans. on Electrical Energy Systems, vol. 29, no. 8, e12038, Aug. 2019 (doi: 10.1002/2050-7038.12038).
- [5] H. Renmu, M. Jin, D.J. Hill, "Composite load modeling via measurement approach", IEEE Trans. on Power Systems, vol. 21, no. 2, pp. 663-672, May 2006 (doi: 10.1109/TPWRS.2006.873130).
- [6] P. Regulski, D.S. Vilchis-Rodriguez, S. Djurović, V. Terzija, "Estimation of composite load model parameters using an improved particle swarm optimization method", IEEE Trans. on Power Delivery, vol. 30, no. 2, pp. 553-560, Feb. 2015 (doi: 10.1109/TPWRD.2014.2301219).
- [7] V. Knyazkin, C.A. Canizares, L.H. Soder, "On the parameter estimation and modeling of aggregate power system loads", IEEE Trans. on Power Systems, vol. 19, no. 2, pp. 1023-1031, May 2004 (doi: 10.1109/TPS.2004.1397702).
- [8] P. Jazayeri, W. Rosehart, D.T. Westwick, "A multistage algorithm for identification of nonlinear aggregate power system loads", IEEE Trans. on Power Systems, vol. 22, no. 3, pp. 1072-1079, July 2007 (doi: 10.1109/TPWRS.2007.430565-018-0469-2).
- [9] Q. Liu, Y. Chen, D. Duan, "The load modeling and parameters identification for voltage stability analysis", Int. Conf. on Power System Technology, vol. 4, pp. 2030-2033, Oct. 2002 (doi: 10.1109/PSCE.2004.1397702).
- [10] S.M. Rizvi, K.S. Sajan, A.K. Srivastava, "Real-time parameter tracking of power-electronics interfaced composite ZIP load model", IEEE Trans. on Smart Grid, Oct. 2021 (Early Access) (doi: 10.1109/TSG.2021.3119507).
- [11] A. M. Najafabadi A. T. Alouani, "Real time estimation of sensitive parameters of composite power system load model", Proceeding of the IEEE/TDC, pp. 1-8, May, Orlando, FL, USA, 2012 (doi: 10.1109/TDC.2012.6281427).
- [12] A. Rouhani, A. Abur, "Real-time dynamic parameter estimation for an exponential dynamic load model", IEEE Trans. on Smart Grid, vol. 7, no. 3, pp. 1530-1536, May 2016 (doi: 10.1109/TSG.2015.2449904).
- [13] S. Afrasiabi, M. Afrasiabi, B. Parang, M. Mohammadi, S. Kahourzade, A. Mahmoudi, "Two-stage deep learning-based wind turbine condition monitoring using SCADA data", Proceeding of the IEEE/PEDES, pp. 1-6, Jaipur, India, Dec. 2020 (doi: 10.1109/PEDES49360.2020.9379393).
- [14] A. Qian, G.B. Shrestha, "An ANN-based load model for fast transient stability calculations", Electric Power Systems Research, vol. 76, no. 4, pp. 217-227, Jan. 2006 (doi: 10.1016/j.epsr.2005.06.001).
- [15] M. Ganjouri, M. Moattari, A. Forouzantabar, M. Azadi, "Short-term load forecasting using a graph-based deep learning structure", Journal of Novel Researches on Electrical Power, vol. 9, no. 4, pp. 37-46, Feb. 2021.
- [16] J. Ma, Z.Y. Dong, P. Zhang, "Using a support vector machine (SVM) to improve generalization ability of load model parameters", Proceeding of the IEEE/PES, pp. 1-8, Seattle, WA, USA, Mar. 2009 (doi: 10.1109/PSCE.2009.4839969)
- [17] L. Chávarro-Barrera, S. Pérez-Londoño, J. Mora-Flórez, "An adaptive approach for dynamic load modeling in microgrids", IEEE Trans. on Smart Grid, vol. 12, no. 4, pp. 2834-2843, Mar. 2021 (doi: 10.1109/TSG.2021.3064046).

- [18] S.M.H. Rizvi, K. S. Sajan, A. K. Srivastava, "Synchrophasor based ZIP parameters tracking using ML with adaptive window and data anomalies", IEEE Trans. on Power Systems, vol. 37, no. 1, pp. 3-13, June 2022 (doi: 10.1109/TPWRS.2021.3088903).
- [19] M. Cui, M. Khodayar, C. Chen, X. Wang, Y. Zhang, M.E. Khodayar, "Deep learning-based time-varying parameter identification for system-wide load modeling", IEEE Trans. on Smart Grid, vol. 10, no. 6, pp. 6102-6114, Jan. 2019 (doi: 10.1109/TSG.2019.2896493).
- [20] C. Wang, Z. Wang, J. Wang, D. Zhao, "SVM-Based parameter identification for composite ZIP and electronic load modeling", IEEE Trans. on Power Systems, vol. 34, no. 1, pp. 182-193, Jan. 2019 (doi: 10.1109/TPWRS.2018.2865966).
- [21] M. Afrasiabi, M. Mohammadi, M. Rastegar, L. Stankovic, S. Afrasiabi, M. Khazaei, "Deep-based conditional probability density function forecasting of residential loads", IEEE Trans. on Smart Grid, vol. 11, no. 4, pp. 3646-3657, July 2020 (doi: 10.1109/TSG.2020.2972513).
- [22] M. Afrasiabi, M. Mohammadi, M. Rastegar, A. Kargarian, "Probabilistic deep neural network price forecasting based on residential load and wind speed predictions", IET Renewable Power Generation, vol. 13, no. 11, pp. 1840-1848, Aug. 2019 (doi: 10.1049/iet-rpg.2018.6257).
- [23] M. Afrasiabi, M. Mohammadi, M. Rastegar, S. Afrasiabi, "Advanced deep learning approach for probabilistic wind speed forecasting", IEEE Trans. on Industrial Informatics, vol. 17, no. 1, pp. 720-727, Jan. 2021 (doi: 10.1109/TII.2020.3004436).
- [24] S. Afrasiabi, M. Afrasiabi, M. Mohammadi, B. Parang, "Fault localisation and diagnosis in transmission networks based on robust deep Gabor convolutional neural network and PMU measurements", IET Generation, Transmission and Distribution, vol. 14, no. 26, pp. 6484-6492, Dec. 2020 (doi: 10.1049/iet-gtd.2020.0856).
- [25] S. Afrasiabi, M. Mohammadi, M. Afrasiabi, B. Parang, "Modulated gabor filter based deep convolutional network for electrical motor bearing fault classification and diagnosis," , IET Science, Measurement and Technology, vol. 15, no. 2, pp. 154-162, Mar. 2021 (doi: 10.1049/smt2.12017).
- [26] S. Afrasiabi, M. Afrasiabi, B. Parang, M. Mohammadi, M.M. Arefi, M. Rastegar, "Wind turbine fault diagnosis with generative-temporal convolutional neural network", Proceeding of the IEEE/EEEIC, pp. 1-5, Genova, Italy, June 2019 (doi: 10.1109/EEEIC.2019.8783233).
- [27] H. Samet, S. Katabipoor, M. Afrasiabi, S. Afrasiabi, M. Mohammadi, "Deep learning forecaster based controller for SVC: Wind farm flicker mitigation", IEEE Trans. on Industrial Informatics, Sept. 2020 (Early Access) (doi: 10.1049/iet-gtd.2019.128).
- [28] D. Bahdanau, K. Cho, Y. Bengio, "Neural machine translation by jointly learning to align and translate", arXiv Preprint, Article Number: 1409.0473, Sept. 2014 (doi: 10.48550/arXiv.1409.0473).
- [29] D.P. Kingma, J. Ba, "Adam: A method for stochastic optimization", arXiv Preprint, Article Number: 1412.6980, Dec. 2014 (doi: 10.48550/arXiv.1412.6980).
- [30] S. Afrasiabi, M. Afrasiabi, B. Parang, M. Mohammadi, "Designing a composite deep learning based differential protection scheme of power transformers", Applied Soft Computing, vol. 87, Article Number: 105975, Feb. 2020 (doi: 10.1016/j.asoc.2019.105975).
- [31] A.K. Singh, B.C. Pal, "IEEE PES task force on benchmark systems for stability controls report on the 68-bus 16-machine 5-area system", Technical Report, IEEE Power and Energy Society, Dec. 2013 (<https://eprints.lincoln.ac.uk/id/eprint/28771>).

## زیرنویس‌ها

- 
1. Impedance-current-power
  2. Metaheuristic optimization method
  3. Classic optimization method
  4. Machine learning
  5. Artificial intelligence
  6. Artificial neural network
  7. Local model network
  8. Support vector machine
  9. K-nearest neighborhood
  10. Random forest
  11. Long short-term memory
  12. Gated recurrent unit
  13. Encoder-decoder structure
  14. Haber estimator
  15. Adaptive torque estimation