

Comprehensive Review on Data-Driven Techniques in Smart Power Grids

Khalegh Behrouz Dehkordi^{1,2}, M.Sc., Homa Movahednejad^{1,2}, Assistant professor, Mahdi Sharifi^{1,2}, Assistant professor

¹Faculty of Computer Engineering, Najafabad Branch, Islamic Azad University, Najafabad, Iran

²Big Data Research Center, Najafabad Branch, Islamic Azad University, Najafabad, Iran
khalegh.behrouz@sco.iaun.ac.ir, h.movahed@pco.iaun.ac.ir, m.sharifi@pco.iaun.ac.ir

Abstract

As a promising vision toward obtaining high reliability and better energy management, nowadays power grid is transferring to the smart grid (SG). This process is changing continuously and needs advanced methods to process big data produced by different segments. Artificial intelligence methods can offer data-driven services by extracting valuable information which is produced by meter devices and sensors in smart grids. To this end, machine learning (ML), deep learning (DL), reinforcement learning (RL), and deep reinforcement learning (DRL) can be applied. These methods are able to process huge amounts of data and propose an appropriate solution to solve power industry complex problems. In this paper, the state-of-the-art approaches based on artificial intelligence used by smart power grids for applications and data sources are investigated. Also, the role of big data in smart power grids, and its features such life cycle, and efficient services such as forecast, predictive maintenance, and fault detection are discussed.

Keywords: big data, data driven methods, deep learning, machine learning, smart power grid

Received: 10 December 2021

Revised: 9 February 2022

Accepted: 3 May 2022

Corresponding Author: Dr. Homa Movahednejad

Citation: K. Behrouz-Dehkordi, H. Movahednejad, M. Sharifi, "Comprehensive review on data-driven techniques in smart power grids", Journal of Intelligent Procedures in Electrical Technology, vol. 15, no. 57, pp. 133-162, Spring 2024 (in Persian).

<https://dorl.net/dor/20.1001.1.23223871.1403.15.57.9.8>

مقاله مروری

مروری جامع بر روش‌های داده‌محور در شبکه‌های هوشمند برق

خالق بهروز دهکردی^۱، دانش‌آموخته کارشناسی ارشد، هما موحدنژاد^{۱،۲}، استادیار، مهدی شریفی^{۱،۲}، استادیار

۱- دانشکده مهندسی کامپیوتر- واحد نجف آباد، دانشگاه آزاد اسلامی، نجف آباد، ایران

۲- مرکز تحقیقات کلان داده- واحد نجف آباد، دانشگاه آزاد اسلامی، نجف آباد، ایران

khalegh.behrouz@sco.iaun.ac.ir, h.movahed@pco.iaun.ac.ir, m.sharifi@pco.iaun.ac.ir

چکیده: امروزه شبکه برق به‌طور چشم‌گیری در حال تبدیل شدن به شبکه هوشمند (SG)، به عنوان یک چشم‌انداز امیدوارکننده برای برخورداری از قابلیت اطمینان بالا و مدیریت کارآمد انرژی است. این انتقال به‌طور پیوسته در حال تغییر است و نیازمند روش‌های پیشرفته برای پردازش کلان داده‌های تولید شده از بخش‌های مختلف است. روش‌های هوش مصنوعی می‌توانند از طریق استخراج اطلاعات ارزشمند که توسط دستگاه‌های اندازه‌گیری و سنسورهای موجود در شبکه تولید می‌شوند خدمات مبتنی بر داده را ارائه نمایند. به این منظور روش‌های یادگیری ماشین، یادگیری عمیق، یادگیری تقویتی و یادگیری عمیق تقویتی می‌توانند به کار گرفته شوند. این روش‌ها می‌توانند حجم زیادی از داده‌های جمع‌آوری شده را پردازش نموده و راه‌حل مناسبی برای مشکلات پیچیده صنعت برق ارائه نمایند. از این‌رو در این مقاله آخرین رویکردهای مبتنی بر هوش مصنوعی مورد استفاده در شبکه هوشمند برق برای کاربردها و منابع داده به‌طور جامع بررسی شده است. همچنین نقش کلان داده در شبکه هوشمند برق و ویژگی‌های آن از جمله چرخه حیات کلان داده و رویکردهای موثر آن مانند پیشگویی، تعمیرات قابل پیش‌بینی و تشخیص خطا در صنعت برق بیان می‌شود.

کلمات کلیدی: روش‌های داده‌محور، شبکه هوشمند برق، یادگیری عمیق، کلان داده، یادگیری ماشین

تاریخ ارسال مقاله: ۱۴۰۰/۰۹/۱۹

تاریخ بازنگری مقاله: ۱۴۰۰/۱۱/۲۰

تاریخ پذیرش مقاله: ۱۴۰۱/۲/۱۳

نام نویسنده‌ی مسئول: دکتر هما موحدنژاد

نشانی نویسنده‌ی مسئول: نجف‌آباد- بلوار دانشگاه- دانشگاه آزاد اسلامی واحد نجف‌آباد- دانشکده مهندسی کامپیوتر

۱- مقدمه

مدیریت شبکه‌های هوشمند^۱ (SG) برق به‌طور ذاتی دارای فرایندهای تصمیم‌گیری پیچیده است. رشد فزاینده منابع انرژی تجدیدپذیر که با تغییرپذیری و عدم قطعیت در سیستم‌های برق همراه است، این پیچیدگی را چالش برانگیزتر می‌کند. روش‌های مرسوم با تکیه بر روش‌هایی مانند روش‌های آماری، طیفی، پردازش سیگنال، نظریه اطلاعات و تحلیل سری‌های زمانی سعی در تسهیل فرایندهای تصمیم‌گیری داشته‌اند. اگرچه این روش‌ها سطح فرمالیسم ریاضی قوی را از خود نشان داده‌اند اما همیشه نمی‌توانند با ارائه مدل‌های قطعی، پیچیدگی سیستم‌های دنیای واقعی را مدیریت کنند. روش‌های مرسوم از دیرباز در صنعت برق مورد استفاده قرار گرفته‌اند اما با روند دیجیتالی شدن صنعت برق با روش‌های داده‌محور در حال جایگزین شدن هستند. با ظهور روش‌های داده‌محور، این روش‌ها با تکیه بر مفاهیم هوش مصنوعی^۲ (AI) تلاش نمودند بر این پیچیدگی‌ها غلبه کنند. هوش مصنوعی می‌تواند در کلیه حوزه‌های صنعت برق شامل تولید، انتقال، توزیع و مصرف مورد بهره‌برداری قرار گیرد. با پیشرفت‌های حاصل شده در ابزارهای اندازه‌گیری، پایش و ذخیره‌سازی در شبکه‌های هوشمند برق و به دنبال آن ظهور کلان-داده‌های تولید شده از این تجهیزات هوشمند، جامعه علمی به دنبال توسعه و به‌کارگیری روش‌های مبتنی بر هوش مصنوعی در صنعت برق است [۱]. یادگیری ماشین^۳ به عنوان یک زیرحوزه از هوش مصنوعی و علوم کامپیوتر مطرح شده که از شناسایی الگو تا تجزیه و تحلیل ساختمان‌های داده تکامل پیدا کرده است. روش‌های یادگیری ماشین به عنوان یک راه‌کار امید بخش در جهت خودکار کردن فرایند جمع‌آوری داده به‌منظور تحلیل در سطح محلی و کلان مورد توجه قرار گرفته‌اند. این مجموعه روش‌ها می‌توانند به‌طور خودکار الگوهای موجود در داده را تشخیص داده و سپس از این الگوها به‌منظور پیش‌بینی شرایط آینده یا تصمیم‌گیری با در نظر گرفتن شرایط عدم قطعیت استفاده کنند. در چندین حوزه شبکه‌های هوشمند برق روش‌های یادگیری ماشین به نقاط عطفی دست یافته‌اند، با این حال چالش‌های بسیاری در شبکه‌های عصبی سطحی^۴ و مدل‌های یادگیری ماشین ساده خودنمایی می‌کند که باعث می‌گردد این روش‌ها در مسائل پیچیده سیستم‌های قدرت خیلی کم مورد استفاده قرار گیرند [۲]. شبکه‌های هوشمند برق به آرامی جایگزین شبکه‌های قدیمی در طول دهه گذشته شده‌اند. این انتقال با اضافه شدن تعداد زیادی از سیستم‌های اندازه‌گیری هوشمند و دیگر منابع استخراج اطلاعات همراه شد. بنابراین کلان‌داده جمع‌آوری شده از این سیستم‌ها فرصت‌های متعددی را جهت بهره‌برداری از این داده‌ها در شبکه‌های هوشمند برق فراهم آورد [۳]. تحلیل این کلان-داده‌ها ارتقاء عملکرد خدمات و تشویق به ساخت مدل‌های تجاری جدید در بخش انرژی به‌منظور بهره‌برداری از داده‌های جمع‌آوری شده در شبکه هوشمند برق را به همراه دارد که از جمله آن می‌توان به پیش‌گویی، تشخیص خطا و تعمیرات قابل پیش‌بینی^۵ اشاره کرد. در سال‌های اخیر شبکه‌های عصبی عمیق^۶ با توجه به پیشرفت‌های حاصل شده در حوزه‌های عملکرد محاسباتی و ذخیره کلان‌داده در کانون توجه قرار گرفته‌اند. الگوی یادگیری عمیق در این خصوص با توجه به پتانسیل قوی خود به عنوان نماینده روش‌های یادگیری به موفقیت چشم‌گیری دست یافته است. روش‌های یادگیری ماشین مرسوم دارای محدودیت‌های متعددی به‌منظور پردازش داده‌های خام هستند. با این حال، یادگیری عمیق برای این منظور گزینه‌هایی بدون استخراج و انتخاب بردار ویژگی فراهم می‌نماید. در حقیقت به جای قرار دادن فرایندها و قوانین متعدد غیر خودکار به‌منظور استخراج ویژگی از داده‌های خام جمع‌آوری شده، یادگیری عمیق این ویژگی‌ها را به‌طور خودکار در زمان آموزش یاد می‌گیرد [۴]. از این‌رو خانواده این الگوریتم‌ها شامل یادگیری متمایزکننده^۷، احتمالی و تقویتی، ابزارهای مناسب و تسهیل‌کننده‌ایی برای مواجهه با پیشرفت‌های حاصل شده اخیر در شبکه‌های هوشمند برق و استفاده بهینه از کلان‌داده به‌دست آمده، به‌منظور کسب دستاوردهای جدید به نظر می‌رسند.

توسعه‌های اخیر در پایش شبکه‌های حسگر و زیر ساخت‌های پیشرفته اندازه‌گیری^۸ (AMI) و به لطف بستر فراهم شده توسط اینترنت اشیا^۹ (IoT)، به‌طور چشم‌گیری تنوع، حجم و پویایی داده‌های اندازه‌گیری شده در شبکه‌های انتقال و توزیع برق را افزایش داده است. علاوه بر آن یادگیری ماشین و یادگیری عمیق، ساختار پایگاه داده و متدلوژی‌های داده‌کاوی در کنار وجود پلتفرم‌های متن باز تحلیل داده، صنعت برق را دگرگون نموده و آنها را از سازمان‌های خدمات محور به شرکت‌هایی با محوریت داده تبدیل کرده است [۵]. بنابراین ضرورت وجود یک مطالعه مروری در این حوزه که مورد استفاده محققین و متخصصین صنعت برق در داخل کشور قرار گیرد، اهمیت دارد. از این‌رو این مقاله تلاش نموده است مروری جامع بر آخرین روش‌های

داده‌محور به‌کار گرفته شده در این صنعت در کنار معرفی و بررسی تاثیر کلان‌داده ارائه دهد. بر اساس اطلاعات به‌دست آمده توسط نویسندگان، این مطالعه اولین مقاله مروری ارائه شده در زمینه روش‌های داده‌محور در شبکه‌های هوشمند برق در داخل کشور است که به بررسی آخرین رویکردهای مرتبط و معرفی چالش‌ها و فرصت‌های پیش‌رو پرداخته است. از دستاوردهای این مطالعه می‌توان به موارد زیر اشاره کرد:

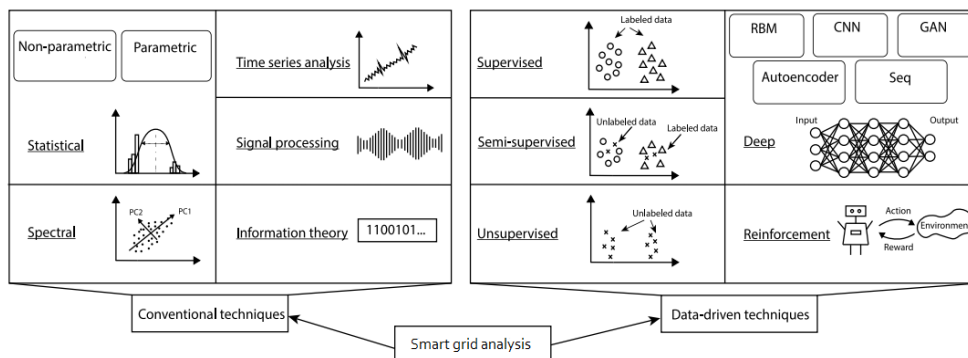
- ارائه طبقه‌بندی روش‌های مختلف داده‌محور استفاده شده در شبکه هوشمند برق شامل یادگیری ماشین و یادگیری عمیق.
 - معرفی چرخه حیات کلان‌داده مورد استفاده در شبکه هوشمند برق و روش‌های قابل استفاده در هر گام.
 - ارائه طبقه‌بندی سرویس‌های کلان‌داده در شبکه هوشمند برق، معرفی روش‌های یادگیری ماشین و یادگیری عمیق استفاده شده به ازای هر سرویس و ارزیابی مقایسه‌ای میزان تاثیر هر یک از این روش‌ها در سرویس‌های مطروحه.
 - معرفی چالش‌ها و فرصت‌های پیش‌روی شبکه‌های هوشمند در صنعت برق.
- ساختار مقاله در ادامه به این شرح است. روش‌های مرسوم در مقابل روش‌های داده‌محور مورد استفاده در شبکه‌های هوشمند برق در بخش ۲ به تفصیل آورده شده است. کلان‌داده در شبکه هوشمند برق در بخش سوم تشریح شده است. در ادامه سرویس‌های کلان‌داده در شبکه هوشمند برق در بخش ۴ معرفی شده‌اند. در بخش پنجم بررسی روش‌های به‌کار گرفته شده در سرویس‌های شبکه هوشمند برق به همراه چالش‌ها و فرصت‌های پیش‌رو آورده شده است. در انتها در بخش ۶ نتیجه‌گیری بیان شده است.

۲- روش‌های مرسوم در مقابل روش‌های داده‌محور مورد استفاده در شبکه‌های هوشمند برق

در این بخش مروری بر روش‌های مرسوم و داده‌محور قابل استفاده در شبکه‌های هوشمند ارائه شده است. در ابتدا به نقاط ضعف و قوت روش‌های متداول که سابقه طولانی استفاده در صنعت برق دارند اشاره شده و در ادامه ظهور روش‌های داده‌محور شامل روش‌های مبتنی بر یادگیری ماشین و یادگیری عمیق در پاسخ به ضعف‌های روش‌های مرسوم بررسی شده است. روش‌های مرسوم را می‌توان به روش‌های آماری، آنالیز سری‌های زمانی، پردازش سیگنال، روش‌های طیفی و تئوری اطلاعات تقسیم کرد. از طرف دیگر روش‌های داده‌محور با تکیه بر دو دسته‌بندی الگوریتم‌های یادگیری ماشین و یادگیری عمیق سعی در پاسخ به نیازهای مطرح شده در شبکه‌های هوشمند دارد. دسته‌بندی‌های یاد شده در شکل (۱) نشان داده شده که ادامه توضیح داده خواهد شد.

۲-۱- روش‌های مرسوم

روش‌های مرسوم در تجزیه و تحلیل شبکه‌های هوشمند در طول سال‌های گذشته استفاده شده است. تشخیص انحراف از یک مدل تعریف شده توسط روش‌های آماری، شناسایی تغییر فرکانس در حوزه تبدیل فوریه به‌وسیله پردازش سیگنال و تشخیص اعوجاج در محتوا به کمک استفاده از تئوری اطلاعات نمونه‌هایی از این دسته است که در ادامه توضیح داده خواهد شد.



شکل (۱): روش‌های مرسوم در مقابل روش‌های داده‌محور مورد استفاده در شبکه‌های هوشمند

Figure (1): Conventional methods Vs. Data-driven methods used in smart power grid

۱-۲-۱- روش‌های آماری

در روش‌های آماری فرض بر این است که داده‌های سیستمی بر اساس مدل‌های آماری تولید شده‌اند. هر انحراف از مدل مورد انتظار به‌عنوان یک ناهنجاری در نظر گرفته می‌شود. به‌منظور تشخیص این ناهنجاری‌ها آزمایش‌های استنتاجی آماری شامل روش‌های پارامتری و غیر پارامتری به‌کار گرفته می‌شود. در روش‌های پارامتری توزیع داده مشخص است و پارامترها بر اساس داده‌ها تخمین زده می‌شود. مدل رگرسیون و مدل گاوسی^{۱۰} به‌عنوان نمونه‌هایی از این روش‌ها شناخته می‌شوند [۶]. از طرف دیگر توزیع داده‌ها در روش‌های غیر پارامتری مشخص نیست و براساس داده‌های جاری مشخص می‌گردد. روش‌های مبتنی بر هیستوگرام^{۱۱}، تابع هسته^{۱۲} و مجاورت^{۱۳} به‌عنوان نمونه‌های شاخص دسته غیر پارامتری شناخته می‌گردند [۷]. از مزایای روش‌های آماری می‌توان به قابل توضیح بودن و قابل تفسیر بودن آنها (مخصوصاً در هنگامی که توزیع داده‌ها مشخص است) اشاره کرد. از طرفی دیگر پیچیدگی محاسباتی بالا در مواجهه با مدل‌ها و روش‌های با توزیع پیچیده و عملکرد ضعیف‌تر نسبت به روش‌های یادگیری ماشین در کار با داده‌های با تعداد ویژگی زیاد به‌عنوان نقاط ضعف روش‌های آماری محسوب می‌گردد [۸].

۲-۱-۲- تحلیل سری‌های زمانی

تحلیل سری‌های زمانی در اغلب موقعیت‌هایی که داده‌ها توسط سیستم‌های سنسوری^{۱۴} تولید می‌گردد استفاده می‌شود. این روش بر تحلیل ویژگی‌های داده به‌منظور استخراج آمارهای قابل استفاده از آنها متمرکز است. پیش‌بینی با استفاده از تحلیل سری زمانی به‌منظور تخمین مقادیر آینده مورد انتظار داده‌ها استفاده می‌گردد. از روش‌های متداول این دسته می‌توان به تحلیل همبستگی متقابل^{۱۵}، میانگین متحرک یکپارچه خودگردان^{۱۶} (ARIMA) و فیلتر کالمن^{۱۷} اشاره کرد [۹]. سادگی و تاثیرگذاری از ویژگی‌های بارز روش‌های مبتنی بر تحلیل سری‌های زمانی به حساب می‌آید، اما در موقعیت‌هایی که با تغییرات چشم‌گیری همراه است، استفاده از تحلیل سری زمانی نتایج رضایت‌بخشی به همراه ندارد [۱۰].

۲-۱-۳- پردازش سیگنال

پردازش سیگنال با تحلیل انواع مختلفی از سیگنال‌ها شامل سیگنال‌های صوتی، تصویری، حاصل شده از نظارت فرایندهای فیزیکی و جریان‌های داده‌ای از سنسورها سر و کار دارد. روش‌های پردازش سیگنال اغلب در موقعیت‌هایی به‌کار گرفته می‌شوند که سیگنال‌ها تحت اثرپذیری نویز قرار دارند و در نتیجه مکانیزم‌های جداسازی نویز به‌کار گرفته می‌شوند. تبدیل‌های متفاوتی مانند تبدیل فوریه و تبدیل‌های بر پایه موجک^{۱۸} در این خصوص استفاده می‌گردد. به‌عنوان نمونه در مرجع [۱۱] نویسندگان تحلیل کرده‌اند که چگونه تجمیع زمانی در نمونه‌برداری بسته تصادفی^{۱۹} ویژگی‌های یک سیگنال را تغییر می‌دهند. برای این منظور گام تجمیعی با یک فیلتر پایین‌گذر^{۲۰} طراحی شده خاص جایگزین شده است. با وجود آنکه روش‌های پردازش سیگنال در موقعیت‌هایی همچون مواجهه با وقایع غیرعادی نرخ تشخیص خوبی را به نمایش می‌گذارند، اما این روش‌ها بر مبنای فرض‌های غیرواقعی از پردازش استوار هستند که بر عملکرد آنان اثر مخرب خواهد گذاشت.

۲-۱-۴- روش‌های طیفی

روش‌های طیفی سعی در کاهش ابعاد دارند. اساس این روش‌ها نگاشت فضای مسئله به فضای جدیدی با تعداد ویژگی کمتر است که در آن تفکیک‌پذیری بالاتری بین داده‌های عادی و غیرعادی اتفاق می‌افتد. این روش‌ها می‌توانند بر پایه روش متداول تجزیه و تحلیل اجزای اصلی^{۲۱} (PCA) باشند که در آن داده به فضای با ابعاد کمتر نگاشت می‌گردد. در مواقعی که فضای مسئله با داده‌های با ابعاد بالا مواجه است ویژگی کاهش ابعاد این روش‌ها به‌عنوان یک نقطه قوت به‌شمار می‌آید. همچنین استفاده از روش‌های کاهش ابعاد به‌عنوان یک مرحله پیش‌پردازش می‌تواند مناسب باشد اما باید در نظر داشت این روش‌ها اغلب با پیچیدگی محاسباتی بالایی همراه هستند که به‌عنوان نقطه ضعف روش‌های طیفی محسوب می‌گردد [۱۲].

۲-۱-۵- نظریه اطلاعات

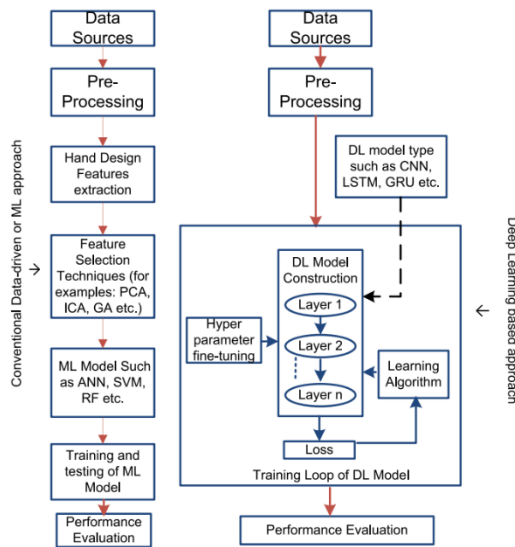
هدف روش‌ها در این دسته‌بندی، تحلیل محتوای اطلاعات یک مجموعه داده با به‌کارگیری معیارهای نظریه اطلاعاتی مختلف مانند پیچیدگی کولموگوروف^{۲۲}، آنتروپی^{۲۳} و آنتروپی نسبی^{۲۴} است. به‌طور معمول این معیارها ابتدا از طریق کل مجموعه داده ایجاد می‌گردد و سپس باید یک زیر مجموعه از داده‌ها معلوم گردد. در اصل انتخاب یک معیار تئوری اطلاعاتی خاص می‌تواند بر عملکرد الگوریتم‌های متفاوت تاثیرگذار باشد. علاوه بر این، در مواجهه با داده‌های ذاتاً مرتب، انتخاب روش‌های نظریه اطلاعات به تعیین سائز زیر ساخت بهینه بستگی دارد. اما به هر حال این روش‌ها توزیع آماری نهفته در داده‌ها را به حساب نمی‌آورد [۶].

۲-۲- روش‌های داده‌محور

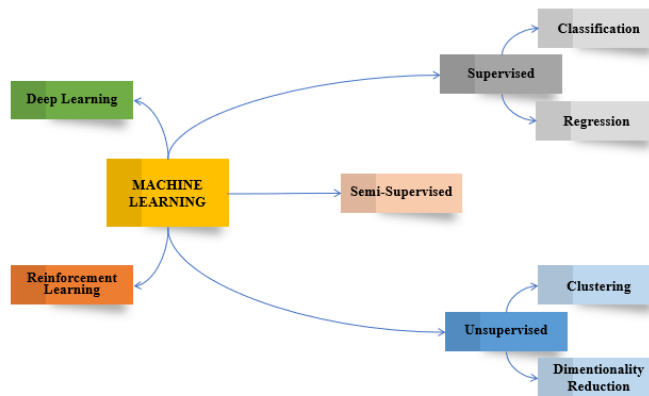
آژانس بین‌المللی انرژی‌های تجدیدپذیر^{۲۵} (IRENA) هوش مصنوعی را به‌عنوان یکی از حوزه‌های علم کامپیوتر تعریف می‌کند که در آن تمرکز بر ایجاد ماشین‌های هوشمندی است که بر مبنای داده‌های جمع‌آوری شده رفتار انسان را تقلید می‌کنند. این تعریف نقطه شروع توسعه خدمات داده‌محور در صنعت برق به‌شمار می‌رود. حجم عظیم داده‌های در حال تولید در کنار سیستم‌های قدرت (از تولید تا تقاضا) این فرصت را پدید آورده است تا درک بهتری از سیستم‌ها حاصل گردد و خدمات نوآورانه بر مبنای این داده‌ها به‌وجود آید [۱۳]. روش‌های داده‌محور معمولاً به روش‌های بر مبنای یادگیری اشاره می‌کنند که در آنها فقدان یک مدل ریاضی استوار را می‌توان با حجم عظیمی از داده‌ها که در یادگیری استفاده می‌گردند جبران نمود [۸]. یادگیری ماشین به عنوان یک زیرحوزه از هوش مصنوعی و علوم کامپیوتر مطرح شده که از شناسایی الگو تا تجزیه و تحلیل ساختمان‌های داده تکامل پیدا کرده است. این تجزیه و تحلیل به نحوی مدل می‌گردد که قابل فهم و تکرارپذیر برای کاربران باشد [۱۴]. این بیان منطبق با تعریف مورفی در مرجع [۱۵] است که یادگیری ماشین را مجموعه‌ای از روش‌ها تعریف می‌کند که به‌طور خودکار الگوهای موجود در داده‌ها را تشخیص می‌دهند. روش‌های یادگیری ماشین به عنوان یک راه‌کار امید بخش در جهت خودکار کردن فرایند جمع‌آوری داده به‌منظور تحلیل در سطح محلی و کلان مورد توجه قرار گرفته‌اند. این مجموعه روش‌ها می‌توانند به‌طور خودکار الگوهای موجود در داده را تشخیص داده و سپس از این الگوها به‌منظور پیش‌بینی شرایط آینده یا تصمیم‌گیری با در نظر گرفتن شرایط عدم قطعیت استفاده کنند. با این وجود این روش‌ها در مواجهه با حجم عظیم داده‌های تولیدی نیاز به اصلاح و بهبود دارند [۱۶]. در چندین حوزه شبکه‌های هوشمند برق روش‌های یادگیری ماشین به نقاط عطفی دست یافته‌اند، با این حال چالش‌های بسیاری در شبکه‌های عصبی سطحی^{۲۶} و مدل‌های یادگیری ماشین ساده خودنمایی می‌کند که باعث می‌گردد این روش‌ها در مسائل پیچیده سیستم‌های قدرت به‌ندرت مورد استفاده قرار گیرند [۲]. این چالش‌ها به‌طور گسترده‌ای از دو واقعیت نشأت می‌گیرد: (۱) الگوریتم‌های یادگیری غیر عمیق برای کار روی داده‌های با ابعاد بالا و پیچیدگی‌های بی‌دلیل، موثر نیست [۱۷، ۱۸]. (۲) دقت مدل‌های یادگیری ماشین ساده با حجم عظیمی از داده نمی‌تواند بهبود پیدا کند [۱۹، ۲۰]. به‌منظور مقابله با این مشکلات الگوی یادگیری به سمت یادگیری عمیق به عنوان برجسته‌ترین پرچم‌دار یادگیری ماشین سوق پیدا کرد. این تغییرات در راستای بهره‌برداری از فراوانی کلان‌داده با استخراج ویژگی سلسله‌مراتبی به‌هنگام و با کارایی بالا صورت پذیرفت [۳]. شکل (۲) اختلاف مفهومی کلی بین یادگیری ماشین مرسوم و یادگیری عمیق را نشان می‌دهد [۴]. روش‌های یادگیری ماشین مرسوم محدودیت‌های متعددی برای پردازش داده‌های خام دارند، با این وجود یادگیری عمیق گزینه‌هایی را برای پردازش آنها بدون استخراج و انتخاب بردار ویژگی پیشنهاد داده است [۱۷]. یادگیری عمیق در ازای روال‌ها و قوانین متعدد غیر خودکار به‌منظور استخراج بردار ویژگی از داده‌های خام، یادگیری خودکار این ویژگی‌ها را در زمان آموزش فراهم می‌کند [۱۹، ۲۲].

۱-۲-۲- طبقه‌بندی روش‌های یادگیری ماشین

در سال‌های اخیر با پیشرفت سیستم‌های پردازشی و کلان‌داده، یادگیری ماشین به‌طور چشم‌گیری در حوزه‌های مختلف به‌کار گرفته شده است [۱۸]. در بسیاری از کاربردها اثبات شده که ماشین‌ها نسبت به انسان‌ها عملکرد بهتری دارند، اما اکثر کارشناسان اذعان دارند که یادگیری ماشین همچنان در حال توسعه سریع است و به اوج شکوفایی خود نرسیده است. یادگیری ماشین در به‌دست آوردن تجربه از داده‌های تاریخی^{۲۷} و تصمیم‌های قبلی قدرتمند است. مطالعات تجربی نشان می‌دهد که ادغام یادگیری ماشین و سیستم‌های قدرت قادر به ارائه منافع چشم‌گیری است [۱۹].



شکل (۲): یادگیری ماشین مرسوم در مقابل یادگیری عمیق [۴]
Figure (2): Conventional Machine Learning Vs. Deep Learning [4]



شکل (۳): دسته‌بندی روش‌های یادگیری ماشین
Figure (3): Machine Learning classification

شکل (۳) دسته‌بندی‌های یادگیری ماشین، روش‌ها و مدل‌های کاربردی در سیستم‌های قدرت را نشان می‌دهد. بر این اساس الگوریتم‌های یادگیری ماشین به پنج دسته نظارت شده^{۲۸}، بدون نظارت^{۲۹}، نیمه نظارتی^{۳۰}، یادگیری تقویتی^{۳۱} و یادگیری عمیق^{۳۲} تقسیم می‌گردند. هدف این روش‌ها پیش‌بینی یا توصیف روابط موجود در مجموعه داده‌ها است به طوری که اگر با متغیر وابسته مواجه باشیم یادگیری تحت نظارت و در غیر این صورت یادگیری بدون نظارت مورد استفاده قرار می‌گیرد [۲۰].

الف- یادگیری نظارت شده: این نوع یادگیری به روش‌های یادگیری ماشینی اشاره می‌کند که در آن یک مدل با استفاده از مجموعه نمونه‌ها دارای خروجی هدف (برچسب‌ها) آموزش داده می‌شود. با تکیه بر این واقعیت که آموزش و تست مدل‌های مبتنی بر یادگیری نظارت شده با استفاده از داده‌های برچسب گذاری شده انجام می‌گیرد، این روش‌ها توانمندی مطلوبی از خود نشان داده‌اند. خانواده روش‌های یادگیری نظارت شده به دو دسته اصلی طبقه‌بندی^{۳۳} و رگرسیون تقسیم می‌شوند. از روش‌های مشهور طبقه‌بندی می‌توان به طبقه‌بند ماشین بردار پشتیبان^{۳۴} و طبقه‌بند K نزدیکترین همسایه^{۳۵} (KNN) اشاره کرد. همچنین روش‌های رگرسیون خطی و درخت تصمیم^{۳۶} را می‌توان به عنوان نمونه روش‌های مشهور دسته رگرسیون نام برد [۲۱].

ب- یادگیری نیمه نظارتی: یادگیری نیمه نظارتی به طور کلی به روش‌های یادگیری ماشینی اشاره می‌کند که از حجم کوچکی از داده‌های برچسب گذاری شده و حجم زیادی از داده‌های بدون برچسب استفاده می‌کند. همچنین روش‌های نیمه نظارتی می‌توانند به روش‌های یادگیری ماشینی اشاره کنند که یک طبقه‌بند را با استفاده از داده‌های برچسب گذاری شده آموزش می‌دهند. اگرچه در فرایند آموزش مدل از برچسب گذاری‌های صریح استفاده نشده است، این نوع مجموعه داده آموزشی می‌تواند

از دنیای واقعی به دست آید که در آن برچسب گذاری یا جداسازی داده‌های نرمال از مجموعه عظیم داده‌ها (شامل داده‌های نرمال و غیرنرمال) انجام می‌پذیرد. ماشین بردار پشتیبان وان کلاس^{۳۷} یک نوع روش یادگیری نیمه نظارتی است که الزامی به برچسب گذاری داده‌های غیرنرمال ندارد. اگرچه یادگیری نیمه نظارتی بهترین انتخاب برای استفاده در زمان‌هایی است که حجم کمی از داده‌های برچسب گذاری شده موجود است، باید در نظر داشت با محدودیت‌هایی در ارتباط با استفاده از داده‌های برچسب گذاری نشده مواجه هستیم. این محدودیت‌ها بر مبنای رابطه بین توزیع داده‌های برچسب گذاری شده و بدون برچسب است که در آن فرض‌های غلط ممکن است به عملکرد ضعیف منجر شود [۲۲].

ج- یادگیری بدون نظارت: یادگیری بدون نظارت یکی از روش‌های یادگیری ماشین است که به منظور تعیین وابستگی‌ها در داده‌های بدون برچسب استفاده می‌شود. از روش‌های متداول این دسته می‌توان به خوشه بندی^{۳۸}، استخراج قوانین انجمنی^{۳۹}، تشخیص ناهنجاری (داده‌های پرت^{۴۰}) و تخمین چگالی^{۴۱} اشاره کرد. در همه این روش‌ها هدف اصلی استنتاج ساختار داده بدون استفاده از برچسب گذاری است به طوری که یک نمایش کاربردی از داده‌ها تولید کند.

به دلیل احتمال بالای مواجه با داده‌های برچسب گذاری شده تعداد مقاله‌های یادگیری بدون نظارت کمتر از یادگیری تحت نظارت است [۲۱]. روش‌های یادگیری بدون نظارت عمدتاً به منظور تقسیم بندی پروفایل‌ها به کار می‌روند.

د- یادگیری تقویتی: یادگیری تقویتی در مقایسه با دیگر دسته‌بندی‌ها مورد مطالعه کمتری قرار گرفته است با اینحال این نوع یادگیری، یادگیری هدفمند بدون ناظر را ارائه می‌دهد. این سبک یادگیری خود را با محیط‌های پویا وفق داده و چارچوب‌هایی برای فهم و مدل‌سازی سیستم‌ها بر مبنای پاداش و جریمه فراهم می‌آورد. یادگیری تقویتی می‌تواند در حل مشکلات تصمیم‌گیری ترکیبی پیچیده و به طور خاص در پاسخ به طیف گسترده‌ای از مشکلات صنعتی مانند کنترل و برنامه‌ریزی کمک نماید [۲۱]. چهار مولفه اصلی یادگیری تقویتی شامل عامل، محیط، بازخورد و عمل است. هدف یادگیری تقویتی این است که پاداش عامل با در نظر گرفتن مجموعه‌ای از اعمال در محیط حداکثر شود. این نوع یادگیری می‌تواند از تصمیم‌گیری ترتیبی با در نظر گرفتن شرایط عدم قطعیت حمایت کند. یک الگوریتم یادگیری تقویتی عادی با توجه به دانش محدودی که از محیط کسب می‌نماید و بازخورد محدود از تصمیم‌ها عمل می‌کند. از متداول‌ترین الگوریتم‌های یادگیری تقویتی می‌توان به یادگیری Q^{۴۲} و سارسا^{۴۳} (SARSA) اشاره کرد. یادگیری تقویتی اغلب در حوزه‌های بازی‌سازی، راهبری و رباتیک استفاده می‌گردد [۲۳].

ه- یادگیری عمیق: در بسیاری از حوزه‌ها اهداف مختلفی با ارائه روش‌های یادگیری ماشین برآورده شده‌اند. با این وجود شبکه‌های مصنوعی سطحی و مدل‌های ساده یادگیری ماشین با چالش‌های فراوانی مواجه شده‌اند که به کارگیری آنها به منظور حل مشکلات پیچیده رضایت بخش نبوده است [۲۴]. در سال‌های اخیر با رشد فزاینده داده‌ها یک ظهور چشم‌گیری در بهبود الگوریتم‌های هوش مصنوعی و صنعت سخت‌افزار به وقوع پیوست که باعث شد هوش مصنوعی به یک مرحله تکامل یافته وارد گردد [۲۵]. از این رو یادگیری عمیق به عنوان یک زیر مجموعه از یادگیری ماشین از شبکه‌های عصبی مصنوعی چندلایه پدیدار شد. یادگیری عمیق، معنایی فراتر از معنای کنونی دارد که در آن از یادگیری عمیق صرفاً به عنوان شبکه عصبی عمیق یاد می‌شود که مطابق این دیدگاه واژه عمیق به تعداد لایه‌ها اشاره دارد. با این حال ساختارهای متفاوت از یادگیری عمیق وجود دارد که می‌توان به ماشین بولتزمن^{۴۴}، شبکه‌های باور عمیق^{۴۵} (DBN)، شبکه‌های عمیق پیش‌خور^{۴۶} (FDN)، شبکه‌های عصبی کانولوشنی^{۴۷} (CNN)، شبکه‌های عصبی بازگشتی^{۴۸} (RNN)، شبکه‌های حافظه بلند-کوتاه مدت^{۴۹} (LSTM) و شبکه‌های متخاصم مولد^{۵۰} (GAN) اشاره کرد [۲۶]. امروزه یادگیری عمیق توانایی خارق‌العاده‌ای در بسیاری از حوزه‌ها مانند شناسایی تصویر^{۵۱}، شناسایی گفتار^{۵۲}، پردازش زبان‌های طبیعی^{۵۳} (NLP)، مدیریت سلامت^{۵۴} و نظامی^{۵۵} از خود نشان داده است [۳۱، ۳۲].

۲-۲-۲- طبقه‌بندی روش‌های یادگیری عمیق

در سال‌های اخیر شبکه‌های عصبی عمیق با توجه به پیشرفت‌های حاصل شده در حوزه‌های عملکرد محاسباتی و ذخیره داده در کانون توجه قرار گرفته‌اند. الگوی یادگیری عمیق با توجه به پتانسیل قوی خود به‌عنوان نماینده روش‌های یادگیری به موفقیت چشم‌گیری دست یافته است. کارایی روش‌های یادگیری عمیق به منظور نمایش ویژگی‌ها با سطوح انتزاعی مختلف بر مبنای

چندین واحد پردازشگر قدرت گرفته است [۲۷]. روش‌های یادگیری عمیق را می‌توان به دسته‌های متمایز کننده، احتمالی و تقویتی تقسیم کرد که در شکل (۴) نشان داده شده است.

الف- یادگیری عمیق متمایز کننده: یکی از حوزه‌های اصلی در یادگیری ماشین، مدل‌سازی متمایز کننده است. این روش تلاش می‌کند تقریبی از تابع f_θ به دست آورد که در آن θ متعلق به \mathbb{R}^P است و مستقیماً ورودی را به خروجی صحیح نگاشت می‌کند. مجموعه داده‌های آموزشی D_{Tr} به صورت زیر که شامل n نمونه آموزشی به صورت (x_i, y_i) است را در نظر بگیرد:

$$D_{Tr} = \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\} \quad (1)$$

متناظر با هر ورودی x_i خروجی یا برچسب y_i وجود دارد. همچنین مجموعه داده‌های تست شامل m نمونه مشاهده نشده به صورت D_{Ts} مفروض است:

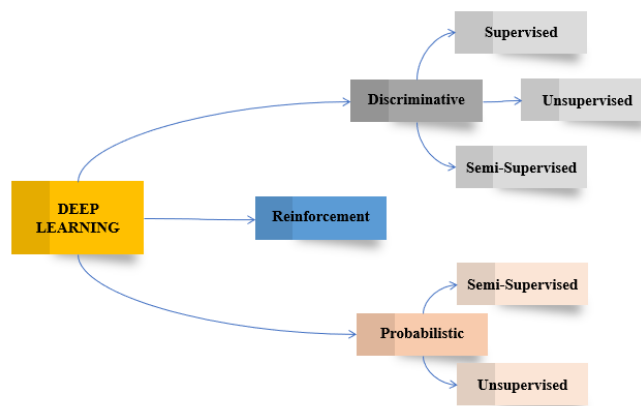
$$D_{Ts} = \{(x_{n+1}, y_{n+1}), (x_{n+2}, y_{n+2}), \dots, (x_{n+m}, y_{n+m})\} \quad (2)$$

هدف، یادگیری پارامتر بهینه θ^* است به نحوی که میانگین فاصله بین $f_{\theta^*}(x)$ و y کمترین مقدار را برای همه نمونه‌های (x, y) متعلق به D_{Tr} داشته باشد.

همچنین خطای تست برابر میانگین خطا بین $f_{\theta^*}(x)$ و y برای همه (x, y) متعلق به D_{Ts} است. پرسپترون چند لایه کلاسیک^{۵۶} یک لایه ورودی h^0 متعلق به \mathbb{R}^{d_0} و تعداد L لایه محاسباتی $\{h^1, h^2, \dots, h^L\}$ به منظور به دست آوردن یک نگاشت غیر خطی بین ورودی و خروجی تعریف می‌کند. هر لایه h^i متعلق به \mathbb{R}^{d_i} است که مقداری بین یک و L دارد و یک تابع غیر خطی از لایه قبل است که توسط رابطه زیر مشخص می‌شود:

$$h^i = g^i(W^i h^{i-1} + b^i) \quad (3)$$

در این رابطه g^i یک تابع تبدیل غیر خطی است که معمولاً با توابع سیگموئید^{۵۷} یا تانژانت هایپربولیک^{۵۸} محاسبه می‌شود. همچنین ماتریس وزن W^i ^{۵۹} متعلق به $\mathbb{R}^{d_i \times \mathbb{R}^{d_{i-1}}}$ و b^i متعلق به \mathbb{R}^{d_i} ، بایاس تابع فعال‌ساز در لایه h^i است. پرسپترون چند لایه کلاسیک با استفاده از چندین لایه مخفی یک تبدیل غیر خطی بین ورودی h^0 برابر با x و خروجی h^L برابر با y در مجموعه داده‌ها فراهم می‌کند. برای آموزش هر لایه h^i با بهره‌گیری از روش گرادین کاهشی^{۶۰} (GD) پارامترهای W^i و b^i در خلاف جهت گرادین خطای آموزش به ترتیب W^i و b^i حرکت داده می‌شوند. همان‌طور که گرادین به‌طور چشمگیری کاهش پیدا می‌کند و همزمان افزایش مقدار L صورت می‌پذیرد، یک مبادله بین تعداد لایه‌های محاسباتی L و قدرت گرادین کاهشی برای به‌هنگام کردن مدل وجود دارد. هنگامی که مقدار L به‌منظور حل مسائل پیچیده افزایش پیدا می‌کند از کارایی گرادین کاهشی کاسته می‌گردد. بنابراین پرسپترون چند لایه کلاسیک قابلیت تعمیم برای حل دقیق مسائل دنیای واقعی را ندارد. در نتیجه یادگیری عمیق متمایز کننده پیشنهاد شد تا به‌صورت کارآمد شبکه‌های عصبی مصنوعی عمیق را با $L > 1$ آموزش دهد [۲۸]. الگوریتم‌های عمیق یادگیری متمایز کننده به سه دسته تحت نظارت، بدون نظارت و نیمه نظارتی تقسیم می‌گردند. از جمله الگوریتم‌های تحت نظارت می‌توان به شبکه‌های کانولوشنی، بدون نظارت به شبکه‌های حافظه بلند-کوتاه مدت و نیمه نظارتی به شبکه‌های رمزنگار خودکار پشته‌ای^{۶۱} اشاره کرد.



شکل (۴): دسته‌بندی روش‌های یادگیری عمیق
Figure (4): Deep learning classification

ب- یادگیری عمیق تقویتی: شبکه‌های عصبی مصنوعی عمیق تقویتی در کنار طبقه‌بندی و رگرسیون به کار گرفته می‌شوند تا مسائلی که به صورت فرایند تصمیم‌گیری مارکف^{۶۲} (MDP) مدل شده‌اند را حل نمایند. در این مدل که به صورت (S, A, P_a, R_a) نمایش داده می‌شود، مجموعه حالت‌ها S ، دامنه اعمال A و احتمال انتقال حالت از رابطه زیر تعیین می‌گردد:

$$P_a(s, s') = P(S_{t+1} = s' | s_t = s, a_t = a) \quad (4)$$

برای مدل کردن احتمال رفتن به حالت s_{t+1} در زمان $t+1$ وقتی زمان t و حالت s است. نتیجه این تغییر حالت مشاهده پاداش/جریمه فوری از طرف محیط، $R_a(s_t=s, s_{t+1}=s^t)$ است. هدف یافتن سیاست بهینه، $\pi^*(s_t)$ است که عمل a_t را مشخص می‌کند و مجموع پاداش مورد انتظار که توسط رابطه زیر به دست می‌آید:

$$R_{avg} = \mathbb{E} \left[\sum_{t=0}^{\infty} \gamma^t R_a(s_t, s_{t+1}) \right] \quad (5)$$

را ماکزیمم کند و شرط زیر برقرار باشد:

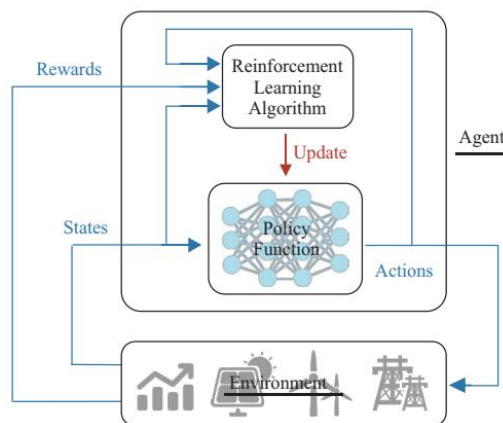
$$0 \leq \gamma \leq 1 \quad (6)$$

سیاست بهینه، $\pi^*(s_t)$ برای هر حالت s متعلق به S توسط رابطه زیر به دست می‌آید:

$$\pi^*(s) = \arg \max_a Q(s, a) \quad (7)$$

که در آن مقدار بهینه تابع حالت/عمل است که پاداش انجام عمل a در حالت s را تخمین می‌زند [۲۹،۳۰]. در شکل (۵) ساختار یادگیری عمیق تقویتی نشان داده شده است [۳۱]. از الگوریتم‌های این دسته به عنوان نمونه می‌توان به شبکه Q عمیق^{۶۳}، DQN دوگانه^{۶۴} و گرادیان خط مشی قطعی عمیق^{۶۵} (DDPG) اشاره کرد.

ج- یادگیری عمیق احتمالی: در مقابل یادگیری عمیق متمایز کننده که در آن یک تابع صریح x را به y نگاشت می‌کند که (x, y) متعلق به D_{tr} هستند، هدف معماری عصبی عمیق احتمالی بدست آوردن یک تابع توزیع احتمال $P(x)$ برای تمامی نمونه‌های موجود در مجموعه داده‌های آموزشی D_{tr} است. در نتیجه یک تابع صریح یاد می‌گیرد که $P(x)$ را به $P(x|y)$ نگاشت کند، به نحوی که یادگیری خروجی صحیح y برای تمامی نمونه‌های (x, y) متعلق به D_{tr} انجام می‌پذیرد [۳۲]. شبکه‌های عصبی عمیق احتمالی یادگیری ویژگی را به عنوان یک فرایند کشف مجموعه‌ای از متغیرهای پنهان در نظر می‌گیرند به طوری که این متغیرها تابع تراکم احتمالی^{۶۶} (PDF) داده را به بهترین صورت توصیف می‌کنند. این تابع سپس کلاس متغیر را مشخص می‌کند. در شبکه‌های متخاصم مولد مجموعه داده حقیقی با نمونه داده‌های تولیدی به منظور افزایش دقت تابع تراکم احتمالی یادگیری شده مقایسه می‌گردد. از آنجائی که این مدل ویژگی‌های اصلی این تابع را یاد می‌گیرد، اخیراً در حل مسائل تشخیص خطا و ناهنجاری در توربین‌های بادی [۳۳] و تشخیص حملات سایبری [۳۴] بر روی شبکه هوشمند برق به کار گرفته می‌شود. همچنین این شبکه‌ها به منظور تولید سناریو تجدیدپذیر بی‌نیاز از مدل استفاده می‌شود [۳۵]. الگوریتم‌های یادگیری عمیق احتمالی را می‌توان به دو دسته بدون نظارت و نیمه نظارتی تقسیم بندی کرد. شبکه‌های متخاصم مولد و شبکه‌های باور عمیق را می‌توان به ترتیب به عنوان نمونه‌ای از یادگیری بدون نظارت و نیمه نظارتی نام برد.



شکل (۵): ساختار یادگیری عمیق تقویتی [۳۱]

Figure (5): Deep reinforcement learning structure [31]

۳- کلان‌داده در شبکه‌هاى هوشمند برق

به‌منظور ساختن شبکه هوشمند برق نیاز به حجم زيادى از اطلاعات مختلف شامل داده‌هاى عملياتى همچون داده‌هاى نظارتى و كنترلى از راه دور و غير عملياتى مانند داده‌هاى آب و هوايى توليد شده از منابع مختلف ابرى^{۶۷}، مه^{۶۸} و لبه^{۶۹} است. اين داده‌ها مى‌توانند بلادرنگ يا تاريخى و از لحاظ تنوع شامل اطلاعات آب و هوايى، شبکه‌هاى اجتماعى، رفتار مشتركين، جغرافيايى و بازار برق باشد. در شكل (۶) معماری مفهومی شبکه‌هاى هوشمند ارائه شده كه نشان دهنده منابع مختلف جمع‌آورى داده است. تكنولوژى‌هاى کلان‌داده فرصت مناسبى براى سرويس‌هاى سودمند ايجاد مى‌كنند كه با متدلوژى‌ها، مدل‌هاى ارزيايى و برنامه‌هاى كاربردى جديد همراه است و مديريت داده در شبکه‌هاى هوشمند را بهبود مى‌بخشد [۳۶].

کلان‌داده مى‌تواند به عنوان حجم عظيمى از مجموعه داده‌ها تعريف گردد، اما در حقيقت شامل ويژگى‌هاى ديگرى است كه عبارتند از [۳۷]:

الف- حجم^{۷۰}: اين ويژگى به حجم عظيمى از داده‌هاى توليد شده اشاره دارد. در شبکه‌هاى هوشمند كاربرد گسترده سيستم‌هاى اندازه‌گيرى هوشمند و استفاده از سنسورهاى پيشرفته حجم چشم‌گيرى از داده‌ها را توليد مى‌كند.

ب- تنوع^{۷۱}: اين ويژگى به وجود داده با قالب‌هاى متنوع شامل ساختار يافته، نيمه ساختار يافته و بدون ساختار اشاره دارد. با توجه به منابع بسيار وسيع موجود در شبکه‌هاى هوشمند، داده با ابعاد و قالب‌هاى متنوع از حيث ساختار وجود دارد كه در شكل (۷) [۳۸] به نمايش درآمده است.

ج- سرعت^{۷۲}: اين ويژگى به سرعت توليد و انتقال داده اشاره دارد. با در نظر گرفتن نرخ نمونه گيرى چهار بار در ساعت، يك ميليون دستگاه اندازه‌گيرى هوشمند نصب شده در يك شبکه هوشمند برق مى‌تواند ۳۵/۰۴ ميليارد ركورد (معادل با ۲۹۲۰ ترابايت) توليد كند [۳۹].

د- ارزش^{۷۳}: اين ويژگى به توانايى استخراج مقادير معنادار از مجموعه داده‌هاى جمع‌آورى شده اشاره دارد. با پيشرفت دستگاه‌هاى هوشمند تطبيق داده شده با شبکه هوشمند برق، ارزش هر چه بيشتر تحليل کلان‌داده با توجه به كاربردهاى گسترده آن آشكار شده است.

ه- صحت^{۷۴}: اين ويژگى به قابل اعتماد بودن داده‌ها اشاره دارد. خطاهاى اندازه‌گيرى در شبکه‌هاى هوشمند با توجه به نقص در دستگاه‌ها يا خطا در انتقال داده وجود دارد. عملكرد يك سيستم قدرت كارا و امن با تكيه بر ارزيايى داده است.

۳-۱- چرخه حيات کلان‌داده در شبکه هوشمند برق

چرخه حيات کلان‌داده در شبکه‌هاى هوشمند شامل جمع‌آورى و يکپارچه سازى، ذخيره، پيش-پردازش، تجزيه و تحليل و تجسم داده‌ها است كه در شكل (۸) نشان داده شده است:

الف- جمع‌آورى و يکپارچه سازى کلان‌داده: شبکه هوشمند برق به عنوان يك سيستم انرژى-اطلاعاتى هوشمند منبع فراوانى از اطلاعات است كه داده‌هاى فرايندى از توليد، انتقال، توزيع و مصرف برق را شامل مى‌شود. كلاس‌هاى داده‌ايى متمايزى با توجه به نوع ارزش‌هاى استخراج شده به شرح زير وجود دارد:

- داده‌هاى عملياتى: داده‌هاى برقى يك شبکه كه نشان دهنده پارامترهاى از جمله جريان توان واكنشى^{۷۵}، ولتاژ و ظرفيت پاسخ‌گويى به تقاضا هستند.

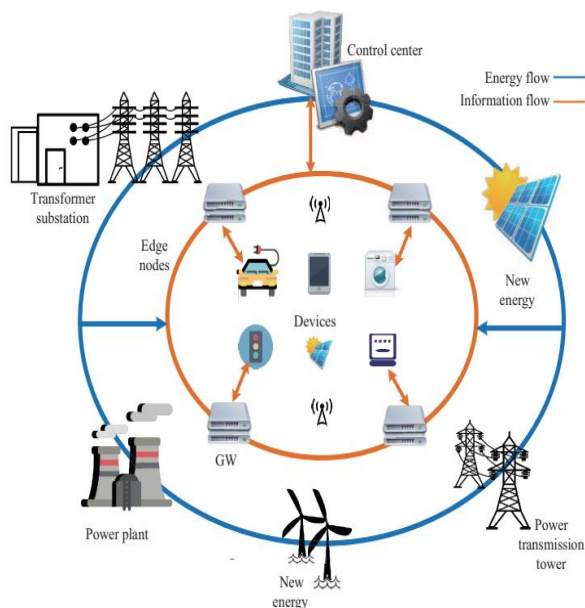
- داده‌هاى غيرعملياتى: اين داده‌ها به توان شبکه ارتباطى ندارند ولى به كيفيت و قابليت اطمينان توان اشاره دارند.

- داده‌هاى اندازه‌گيرى: داده‌هاى مرتبط با مصرف توان و ميزان تقاضا مانند زمان اوج مصرف هستند.


- داده‌هاى رويداد: اين داده‌ها از رويدادهاى مربوط به دستگاه‌هاى شبکه هوشمند برق مانند افت ولتاژ و نرخ تشخيص خطا به وجود مى‌آيند.

- متا داده^{۷۶}: داده‌هايى كه به‌منظور ساماندهى و تفسير ديگر داده‌ها به كار مى‌روند.


همه داده‌هاى فوق از منابع مختلفى مانند سنسورها، دستگاه‌هاى اندازه‌گيرى، پست‌هاى برق، ترمينال‌هاى داده همراه، دستگاه‌هاى كنترلى، منابع انرژى توزيع شده، تجهيزات برقى هوشمند، تجهيزات مشتركين و داده‌هاى تاريخى به‌دست مى‌آيند.



شکل (۶): معماری مفهومی شبکه‌های هوشمند برق [۳۶]
 Figure (6): Conceptual architecture of smart power grid [36]



شکل (۷): منابع داده‌ای شبکه‌های هوشمند برق [۳۸]
 Figure (7): Smart power grid data sources [38]



شکل (۸): چرخه حیات کلان داده در شبکه هوشمند برق
 Figure (8): Big data life cycle in smart power grid

تکنولوژی‌های اطلاعاتی و ارتباطی پیشرفته‌ای به منظور بهبود قابلیت اطمینان، پایداری، کارایی و عملکرد شبکه هوشمند برق به کار گرفته می‌شود. در این راستا زیرساخت ارتباطی یک شبکه هوشمند برق متشکل از سه نوع شبکه است: شبکه خانگی،

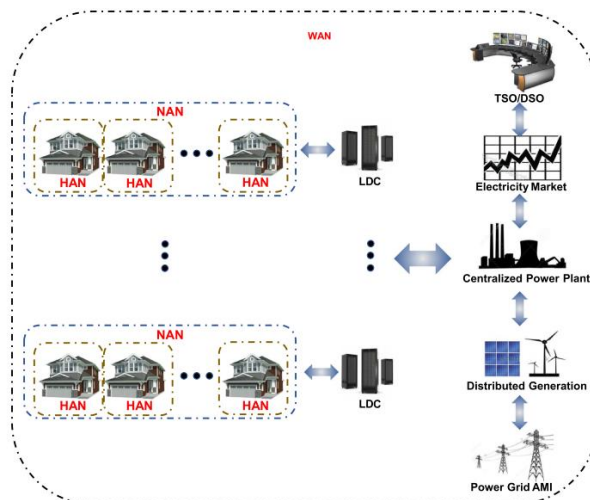
شبکه محلی و شبکه گسترده که در شکل (۹) نمایش داده شده است [۴۰]. بنابراین روش‌ها و تکنولوژی‌های متفاوتی به‌منظور اطمینان از یکپارچه‌سازی داده ارائه شده است که می‌توان به معماری سرویس‌گرا^{۷۷} (SOA)، گذرگاه سرویس سازمانی^{۷۸} (ESB)، زبان مدل‌سازی یکپارچه^{۷۹} (UML) و سیستم‌های تبادل پیام اشاره کرد [۴۴،۴۷].

ب- ذخیره کلان‌داده: با توجه به حجم بالای داده‌های جمع‌آوری شده از منابع ارسالی و تحویل آنها به ابزارهای تجزیه و تحلیل در یک ثانیه ذخیره این کلان‌داده‌ها در شبکه هوشمند برق از اهمیت بسزایی برخوردار است. بنابراین نیاز به یک مکانیزم توسعه یافته و مقیاس‌پذیر به‌منظور تحقق الزامات مربوط به کلان‌داده احساس می‌گردد. سیستم فایل توزیع شده^{۸۰} (DFS) و پایگاه داده‌های NoSQL از راه‌کارهای کلیدی در ذخیره کلان‌داده‌ها محسوب می‌گردند. سیستم فایل توزیع شده یک سیستم فایل است که به چندین کاربر اجازه می‌دهد فایل‌ها و منابع ذخیره‌ای مختلف را بر روی چندین ماشین به اشتراک بگذارند. مکانیزم ذخیره استفاده شده بر پایه مدل سرویس‌گیرنده-سرویس‌دهنده است که در آن هر کاربر می‌تواند یک نمونه محلی از اطلاعات ذخیره شده را دریافت کند. از راه‌کارهای مبتنی بر این سرویس می‌توان به گوگل‌جی‌اف‌اس^{۸۱} و HTFS اشاره کرد. پایگاه داده‌های NoSQL یک روش جدید به‌منظور غلبه بر محدودیت‌های پایگاه داده‌های رابطه‌ای مرسوم مبتنی بر SQL با در نظر گرفتن داده‌های حجیم است. این نوع پایگاه داده‌ها سه نوع معماری شامل راه‌کارهای کلید-مقدار (مانند Dynamo)، ستون محور^{۸۲} (مانند Hbase) و اسناد محور (مانند Mongo DB) ارائه می‌کند.

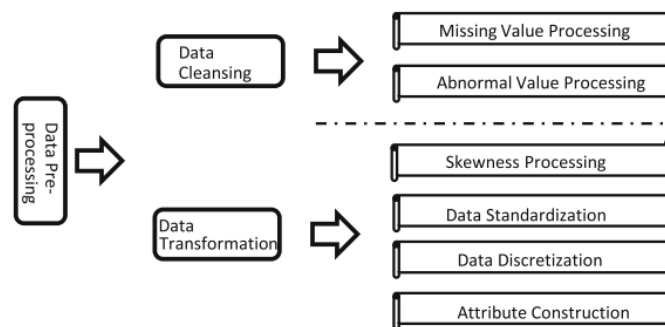
ج- پیش پردازش کلان‌داده: همان‌طور که در شکل (۱۰) نشان داده شده است، روش‌های پیش-پردازش نقش بسزایی در بهبود کیفیت داده دارند. در بسیاری از موارد مجموعه داده‌ها شامل داده‌های مفقود شده هستند که در نتایج تحلیل داده تاثیرگذار است. حذف یا درون‌یابی از متداول‌ترین روش‌ها در پاسخ به این نمونه مشکل‌ها است. در مواجهه با داده‌های غیرطبیعی چنانچه این داده بر اساس عملکرد سیستم قابل توجه است، به عنوان یک داده پرت نگهداری می‌شود در غیر این‌صورت همانند داده‌های مفقود شده با آن برخورد و تلاش می‌گردد با یک مقدار حقیقی جایگزین گردد. در رابطه با تفسیر این نوع داده‌ها روش‌های نوین مبتنی بر هوش مصنوعی مانند شبکه‌های حافظه بلند-کوتاه مدت (LSTM) و مجموعه پرسپترون چندلایه^{۸۳} ارائه گردیده است [۴۱،۴۲]. از آنجائی‌که برخی الگوریتم‌های تحلیل کلان‌داده نسبت به داده نامتعادل حساس هستند، لگاریتم می‌تواند به عنوان یک روش موثر به‌منظور اصلاح شکل توزیع داده‌ها با چولگی شدید باشد. همچنین ساخت ویژگی‌های جدید به‌طور معمول می‌تواند به بهبود دقت نتایج تحلیل داده‌ها کمک نماید.

د- تجزیه و تحلیل کلان‌داده: شبکه‌های هوشمند برق داده‌ها را از منابع مختلفی جمع‌آوری و آنها را در دیتاست‌هایی ذخیره می‌کنند که باید به راحتی برای تجزیه و تحلیل قابل استفاده باشند. تجزیه و تحلیل در هوشمندتر شدن، کارا تر شدن و سودآور شدن شبکه نقشی حیاتی ایفا می‌کند. انواع مختلف تجزیه و تحلیل را می‌توان به‌صورت زیر نام برد:

- تجزیه و تحلیل سیگنال، که بر پایه پردازش سیگنال است.



شکل (۹): زیرساخت ارتباطی شبکه هوشمند برق [۴۰]
Figure (9): Smart power grid connecting infrastructure [40]



شکل (۱۰): روش‌های پیش پردازش
Figure (10): Preprocessing methods

- تجزیه و تحلیل رویداد، که روی رویدادها تمرکز دارد.

- تجزیه و تحلیل وضعیت، که به داشتن دید کلی روی وضعیت شبکه کمک می‌کند.

- تجزیه و تحلیل عملیات مهندسی، که مسئول عملیات شبکه است.

- تجزیه و تحلیل مشتری، که داده‌های مربوط به مشتری را پردازش می‌کند.

در واقع برای انواع مختلف دسته‌بندی‌های گفته شده چندین مدل وجود دارد که می‌توان آنها را با هم ترکیب نمود که از جمله آنها می‌توان به مدل‌های توصیفی، تشخیصی، پیش‌گویی و تجویزی اشاره کرد. هر مدل یک سمت عملیاتی از شبکه را توصیف می‌کند. مدل‌های توصیفی به منظور تشریح رفتار مشتریان در برنامه‌های پاسخ به تقاضا و ارائه درک اولیه از عملکرد آنها به کار گرفته می‌شوند. پس از آن مدل‌های تشخیصی جهت فهمیدن رفتارهای خاص مشتریان و تجزیه و تحلیل تصمیمات آنها مورد استفاده قرار می‌گیرند. این دو مدل جهت ایجاد مدل پیش‌گویی که قادر باشد تصمیمات آتی مشتریان را پیش‌بینی کند، سودمند هستند. در پایان در بالاترین سطح فرایند تجزیه و تحلیل در شبکه هوشمند برق یک مدل تجویزی وجود دارد. این سطح مستقیماً بر روی بازاریابی، استراتژی‌ها و تصمیمات اثرگذار است [۴۳]. پردازش کلان‌داده به دو روش قابل انجام است: (۱) پردازش دسته‌ای، که در بازه‌های زمانی انجام می‌شود و مواقعی استفاده می‌شود که سرعت پاسخگویی اهمیت ندارد. (۲) پردازش جریانی، که در کاربردهای برخط که سرعت پاسخ مهم است مورد استفاده قرار می‌گیرد. مناسب‌ترین پلتفرم برای دسته اول آپاچی هِدوپ^{۸۴} و برای دسته دوم آپاچی استورم^{۸۵} است و همچنین آپاچی اسپارک^{۸۶} برای هر دو دسته می‌تواند استفاده گردد [۳].

- بصری سازی کلان‌داده: بصری‌سازی داده‌ها در شبکه‌های هوشمند نقش مهمی دارد زیرا به ارزیابی شبکه کمک بسزایی می‌کند. روش‌های گوناگونی برای این منظور وجود دارد که توانایی نمایش داده‌های چند متغییره و با ابعاد بالا را به صورت دو بعدی و سه بعدی دارند. اما شبکه‌های هوشمند با متغیرهای بیشماري مواجه هستند، مانند نقشه سه بعدی شبکه که نمایش داده‌ها را پیچیده می‌کند. به منظور غلبه بر مشکلات ناشی از ابعاد بالای داده‌ها می‌توان از روش‌هایی مانند نمودار پراکندگی، مختصات موازی و منحنی اندرو^{۸۷} استفاده کرد [۴۴].

۲-۳- رویکردهای موثر تحلیل کلان‌داده در شبکه‌های هوشمند

با توجه به حجم زیاد و تنوع داده در شبکه‌های هوشمند برق، جمع‌آوری و پردازش همه داده‌ها از نقطه نظر ذخیره‌سازی، پیچیدگی و هزینه آن‌ها به لحاظ فنی ناکارآمد است. برای این منظور راه‌کارهایی جهت تحلیل موثر و کارآمد کلان‌داده در شبکه هوشمند برق طراحی شده است:

- کاهش ابعاد: این روش یکی از روش‌های موثر به منظور تولید نسخه کاهش یافته و قابل ارائه از یک پایگاه داده بزرگ است. چالش کلیدی یافتن مقدار بهینه کاهش برای مجموعه داده به‌گونه‌ای است که بتواند اطلاعات مشابهی در مقایسه با مجموعه داده اولیه تولید کند [۴۵].

- پردازش لبه^{۸۸} و توزیع شده: سیستم‌های قدرت متداول از یک معماری متمرکز به منظور جمع‌آوری، تحلیل و پردازش داده استفاده می‌کنند. چنین چارچوبی نیازمند تبادل وسیعی از جریان داده در بین تجهیزات هوشمند مستقر در شبکه است. این

روش نه تنها از دیدگاه ارتباطی بلکه از منظر ذخیره‌سازی، امنیت و مدیریت داده ناکارآمد است. بنابراین شبکه‌های امروزی باید از پردازش توزیع شده و داده‌کاوی به‌منظور کاهش بار محاسباتی در پردازشگر مرکزی استفاده نمایند. اخیراً پردازش لبه به‌عنوان یک روش بهینه‌سازی محاسبات (با پردازش داده در لبه شبکه نزدیک به منبع داده) توجه زیادی را در حوزه کلان‌داده به خود جلب کرده است. پردازش لبه پهنای باند ارتباطی مورد نیاز بین منبع داده و سیستم پردازش مرکزی را احیا می‌کند، در حالی که پردازش توزیع شده بار مدیریت داده را با پردازش موازی داده کاهش می‌دهد [۵۳،۵۴].

- پردازش ابری: از آنجائی که پردازش ابری از منابع محاسباتی بر اساس تقاضا استفاده می‌کند، این نوع پردازش یک راه‌کار امید بخش برای محاسبات سنگین در شبکه است. پردازش ابری مزایای درخشانی مانند توسعه‌پذیری، انعطاف‌پذیری، پردازش موازی، پردازش توزیع شده، بازیابی سریع اطلاعات و مقیاس‌پذیری به همراه دارد. استقرار پردازش ابری در شبکه هوشمند برق مزایای فراوانی از جمله افزایش تاب‌آوری خطا و امنیت با توجه به پشتیبان‌گیری از داده‌ها در چندین مکان فراهم می‌کند. همچنین پردازش ابری این امکان را می‌دهد تا با صرفه جویی در هزینه، انرژی و منابع، انعطاف‌پذیری، چابکی و کارآمدی را محقق کند [۵۵،۵۶].

۴- سرویس‌های کلان‌داده در شبکه هوشمند برق


هدف اصلی پیاده‌سازی روش‌های هوش مصنوعی در سرویس‌های انرژی مبتنی بر کلان‌داده، تسریع و شبیه‌سازی سیستم قدرت فعلی در جهت تبدیل به شبکه هوشمند قابل اطمینان، مقرون‌بصرفه و سازگار با محیط است. از این خدمات طیف گسترده‌ای از ذینفعان حوزه انرژی مانند اپراتورهای سیستم‌های توزیع شده^{۸۹} (DSO) منتفع می‌گردند. از این‌رو هدف، ارتقاء عملکرد خدمات و تشویق به ساخت مدل‌های تجاری جدید در بخش انرژی به‌منظور بهره‌برداری از کلان‌داده است. از مهمترین این سرویس‌ها، همان‌طور که در شکل (۱۱) نمایش داده شده است، می‌توان به پیش‌گویی، تشخیص خطا و تعمیرات قابل پیش‌بینی اشاره کرد که در ادامه توضیح داده خواهد شد.

۴-۱- پیش‌گویی

سرویس پیش‌گویی، روش‌های مبتنی بر هوش مصنوعی را به‌منظور پیش‌بینی تولید، تقاضا و قیمت عرضه در بازار پیاده‌سازی می‌کند، به طوری که بتواند عدم قطعیت و مدیریت ریسک را در شبکه توزیع در نظر بگیرد. همچنین پیش‌بینی‌های مرتبط با انرژی، اطلاعات لازم برای برنامه‌های پاسخ‌گویی به تقاضا را فراهم می‌نماید. روش‌های پیش‌گویی به سه دسته تقسیم می‌گردند، اگرچه در بعضی از مرجع‌ها دسته‌بندی چهارمی به نام بسیار کوتاه مدت یا پیش‌گویی به‌هنگام اضافه شده است. روش‌های پیش‌بینی مورد بررسی در حوزه تولید، تقاضا و قیمت در جدول‌های (۱)، (۲) و (۳) آمده است.

- کوتاه مدت: در این روش بازه زمانی از یک ساعت تا یک هفته می‌تواند انتخاب گردد. روش‌های کوتاه مدت می‌توانند در سیستم‌های مدیریت انرژی به‌هنگام، سیستم مدیریت بهینه شبکه و بازار برق در حال نوسان مورد استفاده قرار گیرد [۵۷،۵۸].

- میان مدت: در این روش بازه زمانی از یک هفته تا یک سال می‌تواند انتخاب گردد. روش‌های میان مدت می‌توانند در ارزیابی اثرات زیست محیطی و زمان‌بندی نگهداری استفاده گردند [۵۹،۶۰].



شکل (۱۱): سرویس‌های کلان‌داده در شبکه هوشمند برق
Figure (11): Big data services in smart grid

Table (1): Investigated forecasting methods in demand area
جدول (۱): روش‌های پیش‌بینی مورد بررسی در حوزه تقاضا

مدل یادگیری	مرجع	مدل پیشنهادی	حوزه کاربردی	بازه پیش‌بینی	مزیت	معیار ارزیابی	مجموعه داده
۳	[۶۵]	SVM-HS	برق قدرت	کوتاه مدت	سرعت بالای آموزش و صحت پیش‌بینی	MAPE, RMSE, MAE	Guangdong Province Industrial Development
	[۶۶]	SVM- PSO	برق قدرت	کوتاه مدت	توانایی ذخیره حافظه	MAPE	Jibei area, China
	[۶۷]	ترکیب ARIMA و شبکه عصبی	برق قدرت	کوتاه مدت	افزایش دقت پیش‌بینی، قابلیت بالای انطباق مولفه‌های غیرخطی	MAPE, RMSE, MAE	Governmental data
۴	[۷۰،۷۱]	DNN پیش‌خور به همراه روش تعدیل بازگشتی نرخ یادگیری	ساختمان هوشمند	کوتاه مدت	کاهش خطای پیش‌بینی	RMSE	Smart meters data
	[۷۲]	ترکیب DNN با سری زمانی فازی	انرژی	کوتاه مدت	استراتژی پیشرفته پیش‌پردازش داده‌ها	MAPE	Electrical power load datasets collected from QLD
	[۷۳]	ترکیب DNN پیش‌خور با تابع چگالی احتمال	برق قدرت	کوتاه مدت	پیش‌بینی بار و چگالی احتمال	MAPE, MAE	Chine's cities
	[۷۴]	CNN و ترکیب با روش افزایش داده‌ها	شبکه خانگی	کوتاه مدت	پیش‌بینی بار یک واحد مسکونی	MAPE, RMSE	1181 residential households in Seoul, Korea
	[۷۵]	CNN و ترکیب با شبکه LSTM	برق قدرت	کوتاه مدت	پیش‌گویی تقاضای تجمیعی روز آینده	MAPE, MSE, MAE	London smart meter dataset
	[۷۶]	LSTM	شهر هوشمند	کوتاه مدت	افزایش دقت پیش‌بینی	RMSE, MAE	Energy Big Data is used in the US
	[۶۲]	LSTM مبتنی بر یادگیری گروهی	برق صنعتی	به‌هنگام	پیش‌بینی تقاضا در کارخانه‌های فولادسازی	MAPE, RMSE, MAE	The real-time power demand data from practical steel plant
	[۷۷،۷۸]	LSTM	شبکه هوشمند	به‌هنگام	پیش‌بینی تقاضای خانگی با در نظر گرفتن عدم قطعیت و ناپایداری داده‌ها	RMSE, MAE	Irish Commission for Energy Regulation and Smart Grid Smart City

- بلند مدت: در این روش بازه زمانی بیشتر از یک سال انتخاب می‌گردد. روش‌های بلند مدت در سرمایه‌گذاری، تصمیم‌گیری‌های بلند مدت و قیمت‌گذاری بازار آینده استفاده می‌گردد [۴۶].

- به‌هنگام: در این روش بازه زمانی حداکثر یک ساعت می‌تواند انتخاب گردد. روش‌های به‌هنگام می‌تواند به‌منظور حفظ تعادل شبکه استفاده شوند [۴۷].

۱-۱-۴- پیش‌گویی تقاضا

سرویس پیش‌گویی تقاضا نمایه مصرف یک یا چندین کاربر را پیش‌بینی می‌کند. به‌عنوان نمونه پیش‌گویی تقاضای تجمیعی روز آینده یک منطقه خاص برای اپراتورهای سیستم‌های توزیع شده به‌منظور پیش‌بینی ازدحام احتمالی شبکه امری ضروری است.

Table (2): Investigated forecasting methods in generation area

جدول (۲): روش‌هاى پيش‌بينى مورد بررسى در حوزه پيش‌بينى توليد

مجموعه داده	معیار ارزیابی	مزیت	بازه پيش‌بينى	حوزه کاربردى	مدل پيشنهادهى	مرجع	مدل يادگيرى
Electricity demand of northeast China	MAPE, MAE, MSE	کاهش خطاى پيش‌بينى با استفاده از نرم کردن داده‌ها	کوتاه مدت	برق خورشيدى و بادى	SVR, SVM	[۸۰]	ماشين
UQ-SDMS	MAPE	الگوريتم بهينه سازى ازدحام ذرات	کوتاه مدت	برق فتوولتائىک	DNN	[۸۹]	عميق
Gumi city in South Korea	MAE RMSE,	درک روابط پنهان بين اطلاعات هواشناسى و خروجى‌هاى برق فتوولتائىک حقيقى	کوتاه مدت	برق فتوولتائىک	DNN	[۹۰]	
MWWF	ACE, IS, CRPS	پيش‌بينى احتمالى برق بادى با استفاده از تبديل موجک	به‌هنگام	برق بادى	CNN	[۸۶]	
Wind farm in the northwest of China	MSE	ترکيب ماشين تقويت گراډيان با CNN	به‌هنگام	برق بادى	CNN	[۸۷]	
National Renewable Energy Laboratory (NREL)	MAPE, RMSE, MASE	پيش‌بينى فتوولتائىک چند سايتى	کوتاه مدت	برق فتوولتائىک	CNN	[۸۸]	
YULARA PV system in Alice Springs, Australia	MAPE, RMSE, R ²	استفاده از مجموعه داده‌هاى تاريخى چند متغيره کوتاه مدت	به‌هنگام	برق فتوولتائىک، خورشيدى و بادى	LSTM	[۸۱، ۸۲]	
Island of Santiago, Cape Verde - MIDC	RMSE	مدل پيش‌بينى به‌هنگام مبتنى بر LSTM	به‌هنگام	پيش‌بينى ساعتى تابش خورشيدى	LSTM	[۸۳]	
Shaoxing city, China	MAE, MAPE, RMSE	مکانيزم توجه به- منظور تمرکز بر روى مهمترين ويژگى‌هاى داده‌هاى ورودى	کوتاه مدت	برق فتوولتائىک	LSTM	[۸۴]	
Two wind farms in the northeast of China	MAE, MAPE, RMSE	ترکيب K-Means و LSTM	کوتاه مدت	برق بادى	LSTM	[۸۵]	

ظهور مصرف کننده-توليد کننده‌ها، مصرف کننده‌اى که انرژى را توليد و مصرف مى‌کند، در شبکه منجر به افزايش عدم قطعيت در نمايه تقاضا مى‌گردد به اين دليل که مصرف غير قابل پيش‌بينى و ناپايدار خواهد شد. روش‌هاى پيش‌بينى بار مبتنى بر هوش مصنوعى از مدل‌هاى رگرسيون تا الگوريتم‌هاى پيشرفته يادگيرى ماشين را در بر دارد، به‌طورى که در مسئله‌هاى بلند مدت از مدل‌هاى رگرسيون و در کوتاه مدت از الگوريتم‌هاى يادگيرى ماشين به‌عنوان راه‌کار مناسب استفاده مى‌گردد [۶۳، ۶۴]. ترکيب ماشين بردار پشتيبان با الگوريتم‌هاى جستجوى هارمونى سراسرى و فرا اکتشافى بهينه‌سازى ازدحام ذرات در مرجع‌هاى [۶۵] و [۶۶] به‌منظور پيش‌بينى تقاضا استفاده شده است.

Table (3): Investigated forecasting methods in price area
جدول (۳): روش‌های پیش‌بینی مورد بررسی در حوزه پیش‌بینی قیمت

مجموعه داده	معیار ارزیابی	مزیت	بازه پیش‌بینی	حوزه کاربردی	مدل پیشنهادی	مرجع	مدل یادگیری
Eléctrica de España (REE)	MAE, MAPE, RMSE	دقت خوب در پیش‌بینی شکل‌گیری قیمت	کوتاه مدت	بازار برق	GBM	[۹۳]	ماشین
Electricity data of Ontario, Canada	MAE, MAPE, RMSE	حذف نویز داده‌های تولید شده	کوتاه مدت	بازار برق	DNN ترکیب با رمزنگار خودکار	[۵۷]	۳
Turkish Day-ahead Market electricity prices	MAE	بهبود عملکرد در مقایسه با ساختارهای شبکه عصبی ساده و روش‌های آماری	کوتاه مدت / میان مدت	بازار برق	استفاده از یک شبکه GRU چند لایه	[۹۴]	
The Electric Power Markets (PJM)	MAE RMSE,	بهبود دقت پیش‌بینی در مقایسه با مدل‌های یادگیری ماشین	به‌هنگام	بازار برق	ترکیب CNN با شبکه LSTM	[۹۲]	
EPEX-Belgium, EPEX-France	MAPE	بهبود صحت پیش‌بینی بر اساس چارچوب ارائه شده	کوتاه مدت	بازار برق	CNN, DNN, GRU, LSTM	[۹۵]	
PJM electricity data	RMSE	عملکرد خوب برای نوسان بالای قیمت	کوتاه مدت	بازار برق	DNN	[۹۶]	
Microgrids, smart buildings, smart meters, electric vehicles, factories	MAE RMSE,	بهبود پیش‌بینی و مکانیزم آموزش مدل با استفاده از الگوریتم بهینه سازی Jaya	میان مدت	شبکه هوشمند	LSTM	[۹۷]	

همچنین ترکیب مدل میانگین متحرک یکپارچه خودگردان (ARIMA) با شبکه‌های عصبی (ANN) باعث افزایش دقت پیش‌بینی‌ها می‌گردد [۴۸]. روش‌های خوشه‌بندی بدون نظارت برای کاربردهای مختلفی در ارتباط با پیش‌بینی تقاضا پیاده‌سازی می‌گردند. از جمله این کاربردها می‌توان به طبقه‌بندی ساختمان‌ها بر اساس بهره‌وری انرژی آن‌ها، دسته‌بندی مشترکین، تعیین الگوهای مصرف لوازم برقی، تعیین پروفایل‌های اوج مصرف و تشخیص دزدی برق اشاره کرد [۶۸، ۶۹]. در سال‌های اخیر، استفاده از الگوریتم‌های یادگیری عمیق به‌عنوان نسل بعدی روش‌های پیش‌بینی تقاضا به‌طور گسترده‌ای صورت پذیرفته است. نقطه قوت این نسل جدید در مقایسه با روش‌های قبل کاهش خطای پیش‌بینی است. از شبکه‌های عصبی عمیق پیش‌خور به‌منظور پیش‌بینی تقاضا در کوتاه مدت استفاده شده است که در آن‌ها از روش تعدیل بازگشتی^{۹۰} نرخ یادگیری^{۹۱} بهره گرفته شده است [۷۰، ۷۱]. در مرجع [۴۹] از ترکیب شبکه عصبی عمیق با سری زمانی فازی به‌منظور پیش‌بینی تقاضا استفاده شده است. این روش از معیار میانگین مربعات خطا^{۹۲} (MSE) در راستای ارزیابی روش پیشنهادی بهره گرفته است. همچنین در مرجع [۵۰] از ترکیب شبکه عصبی عمیق پیش‌خور با تابع چگالی احتمال جهت پیش‌بینی تقاضا استفاده شده است. شبکه‌های کانولوشنی نیز در پیش‌بینی کوتاه مدت به‌کار گرفته شده‌اند. به‌عنوان نمونه در مرجع [۵۱] شبکه‌های کانولوشنی ترکیب شده با روش افزایش داده‌ها^{۹۳} را به‌منظور پیش‌بینی بار کوتاه مدت یک خانوار به خدمت گرفته‌اند. در این روش، افزایش داده‌ها در راستای ازدیاد داده‌های آموزشی به‌کار گرفته شده است. ترکیب شبکه‌های کانولوشنی و شبکه‌های حافظه بلند-کوتاه مدت به‌منظور پیش‌گویی تقاضای تجمیعی روز آینده استفاده می‌گردد. در این روش ترکیب فوق به همراه ادغام شبکه‌های عصبی عمیق با ساختارها و

پارامترهای مختلف به خدمت گرفته شده است [۵۲]. شبکه‌های حافظه بلند-کوتاه مدت در بسیاری از مدل‌های پیش‌گویی تقاضا استفاده گردیده‌اند. در مرجع [۵۳] از این شبکه‌ها در جهت پیش‌بینی قیمت و تقاضا استفاده شده است. روش پیشنهادی در مقایسه با روش‌های متعارف دقت پیش‌بینی را بهبود می‌بخشد. همچنین مدل پیش‌بینی تقاضا در مرجع [۴۷] از شبکه حافظه بلند-کوتاه مدت مبتنی بر یادگیری گروهی^{۹۴} استفاده می‌کند. علاوه بر این، یک مدل پیش‌بینی به‌هنگام مبتنی بر مدل پیش‌بینی احتمالی مبتنی بر شبکه‌های حافظه بلند-کوتاه مدت با در نظر گرفتن عدم قطعیت و ناپایداری داده‌ها در مرجع [۵۴] ارائه شده است. به‌طور مشابه مدل پیش‌بینی کوتاه مدت بر پایه شبکه‌های حافظه بلند-کوتاه مدت به‌منظور مواجهه با داده‌های غیر قطعی و ناپایدار پیشنهاد گردیده است [۵۵].

۲-۱-۴- پیش‌گویی تولید

هدف از سرویس پیش‌گویی تولید، پیش‌بینی تولید برق از منابع تجدیدپذیر در شبکه توزیع است. افزایش مداوم منابع انرژی تجدیدپذیر در سیستم‌های قدرت نیاز به پیش‌بینی دقیق‌تر سیستم‌های انرژی تجدیدپذیر را دوچندان کرده است. در این خصوص، روش‌های متعدد مبتنی بر هوش مصنوعی به‌کار گرفته شده است. نتایج تحقیق ارائه شده در مرجع [۵۶] نشان می‌دهد مدل‌های یادگیری ماشین گروهی در مواجهه با حجم عظیمی از داده‌ها به سطح دقت بیشتری دست پیدا می‌کنند. چندین الگوریتم یادگیری ماشین مانند شبکه‌های عصبی، ماشین‌های بردار پشتیبان و رگرسیون فرایندی گاوسی به‌منظور پیش‌بینی تولید برق خورشیدی و بادی در مرجع [۵۷] مورد بررسی قرار گرفته‌اند. در همین راستا الگوریتم‌های یادگیری عمیق مانند شبکه‌های کانولوشنی، شبکه‌های عمیق، شبکه‌های حافظه بلند-کوتاه مدت و ترکیب آنها با الگوریتم‌های یادگیری ماشین مانند ماشین بردار پشتیبان و K-Means، جهت پیش‌بینی تولید به‌کار گرفته شده‌اند. شبکه‌های حافظه بلند-کوتاه مدت در زمینه‌های مختلف پیش‌بینی تولید مانند برق فتوولتائیک^{۹۵}، خورشیدی و بادی کاربرد دارند [۸۱، ۸۲]. پیش‌بینی ساعتی تابش خورشیدی روز آینده با استفاده از داده‌های هواشناسی و براساس مدل پیش‌بینی به‌هنگام مبتنی بر شبکه‌های حافظه بلند-کوتاه مدت انجام می‌پذیرد [۵۸]. یک مدل پیش‌بینی کوتاه مدت با استفاده از شبکه‌های حافظه بلند-کوتاه مدت در مرجع [۵۹] پیشنهاد شده که در آن از مکانیزم توجه به‌منظور تمرکز بر روی مهم‌ترین ویژگی‌های داده‌های ورودی بهره گرفته شده است. نویسندگان در مرجع [۶۰] از ترکیب الگوریتم K-Means با شبکه‌های حافظه بلند-کوتاه مدت به‌منظور ارائه یک مدل پیش‌بینی کوتاه مدت بهره برده‌اند که در آن الگوریتم K-Means خوشه‌هایی از معیارهای کلیدی برق بادی را شکل می‌دهد که در تولید مدل پیش‌بینی تاثیرگذار است. شبکه کانولوشنی با استفاده از تبدیل موجک در مدل پیش‌بینی به‌هنگام احتمالی برق بادی در مرجع [۶۱] مورد استفاده قرار گرفته است. نویسندگان در مرجع [۶۲] ترکیب ماشین تقویت گرادیان^{۹۶} (GBM) با شبکه کانولوشنی به‌منظور مدل پیش‌بینی به‌هنگام برق بادی را پیشنهاد داده‌اند. در روش پیشنهادی به‌کارگیری ماشین تقویت گرادیان باعث تقویت عملکرد شبکه کانولوشنی گردیده و از معیار میانگین مربعات خطا جهت ارزیابی مدل استفاده شده است. همچنین استفاده از شبکه‌های کانولوشنی در پیش‌بینی فتوولتائیک چند سائیتی در مرجع [۶۳] اشاره شده است. شبکه عصبی عمیق پیش‌خور به همراه الگوریتم بهینه‌سازی ازدحام ذرات در مرجع [۶۴] به‌منظور استفاده در مدل پیش‌بینی کوتاه مدت پیشنهاد شده است. پنج ساختار متفاوت شبکه با پیچیدگی‌های متنوع به‌منظور دست‌یابی به نتایج پیش‌بینی دقیق مورد استفاده قرار گرفته‌اند. در مرجع [۶۵] سه روش پیش‌بینی تولید برق فتوولتائیک شامل مدل‌های مبتنی بر شبکه عصبی، شبکه عصبی عمیق و شبکه‌های حافظه بلند-کوتاه مدت ارائه شده است که قادر است رابطه‌های پنهان بین اطلاعات هواشناسی و خروجی‌های برق فتوولتائیک حقیقی را درک کند. مدل پیشنهادی شبکه‌های حافظه بلند-کوتاه مدت به گونه‌ای طراحی شده است که قادر به برداشت الگوهای ساعتی در یک روز و الگوهای فصلی در طول روزها است.

۳-۱-۴- پیش‌گویی قیمت

هدف از این سرویس پیش‌بینی قیمت برق است که نقش بسزایی در کاهش صورت حساب‌های خرید انرژی برای شرکت‌های فروشنده در افق کوتاه مدت دارد. باید در نظر داشت هنگامی که سری‌های زمانی قیمت برق نوسان زیادی را نشان می‌دهد یا با

افزایش شدید قیمت و رفتار غیرخطی و آشفته همراه است، مدل‌های شبکه عصبی ساده عملکرد مناسبی نخواهند داشت [۶۶]. بنابراین نیاز به روش‌های پیچیده‌تر به‌منظور پیش‌بینی‌های پیچیده‌تر احساس می‌گردد. از این‌رو مدل‌های یادگیری عمیق به‌طور گسترده‌ای در تخمین قیمت برق به همراه دیگر مدل‌های یادگیری ماشین مانند درخت تصمیم و رگرسیون ماشین بردار پشتیبان مورد استفاده قرار گرفته‌اند [۹۲،۹۳]. شبکه‌های عصبی بازگشتی در حل مسائل یادگیری وابسته به زمان کارایی دارند و به‌طور خاص شبکه‌های حافظه بلند-کوتاه مدت و واحدهای بازگشتی مجتمع شده^{۹۷} (GRU) عملکرد فوق‌العاده‌ای در تخمین سری-های زمانی قیمت دارند [۶۷]. به‌منظور پیش‌گویی قیمت برق در مرجع [۶۸] ترکیب دو شبکه عمیق حافظه بلند-کوتاه مدت و شبکه عصبی کانولوشنی پیشنهاد و برای ارزیابی الگوریتم از معیارهای میانگین مطلق خطا و مجذور مربعات خطا استفاده شده است. نویسندگان در مرجع [۶۹] یک چارچوب مدل‌سازی جدیدی به‌منظور پیش‌بینی قیمت برق ارائه داده‌اند. این چارچوب شامل شبکه عصبی عمیق، شبکه‌های حافظه بلند-کوتاه مدت، واحدهای بازگشتی مجتمع شده و شبکه عصبی کانولوشنی است. یک مدل جدید بر اساس شبکه عصبی انتخاب پویا^{۹۸} (DCANN) به‌منظور پیش‌بینی قیمت برق روز آینده در مرجع [۷۰] ارائه شده است. مدل پیشنهادی از ترکیب یادگیری با نظارت و بدون نظارت استفاده کرده و ایده حذف نمونه‌های بعد و جستجوی ورودی با کیفیت را به‌کار گرفته است. در مرجع [۷۱] از شبکه عمیق حافظه بلند-کوتاه مدت در جهت پیش‌بینی قیمت برق بهره گرفته شده است. هاپیر پارامترهای این شبکه به وسیله الگوریتم بهینه‌سازی جایا تنظیم می‌گردند تا توانایی پیش‌بینی و مکانیزم آموزش مدل را بهبود دهند. یک شبکه واحدهای بازگشتی مجتمع شده چند لایه به عنوان یک مدل جدید پیش‌بینی قیمت برق در مرجع [۶۷] ارائه شده است. نتایج به‌دست آمده از شبکه پیشنهادی نشان دهنده بهبود عملکرد آن در مقایسه با ساختارهای شبکه عصبی ساده و روش‌های آماری است. نویسندگان در این روش از شبکه عصبی عمیق به‌منظور پیش‌بینی برق روز آینده استفاده کرده‌اند. در مرجع [۷۲] این روش از ترکیب شبکه عصبی عمیق با رمزنگار خودکار حذف نویز پشته‌ای^{۹۹} به‌منظور حذف نویز داده‌های تولید شده توسط منابع مختلف بهره گرفته شده است.

۲-۴- تعمیرات قابل پیش‌بینی

هدف از سرویس تعمیرات قابل پیش‌بینی، استفاده از اطلاعات بالقوه با ارزش جمع‌آوری شده از سنسورهای قرار گرفته در تجهیزات شبکه هوشمند برق به‌منظور تسهیل در تصمیم‌گیری‌های مرتبط با تعمیرات زمان‌بندی شده است. علاوه بر این، تعمیرات زمان‌بندی شده با استفاده از مدل‌های تعمیرات قابل پیش‌بینی به مراتب مقرون به‌صرفه‌تر نسبت به انجام تعمیرات بعد از وقوع خرابی‌ها است [۷۳]. این مدل‌ها در حوزه‌های مختلف شبکه توزیع استفاده گردیده است. تعمیرات قابل پیش‌بینی مربوط به ترانسفورماتورهای قدرت در مرجع [۷۴] مورد بررسی قرار گرفته است. در سال‌های اخیر الگوریتم‌های یادگیری ماشین به‌منظور تعمیرات قابل پیش‌بینی در ترانسفورماتورهای قدرت و پنل‌های فتوولتائیک به‌کار گرفته شده است [۷۵]. الگوریتم جنگل تصادفی^{۱۰۰} و آدابوست^{۱۰۱} به‌عنوان نمونه‌هایی از روش‌های یادگیری ماشین در تعمیرات قابل پیش‌بینی ترانسفورماتورهای قدرت به‌کار گرفته شده‌اند [۷۶]. عیب روش‌های داده‌محور تعمیرات قابل پیش‌بینی، تکیه بر داده‌های با کیفیت بالا است که به‌منظور ارزیابی استفاده می‌گردد. در حالی که در سناریوهای شبکه توزیع واقعی وجود اینگونه داده‌ها غیرمحمتمل است. در مرجع [۷۷] از شبکه‌های کانولوشنی به‌منظور نظارت بر عملیات پنل‌های فتوولتائیک استفاده می‌گردد. بر این اساس منحنی توان الکتریکی روزانه یک پنل فتوولتائیک با توجه به منحنی‌های توان پنل‌های مجاور پیش‌بینی می‌گردد. یک انحراف بزرگ بین منحنی توان مشاهده و پیش‌بینی شده می‌تواند نشان دهنده پنلی با عملکرد نادرست باشد. بر اساس یک تحقیق انجام شده در دانمارک، یک روش به‌هنگام جدید پیش‌بینی خطا در خطوط انتقال برق زیر زمینی ۱۰ کیلوولت که با روغن عایق شده‌اند با استفاده از داده‌های با دقت پایین تولید شده از پست توزیع ارائه شده است. روش پیشنهادی بر مبنای طبقه‌بندی توالی با استفاده از شبکه عمیق حافظه بلند-کوتاه مدت بنا شده است که در آن سه سطح عملیاتی متفاوت شامل نرمال، هشدار اولیه و هشدار بحرانی تعریف شده‌اند. این روش اجازه می‌دهد پیش‌بینی انعطاف‌پذیر شده و تشخیص خطاهای سیستماتیک بهبود یابد [۷۸]. روش‌های مورد بررسی در حوزه تعمیرات قابل پیش‌بینی در جدول (۴) آورده شده است.

۳-۴- تشخیص خطا

تشخیص و شناسایی جریان‌های غیر طبیعی برق هدف سرویس تشخیص خطا است. روش‌های تشخیص خطا به دو دسته تقسیم می‌گردند. دسته اول شامل روش‌های مدل‌محور است که داده‌های حقیقی تولید شده توسط سنسورها با داده‌های مدل پیش‌بینی مقایسه شده و اختلاف‌های زیاد می‌تواند نشان دهنده خطا باشد. در دسته دوم، روش‌های داده‌محور به دنبال تشخیص الگو از داده‌های جمع‌آوری شده از سنسورهای قرار گرفته در نقاط مختلف شبکه هستند که نشان دهنده خطا هستند [۷۹]. از عوامل اصلی وقوع خطا می‌توان به تجهیزات آسیب دیده رخدادهای زیست محیطی، سقوط درختان، تماس مستقیم حیوانات و وقوع پدیده‌های طبیعی مانند طوفان و کولاک اشاره کرد. الگوریتم‌های هوش مصنوعی می‌توانند به پیش‌بینی قطعی در صورت وقوع حوادث فوق‌کمک نمایند [۱۰۵، ۱۰۶]. الگوریتم‌های یادگیری ماشین متعددی به منظور تشخیص خطا در شبکه‌های هوشمند مورد استفاده قرار گرفته‌اند. نویسندگان در مرجع [۸۰] از الگوریتم درخت تصمیم برای تشخیص عیب در خطوط برق بر مبنای داده‌های خطای پیشین استفاده کرده‌اند. در همین راستا مدل طبقه‌بند جنگل تصادفی، ماشین بردار پشتیبان و k نزدیکترین همسایه (KNN) در جهت تشخیص خطاهای ریز شبکه^{۱۰۲} پیشنهاد شده‌اند [۸۱]. همچنین روش‌های خوشه‌بندی مانند خوشه-بندی فضایی مبتنی بر چگالی برنامه‌های کاربردی با نویز^{۱۰۳} (DBSCAN) برای این منظور استفاده شده است [۸۲]. طبقه‌بند درخت تصمیم گروهی در مرجع [۸۳] برای تشخیص رخدادهای پویا در سیستم برق ارائه شده است. با ظهور یادگیری عمیق، از الگوریتم‌های آن به‌طور گسترده‌ای به منظور تشخیص خطا استفاده گردیده است. از جمله این الگوریتم‌ها می‌توان به شبکه‌های کانولوشنی، رمزنگار خودکار، ماشین بولتزمن و شبکه‌های عصبی بازگشتی اشاره کرد. نویسندگان در مرجع [۸۴] استفاده از شبکه کانولوشنی به منظور تشخیص به‌هنگام خطوط آسیب دیده را پیشنهاد دادند. دقت سیستم تشخیص پیشنهادی به‌طور قابل ملاحظه‌ای بالاتر از دیگر الگوریتم‌های یادگیری ماشین است. یک راه‌کار تشخیص هوشمند خطا کابل با استفاده از شبکه عصبی عمیق به منظور تعیین صحت کابل‌های انتقال و پیش‌بینی و جلوگیری از خطاهای نهایی در مرجع [۸۵] ارائه شده است. روش پیشنهادی یک فرایند عیب‌یابی و تشخیص خطا را به صورت خودکار فراهم می‌نماید به‌طوری‌که نیاز به استخراج ویژگی به صورت دستی در زمان عملیات لازم نمی‌باشد. نویسندگان در مرجع [۸۶] یک فرایند جدید به منظور تشخیص و عیب‌یابی در جریان مستقیم سیستم فتوولتائیک بر مبنای طبقه‌بند شبکه عصبی احتمالی معرفی کردند. این فرایند شامل چهار مرحله اصلی به این قرار است: (۱) استخراج پارامترهای ماژول فتوولتائیک، (۲) شبیه‌سازی و اعتبار‌سنجی آرایه فتوولتائیک، (۳) ایجاد یک پایگاه داده مرتبط با عملیات سالم و دارای خطا و (۴) ساخت، آموزش و آزمایش شبکه. نتایج به‌دست آمده نشان دهنده کارایی بالای روش پیشنهادی در تشخیص و عیب‌یابی ناهنجاری‌ها در جریان مستقیم با در نظر گرفتن مجموعه داده‌های بدون نویز و دارای نویز می‌باشد. روش‌های مورد بررسی در حوزه تشخیص خطا در جدول (۴) آورده شده است.

۵- بحث

در این بخش، ابتدا روش‌های به‌کار گرفته شده در سرویس‌های شبکه هوشمند برق به تفکیک بررسی و در ادامه چالش‌ها و فرصت‌های پیش‌رو آورده شده است.

۱-۵- روش‌ها در سرویس‌های شبکه هوشمند برق

نتایج مطالعه انجام شده روی روش‌های هوش مصنوعی در حوزه سرویس‌های مرتبط با کلان‌داده در شبکه‌های هوشمند در شکل (۱۲) نمایش داده شده است. در سرویس‌های پیش‌بینی بار روش‌های مبتنی بر یادگیری ماشین و شبکه‌های حافظه بلند-کوتاه مدت بیشترین کاربرد را دارند. همچنین روش‌های مبتنی بر شبکه عصبی عمیق و شبکه‌های عصبی کانولوشنی به ترتیب مورد استفاده بوده‌اند. نتایج در مورد سرویس‌های پیش‌گویی تولید نشان دهنده آن است که شبکه‌های حافظه بلند-کوتاه مدت بالاترین کاربرد در این سرویس را به خود اختصاص داده‌اند. بررسی‌ها در این خصوص بیانگر آن است که روش‌های یادگیری ماشین و شبکه عصبی کانولوشنی پس از شبکه‌های حافظه بلند-کوتاه مدت به یک میزان مورد استفاده قرار گرفته‌اند. همچنین شبکه‌های عصبی عمیق در این سرویس به میزان کمتری نسبت به رویکردهای قبلی مورد استفاده بوده‌اند.

Table (4): Predictive maintenance and fault detection methods

جدول (۴): روش‌های تعمیرات قابل پیش‌بینی و تشخیص خطا

حوزه	مدل یادگیری	مرجع	مدل پیشنهادی	تجهیزات	مجموعه داده
تعمیرات قابل پیش‌بینی	ماشین	[۹۹]	SVM	ترانسفورماتور برق	زیرساخت و داده‌های مشتری
		[۱۰۱]	RF, Adaboost	ترانسفورماتور برق	مشخصات ترانسفورماتورها، بارگذاری، مکان و داده‌های هواشناسی
	عمیق	[۱۰۲]	CNN	پنل‌های فتوولتائیک	سیگنال‌های الکتریکی برق
		[۱۰۳]	LSTM	کابل‌های برق زیرزمینی	ولتاژ، توان فعال و جریان
تشخیص خطا	ماشین	[۱۰۸]	PCA, RF, KNN, SVM	ریزشبکه	سیگنال‌های جریان و ولتاژ در هر نقطه انتهایی خط
		[۱۱۰]	Ensemble DT	ریزشبکه	داده‌های مولد توزیع شده
	عمیق	[۱۱۱]	CNN	برق قدرت	ولتاژ گذرگاه
		[۱۱۲]	DNN	کابل‌های برق زیرزمینی	مبدل خطوط انتقال
		[۱۱۳]	DNN	فتوولتائیک	پارامترهای ماژول فتوولتائیک

شبکه‌های حافظه بلند-کوتاه مدت در سرویس‌های مرتبط با پیش‌گویی قیمت بیشترین سهم را به خود اختصاص داده‌اند و روش‌های مبتنی بر یادگیری ماشین و شبکه عصبی عمیق بعد از آن به یک میزان موثر بوده‌اند. همچنین از شبکه‌های عصبی کانولوشنی نیز در برخی مطالعات استفاده شده است.

براساس بررسی نویسندگان در این مقاله، شبکه‌های حافظه بلند-کوتاه مدت در سرویس‌های مرتبط با پیش‌گویی در ۳۷ درصد موارد استفاده گردیده‌اند. این میزان کاربرد بیان‌گر آن است که این دسته در مقایسه با سایر روش‌ها بیشترین سهم را در پیش‌بینی‌های مرتبط با شبکه‌های هوشمند داشته‌اند. همچنین خانواده روش‌های یادگیری ماشین و شبکه عصبی عمیق به ترتیب ۲۶ و ۲۱ درصد برای پیش‌گویی‌ها موثر بوده‌اند. شبکه‌های کانولوشنی نیز در ۱۶ درصد موارد استفاده شده‌اند که در این زمینه کمترین میزان استفاده را نشان می‌دهد. نتایج فوق در شکل (۱۳) نمایش داده شده است. نتایج به‌دست آمده از این مطالعه بیان‌گر آن است که در سرویس تعمیرات قابل پیش‌بینی، روش‌های یادگیری ماشین در حل مسائل این گروه بسیار خوب عمل کرده‌اند. این بررسی نشان می‌دهد این روش‌ها در ۶۰ درصد کاربردها به کار گرفته شده‌اند. همچنین در ۴۰ درصد دیگر، روش‌های مبتنی بر شبکه‌های حافظه بلند-کوتاه مدت و شبکه عصبی عمیق با نسبت مساوی در تعمیرات قابل پیش‌بینی توانسته‌اند در شبکه هوشمند برق مورد استفاده قرار گیرند. در شکل (۱۴) نتایج مربوط به این گروه نمایش داده شده است.

روش‌های مبتنی بر یادگیری ماشین علاوه بر سرویس تعمیرات قابل پیش‌بینی در سرویس تشخیص خطا نیز توانسته‌اند بیشترین میزان تاثیرگذاری را داشته باشند. بر اساس شکل (۱۵) مشاهده می‌شود که روش‌های مبتنی بر یادگیری ماشین در ۶۲ درصد موارد جهت تشخیص خطا به کار گرفته شده‌اند. همچنین شبکه‌های یادگیری عمیق و شبکه‌های کانولوشنی به ترتیب با ۲۵ و ۱۳ درصد جهت تشخیص خطا استفاده شده‌اند.


۲-۵- چالش‌ها و فرصت‌های پیش‌رو

مؤسسات فعال در حوزه انرژی تمایل فزاینده‌ای به استفاده از توانمندی‌های هوش مصنوعی و علم داده در جهت حل چالش‌های روزمره خود دارند. با این حال این روش‌ها همچنان در مراحل اولیه توسعه خود هستند و بیشتر برنامه‌های کلان‌داده محور به شکوفایی مورد انتظار خود نرسیده‌اند. این مطلب فرصت‌های جدید در این حوزه تحقیقاتی نوظهور و امید بخش فراهم می‌آورد. یکی از محرک‌های اولیه این تمایل فزاینده، در دسترس بودن حجم قابل توجه از داده‌های تولید شده توسط ابزارهای اندازه‌گیری هوشمند و دیجیتالی شدن شبکه است. چنانچه این اطلاعات با دیگر سیستم‌های مرتبط با دیجیتالی شدن شبکه و یا دیگر منابع داده‌ای خارجی ترکیب گردد، درک بیشتری از چگونگی عملکرد سیستم ارائه می‌دهد. اگرچه این فرصت‌ها مشوقی برای توسعه راه‌کارهای کلان‌داده محور است، چالش‌های موجود در آن نیز باید به درستی مورد بررسی قرار گیرند تا توسعه شبکه هوشمند برق به ظرفیت‌های کامل بالقوه خود دست یابد. بر اساس تحقیقات صورت گرفته چالش‌های کلان‌داده در صنعت برق در شش موضوع متمرکز شده‌اند [۱،۴۵] که عبارتند از:


الف- زیرساخت فناوری اطلاعات: برنامه‌های کاربردی با وجود سنسورهای جدید، روش‌های ذخیره و انتقال بهبود داده شده و توانمندی‌های تبادل و پردازش داده ملزم به تقویت زیرساخت فناوری اطلاعات در مواجهه با کلان‌داده هستند. با در نظر گرفتن زیر ساخت موجود، نسل فعلی ابزارهای اندازه‌گیری هوشمند با کمبود داده‌های به‌هنگام روبرو هستند که در نسل جدید آنها این موضوع باید مورد توجه قرار گرفته تا بتواند در برنامه‌ریزی‌های بلند مدت مورد استفاده قرار گیرند.

ب- جمع‌آوری و حاکمیت داده: وجود و دسترسی به داده‌های با کیفیت یکی از چالش‌های کلیدی روش‌های مبتنی بر هوش مصنوعی در حوزه انرژی است. باید در نظر داشت که داده‌های جمع‌آوری شده همیشه از کیفیت خوب و مناسبی برخوردار نیستند تا بتوانند در توسعه سیستم‌هایی با قابلیت مواجهه با سناریوهای پیچیده استفاده گردند. این مشکلات می‌توانند با استفاده از استراتژی‌های صحیح مدیریت و حاکمیت داده برطرف گردند.


ج- یکپارچه سازی و به اشتراک گذاری داده: قابلیت تبادل و استفاده از اطلاعات حاصل شده از داده‌ها در راه‌کارهای داده‌محور امری ضروری به‌نظر می‌رسد. با این وجود مؤسسات به‌منظور اجتناب از ریسک‌های امنیتی و حفظ مزیت‌های رقابتی خود از به اشتراک گذاری داده‌ها اجتناب می‌کنند.



شکل (۱۲): رویکرد های یادگیری ماشین و یادگیری عمیق در شبکه هوشمند برق
Figure (12): Machine Learning and Deep Learning approaches in smart power grid




شکل (۱۳): رویکردهای پیش‌بینی در شبکه هوشمند برق
Figure (13): Forecasting Approaches in smart power grid



شکل (۱۴): رویکردهای تعمیرات قابل پیش‌بینی در شبکه هوشمند برق

Figure (14): Predictive maintenance approaches in smart power grid



شکل (۱۵): رویکردهای تشخیص خطا در شبکه هوشمند برق

Figure (15): Fault detection approaches in smart power grid

د- پردازش و تحلیل داده: روش‌های جدید تحلیل داده در داده‌کاوی، یادگیری ماشین و مدیریت و بصری‌سازی داده در حوزه انرژی مورد استفاده قرار گرفته‌اند. این نوآوری‌ها در روش‌های تحلیل داده فرصت‌های جدید به‌منظور ارائه راه‌کارها و ایجاد مدل‌های تجاری جدید در این حوزه به‌وجود آورده است. از این‌رو ضروری است مدل‌های جدید داده‌محوری ایجاد گردد تا از نوآوری‌های به‌وجود آمده نهایت استفاده را ببرند.

ه- امنیت و حریم شخصی داده: دیجیتال‌سازی سیستم‌های برق رشد فزاینده حوادث سایبری در این حوزه را به‌همراه داشته که باعث شده است به‌عنوان یکی از محورهای مهم امنیت سایبری در نظر گرفته شود. از طرفی امنیت و حریم شخصی داده‌ها باید تضمین گردد تا از مشتریان حفاظت شده و ریسک‌های زنجیره تامین به حداقل برسد.

و- تخصص و مهارت: در هوشمندسازی شبکه برق و بهره‌گیری از سرویس‌های کلان‌داده، نیاز به متخصصین تحصیل کرده و آموزش دیده که توانایی استفاده از کلان‌داده را داشته باشند امری مهم و حیاتی در نظر گرفته می‌شود. از این‌رو سرمایه‌گذاری در آموزش و مهارت‌ورزی متخصصین مرتبط با این حوزه می‌تواند به مدیریت بهتر سیستم‌های دیجیتالی شده در شبکه کمک شایانی نماید.

۶- نتیجه‌گیری

با افزایش پیچیدگی زمانی و حافظه‌ای سیستم‌های برق، پیاده‌سازی راه‌کارهای مبتنی بر کلان‌داده و هوش مصنوعی منتج به روش امیدوار کننده‌ای برای استخراج دانش و ارزش افزوده از حجم بالای داده‌های ذخیره شده توسط تجهیزات هوشمند استقرار یافته در شبکه توزیع برق شده است. این داده‌ها که می‌توانند حاوی اطلاعات با ارزشی باشند، از منابع مختلفی همچون اطلاعات بازار برق، اطلاعات جغرافیایی، شبکه‌های اجتماعی و تجهیزات هوشمند نصب شده در شبکه جمع‌آوری می‌گردند. هدف استفاده از تکنولوژی‌های پیشرفته فناوری اطلاعات در شبکه برق، ارتباط پارامترهای فیزیکی مرسوم استفاده شده در شبکه با اینگونه داده‌ها به منظور کشف الگوهای بالقوه و استخراج چالش‌های فنی صنعت برق است. ابزارهای تحلیلی مرسوم به منظور استفاده در عملیات، نگهداری و برنامه‌ریزی شبکه‌های هوشمند دارای پیچیدگی زمانی بالایی هستند و همواره به راه‌کار امکان‌پذیری منتج نمی‌گردد. از این رو روش‌های هوش مصنوعی می‌توانند با استخراج ارزش از حجم زیادی از داده‌ها، مواجه با تنوع و پویایی آنها با محاسبات به مراتب سریع‌تر، در عملیات، نگهداری و برنامه‌ریزی شبکه‌های هوشمند نقش خود را ایفا کنند. در دهه اخیر روش‌های مبتنی بر هوش مصنوعی افق‌های امید بخشی در شبکه‌های هوشمند ترسیم کرده‌اند. در این مقاله مروری سعی شده است رویکردهای یادگیری ماشین و یادگیری عمیق مرتبط با شبکه هوشمند برق با در نظر گرفتن کلان‌داده بررسی گردد. در ابتدا رویکردهای مرسوم شامل روش‌های آماری، سری‌های زمانی، پردازش سیگنال، روش‌های طیفی و نظریه اطلاعات در مقایسه با رویکردهای داده‌محور مطرح گردید. همچنین به نقش کلان‌داده در شبکه هوشمند برق و ویژگی‌های آن از جمله معماری کلان‌داده، چرخه حیات کلان‌داده و رویکردهای موثر در این حوزه اشاره شد. در انتها یک دسته‌بندی برای سرویس‌های مبتنی بر کلان‌داده در شبکه هوشمند برق ارائه و هر کدام مورد بررسی قرار گرفت. همچنین چالش‌ها و فرصت‌های پیش‌روی موسسات فعال در صنعت برق بیان گردید که می‌تواند توسط محققین و متخصصین مورد توجه و بررسی قرار گیرد.

References

مراجع

- [1] K. Zhou, C. Fu, S. Yang, "Big data driven smart energy management: From big data to big insights", *Renewable and Sustainable Energy Reviews*, vol. 56, pp. 215-225, April 2016 (doi: 10.1016/j.rser.2015.11.050).
- [2] S. Zhao, F. Blaabjerg, H. Wang, "An overview of artificial intelligence applications for power electronics", *IEEE Transactions on Power Electronics*, vol. 36, no. 4, pp. 4633-4658, April 2021 (doi: 10.1109/TPEL.2-020.3024914).
- [3] D. Syed, A. Zainab, A. Ghayeb, S.S. Refaat, H. Abu-Rub, O. Bouhali, "Smart grid big data analytics: Survey of technologies, techniques, and applications", *IEEE Access*, vol. 9, pp. 59564-59585, 2021 (doi: 10.1109/ACCESS.2020.3041178).
- [4] M. Mishra, J. Nayak, B. Naik, A. Abraham, "Deep learning in electrical utility industry: A comprehensive review of a decade of research", *Engineering Applications of Artificial Intelligence*, vol. 96, Article Number: 104000, Nov. 2020 (doi: 10.1016/j.engappai.2020.104000).
- [5] R. Arghandeh, Y.Z. Eds, "Big data application in power systems", Elsevier, 2018 (ISBN: 978-0-12-811968-6).
- [6] V. Chandola, A. Banerjee, V. Kumar, "Anomaly detection: A survey", *ACM Computing Surveys*, vol. 41, no. 3, pp. 1-58, July 2009 (doi: 10.1145/1541880.1541882).
- [7] V.J. Hodge, J. Austin, "A survey of outlier detection methodologies", *Artificial Intelligence Review*, vol. 22, no. 2, pp. 85-126, 2004 (doi: 10.1007/s10462-004-4304-y).
- [8] L. Erhan, M. Ndubuaku, M. Di Mauro, W. Song, M. Chen, G. Fortino, O. Bagdasar, A. Liotta, "Smart anomaly detection in sensor systems: A multi-perspective review", *Information Fusion*, vol. 67, pp. 64-79, Mar 2021 (doi: 10.1016/j.inffus.2020.10.001).
- [9] N. Mohamudally, M. Peermamode-Mohaboob, "Building an anomaly detection engine (ADE) for IoT smart applications", *Procedia Computer Science*, vol. 134, pp. 10-17, 2018 (doi: 10.1016/j.procs.2018.07.138).
- [10] M. Munir, S. A. Siddiqui, M.A. Chattha, A. Dengel, S. Ahmed, "FuseAD: Unsupervised anomaly detection in streaming sensors data by fusing statistical and deep learning models", *Sensors*, vol. 19, no. 11, 2019 (doi: 10.3390/s19112451).
- [11] D. Brauckhoff, K. Salamatian, M. May, "A signal processing view on packet sampling and anomaly detection", *Proceedings of the IEEE/INFCOM*, pp. 1-9, San Diego, CA, USA, March 2010 (doi: 10.1109/INFCOM.2010.5462154).

- [12] A. Tharwat, "Principal component analysis- A tutorial", *International Journal of Applied Pattern Recognition*, vol. 3, no. 3, Jan. 2016 (doi: 10.1504/IJAPR.2016.079733).
- [13] B.Å. Lundvall, C. Rikap, "China's catching-up in artificial intelligence seen as a co-evolution of corporate and national innovation systems", *Research Policy*, vol. 51, no. 1, Article Number: 104395, Jan. 2021.
- [14] G. Shobha, S. Rangaswamy, "Chapter 8- Machine learning", *Handbook of Statistics*, vol. 38, pp. 197-228, 2018 (doi: 10.1016/bs.host.2018.07.004).
- [15] K.P. Murphy, "Machine learning: A probabilistic perspective", MIT Press, Cambridge, Massachusetts London, England, 2012 (ISBN-13: 978-0262018029).
- [16] J. Qiu, Q. Wu, G. Ding, Y. Xu, S. Feng, "A survey of machine learning for big data processing", *EURASIP Journal on Advances in Signal Processing*, vol. 2016, no. 1, Article number: 67, May 2016 (doi: 10.1186/s13634-016-0355-x).
- [17] A. Mellit, A. Massi Pavan, E. Ogliairi, S. Leva, V. Lughi, "Advanced methods for photovoltaic output power forecasting: A review", *Applied Sciences*, vol. 10, no. 2, Article Number: 487, Jan. 2020 (doi: 10.3390/app10-020487).
- [18] S. Shamshirband, T. Rabczuk, K. Chau, "A survey of deep learning techniques: Application in wind and solar energy resources", *IEEE Access*, vol. 7, pp. 164650-164666, Nov. 2019 (doi: 10.1109/ACCESS.2019.2951-750).
- [19] Y. LeCun, Y. Bengio, G. Hinton, "Deep learning", *Nature*, vol. 521, no. 7553, pp. 436-444, 2015 (doi: 10.1038/nature14539).
- [20] Y. Xin, L. Kong, Z. Liu, Y. Chen, Y. Li, H. Zhu, M. Gao, H. Hou, C. Wang, "Machine learning and deep learning methods for cybersecurity", *IEEE Access*, vol. 6, pp. 35365-35381, 2018 (doi: 10.1109/ACCESS.2018.2836950).
- [21] M.A. Wani, F.A. Bhat, S. Afzal, A.I. Khan, "Advances in deep learning", Springer, 2020 (ISBN: 978-981-13-6794-6).
- [22] I. Goodfellow, Y. Bengio, A. Courville, "Deep learning", MIT Press, Cambridge, Massachusetts London, England, 2016 (ISBN: 9780262035613).
- [23] D. Zhang, X. Han, C. Deng, "Review on the research and practice of deep learning and reinforcement learning in smart grids", *Csee Journal of Power and Energy Systems*, vol. 4, no. 3, pp. 362-370, Sept. 2018 (doi: 10.17775/CSEEJPES.2018.00520).
- [24] Q. Zhang, K. Dehghanpour, Z. Wang, Q. Huang, "A learning-based power management method for networked microgrids under incomplete information", *IEEE Trans. on Smart Grid*, vol. 11, no. 2, pp. 1193-1204, March 2020 (doi: 10.1109/TSG.2019.2933502).
- [25] T. Hastie, R.F. Tishirani, Jerome, "The elements of statistical learning", Springer, 2009 (ISBN-13: 978-0387848570).
- [26] A. Dogan, D. Birant, "Machine learning and data mining in manufacturing", *Expert Systems with Applications*, vol. 166, Article Number: 114060, Mar. 2021 (doi: 10.1016/j.eswa.2020.114060).
- [27] V. Garcia-Font, C. Garrigues, H. Rifà-Pous, "A comparative study of anomaly detection techniques for smart city wireless sensor networks", *Sensors*, vol. 16, no. 6, Article Number: 868, June 2016 (doi: 10.3390/s16060868).
- [28] R.S. Sutton, A.G. Barto, "Reinforcement learning: An introduction", MIT Press, Cambridge, Massachusetts London, England, 2018.
- [29] L. Yin, Q. Gao, L. Zhao, B. Zhang, T. Wang, S. Li, H. Liu, "A review of machine learning for new generation smart dispatch in power systems", *Engineering Applications of Artificial Intelligence*, vol. 88, Article Number: 103372, Feb. 2020 (doi: 10.1016/j.engappai.2019.103372).
- [30] Y. Pan, "Heading toward artificial intelligence 2.0", *Engineering*, vol. 2, no. 4, pp. 409-413, Dec. 2016 (doi: 10.1016/J.ENG.2016.04.018).
- [31] D. Judith, S. Klamer, O. Serena, "A vision on hybrid AI for military applications", *Proceedings of SPIE*, vol. 11169, Strasbourg, France, Oct. 2019 (doi: 10.1117/12.2551893).
- [32] S. Khan, T. Yairi, "A review on the application of deep learning in system health management", *Mechanical Systems and Signal Processing*, vol. 107, pp. 241-265, July 2018 (doi: 10.1016/j.ymssp.2017.11.024).
- [33] J. Wang, X. Chen, F. Zhang, F. Chen, Y. Xin, "Building load forecasting using deep neural network with efficient feature fusion", *Journal of Modern Power Systems and Clean Energy*, vol. 9, no. 1, pp. 160-169, Jan. 2021 (doi: 10.35833/MPCE.2020.000321).
- [34] S. Zhou, Q. Chen, X. Wang, "Discriminative deep belief networks for image classification", *Proceeding of the IEEE/ICIP*, pp. 1561-1564, Hong Kong, China, Sept. 2010 (doi: 10.1109/ICIP.2010.5649922).
- [35] D. Cao, W. Hu, J. Zhao, G. Zhang, B. Zhang, Z. Liu, Z. Chen, F. Blaabjerg, "Reinforcement learning and its applications in modern power and energy systems: A review", *Journal of Modern Power Systems and Clean Energy*, vol. 8, no. 6, pp. 1029-1042, Nov. 2020 (doi: 10.35833/MPCE.2020.000552).

- [36] Z. Zhang, D. Zhang, R.C. Qiu, "Deep reinforcement learning for power system applications: An overview", *Csee Journal of Power and Energy Systems*, vol. 6, no. 1, pp. 213-225, March 2020 (doi: 10.17775/CSEE-JPES.2019.00920).
- [37] G.C. Ruan, H.W. Zhong, G.L. Zhang, Y.L. He, X. Wang, T.J. Pu, "Review of learning-assisted power system optimization", *Csee Journal of Power and Energy Systems*, Review vol. 7, no. 2, pp. 221-231, March 2021 (doi: 10.17775/cseejpes.2020.03070).
- [38] M. Khodayar, J. Wang, "Probabilistic time-varying parameter identification for load modeling: A deep generative approach", *IEEE Trans. on Industrial Informatics*, vol. 17, no. 3, pp. 1625-1636, March 2021 (doi: 10.1109/TII.2020.2971014).
- [39] J. Liu, F. Qu, X. Hong, H. Zhang, "A small-sample wind turbine fault detection method with synthetic fault data using generative adversarial nets", *IEEE Trans. on Industrial Informatics*, vol. 15, no. 7, pp. 3877-3888, July 2019 (doi: 10.1109/TII.2018.2885365).
- [40] S. Ahmadian, H. Malki, Z. Han, "Cyber attacks on smart energy grids using generative adversarial networks", *Proceeding of the IEEE/GlobalSIP*, pp. 942-946, Anaheim, CA, USA, Nov. 2018 (doi: 10.1109/GlobalSIP.2018.8646424).
- [41] Y. Chen, Y. Wang, D. Kirschen, B. Zhang, "Model-free renewable scenario generation using generative adversarial networks", *IEEE Trans. on Power Systems*, vol. 33, no. 3, pp. 3265-3275, May 2018 (doi: 10.1109/TPWRS.2018.2794541).
- [42] Z. Guan, Y. Zhang, L. Zhu, L. Wu, S. Yu, "EFFECT: An efficient flexible privacy-preserving data aggregation scheme with authentication in smart grid", *Science China Information Sciences*, vol. 62, no. 3, p. 32103, 2019 (doi: 10.1007/s11432-018-9451-y).
- [43] C.W. Tsai, C.F. Lai, H.C. Chao, A.V. Vasilakos, "Big data analytics: A survey", *Journal of Big Data*, vol. 2, no. 1, p. 21, 2015 (doi: 10.1186/s40537-015-0030-3).
- [44] Y. Zhang, T. Huang, E.F. Bompard, "Big data analytics in smart grids: A review", *Energy Informatics*, vol. 1, no. 1, Article Number: 8, 2018 (doi: 10.1186/s42162-018-0007-5).
- [45] S. Sagiroglu, R. Terzi, Y. Canbay, I. Colak, "Big data issues in smart grid systems", *Proceeding of the IEEE/ICRERA*, pp. 1007-1012, Birmingham, UK, Nov. 2016 (doi: 10.1109/ICRERA.2016.7884486).
- [46] D. Baimel, S. Tapuchi, N. Baimel, "Smart grid communication technologies- overview, research challenges and opportunities", *Proceeding of the IEEE/SPEEDAM*, pp. 116-120, Capri, Italy, June 2016 (doi: 10.1109/SPEEDAM.2016.7526014).
- [47] H. Daki, A. El Hannani, A. Aqqal, A. Haidine, A. Dahbi, "Big Data management in smart grid: concepts, requirements and implementation", *Journal of Big Data*, vol. 4, no. 1, Article Number:13, 2017 (doi: 10.1186/s40537-017-0070-y).
- [48] J. Ma, J.C.P. Cheng, F. Jiang, W. Chen, M. Wang, C. Zhai, "A bi-directional missing data imputation scheme based on LSTM and transfer learning for building energy data", *Energy and Buildings*, vol. 216, Article Number: 109941, 2020 (doi: 10.1016/j.enbuild.2020.109941).
- [49] S. Jung, J. Moon, S. Park, S. Rho, S.W. Baik, E. Hwang, "Bagging ensemble of multilayer perceptrons for missing electricity consumption data imputation", *Sensors*, vol. 20, no. 6, Article Number: 1772, March:2020 (doi: 10.3390/s20061772).
- [50] C.L. Stimmel, "Big data analytics strategies for the smart grid", CRC Press, 2019 (ISBN 9781482218282).
- [51] D.V. Nga, O.H. See, D.N. Quang, C.Y. Xuen, L.L. Chee, "Visualization techniques in smart grid", *Smart Grid and Renewable Energy*, vol. 3, no. 3, Article Number: 22056, 2012 (doi: 10.4236/sgre.2012.33025).
- [52] L. Xie, Y. Chen, P.R. Kumar, "Dimensionality reduction of synchrophasor data for early event detection: linearized analysis", *IEEE Trans. on Power Systems*, vol. 29, no. 6, pp. 2784-2794, 2014 (doi: 10.1109/TPWRS.2014.2316476).
- [53] S.K. Sharma, X. Wang, "Live data analytics with collaborative edge and cloud processing in wireless iot networks", *IEEE Access*, vol. 5, pp. 4621-4635, 2017 (doi: 10.1109/ACCESS.2017.2682640).
- [54] K. Nguyen, M. Cheriet, "Virtual edge-based smart community network management", *IEEE Internet Computing*, vol. 20, no. 6, pp. 32-41, 2016 (doi: 10.1109/MIC.2016.127).
- [55] X. Yu, Y. Xue, "Smart grids: A cyber-physical systems perspective", *Proceedings of the IEEE*, vol. 104, no. 5, pp. 1058-1070, 2016 (doi: 10.1109/JPROC.2015.2503119).
- [56] S. Bera, S. Misra, J.J.P.C. Rodrigues, "Cloud computing applications for smart grid: A survey", *IEEE Trans. on Parallel and Distributed Systems*, vol. 26, no. 5, pp. 1477-1494, 2015 (doi: 10.1109/TPDS.2014.2321378).
- [57] H. Jahangir, H. Tayarani, S. Baghali, A. Ahmadian, A. Elkamel, M.A. Golkar, M. Castilla, "A novel electricity price forecasting approach based on dimension reduction strategy and rough artificial neural networks", *IEEE Trans. on Industrial Informatics*, vol. 16, no. 4, pp. 2369-2381, 2020 (doi: 10.1109/TII.2019.2933009).
- [58] M. Bourdeau, X.Q. Zhai, E. Nefzaoui, X. Guo, P. Chatellier, "Modeling and forecasting building energy consumption: A review of data-driven techniques", *Sustainable Cities and Society*, vol. 48, Article Number: 101533, 2019 (doi: 10.1016/j.scs.2019.101533).

- [59] B. Luo, S. Miao, "A literature survey on electricity price forecasting in deregulated markets", Proceeding of the IEEE/iSPEC, pp. 359-365, Beijing, China, Nov. 2019 (doi: 10.1109/iSPEC48194.2019.8974939).
- [60] M. Askari, F. Keynia, "Mid-term electricity load forecasting by a new composite method based on optimal learning MLP algorithm", IET Generation, Transmission and Distribution, vol. 14, no. 5, pp. 845-852, March 2020 (doi: 10.1049/iet-gtd.2019.0797).
- [61] F. Ziel, R. Steinert, "Probabilistic mid- and long-term electricity price forecasting", Renewable and Sustainable Energy Reviews, vol. 94, pp. 251-266, 2018 (doi: 10.1016/j.rser.2018.05.038).
- [62] M. Tan, S. Yuan, S. Li, Y. Su, H. Li, F. He, "Ultra-short-term industrial power demand forecasting using lstm based hybrid ensemble learning", IEEE Trans. on Power Systems, vol. 35, no. 4, pp. 2937-2948, 2020 (doi: 10.1109/TPWRS.2019.2963109).
- [63] A.A. Mamun, M. Sohel, N. Mohammad, M.S.H. Sunny, D.R. Dipta, E. Hossain, "A comprehensive review of the load forecasting techniques using single and hybrid predictive models", IEEE Access, vol. 8, pp. 134911-134939, 2020 (doi: 10.1109/ACCESS.2020.3010702).
- [64] C. Kuster, Y. Rezugui, M. Mourshed, "Electrical load forecasting models: A critical systematic review", Sustainable Cities and Society, vol. 35, pp. 257-270, 2017 (doi: 10.1016/j.scs.2017.08.009).
- [65] Y.H. Chen, W.C. Hong, W. Shen, N.N. Huang, "Electric load forecasting based on a least squares support vector machine with fuzzy time series and global harmony search algorithm", Energies, vol. 9, no. 2, Article Number: 70, Jan. 2016 (doi: 10.3390/en9020070).
- [66] D. Niu, S. Dai, "A short-term load forecasting model with a modified particle swarm optimization algorithm and least squares support vector machine based on the denoising method of empirical mode decomposition and grey relational analysis", Energies, vol. 10, no. 3, Article Number: 408, March 2017 (doi: 10.3390/en10-030408).
- [67] L. Suganthi, A.A. Samuel, "Energy models for demand forecasting- A review", Renewable and Sustainable Energy Reviews, vol. 16, no. 2, pp. 1223-1240, 2012 (doi: 10.1016/j.rser.2011.08.014).
- [68] S. Welikala, C. Dinesh, M.P.B. Ekanayake, R.I. Godaliyadda, J. Ekanayake, "Incorporating appliance usage patterns for non-intrusive load monitoring and load forecasting", IEEE Trans. on Smart Grid, vol. 10, no. 1, pp. 448-461, 2019 (doi: 10.1109/TSG.2017.2743760).
- [69] S. Singh, A. Yassine, "Mining energy consumption behavior patterns for households in smart grid", IEEE Trans. on Emerging Topics in Computing, vol. 7, no. 3, pp. 404-419, 2019 (doi: 10.1109/TETC.2017.26920-98).
- [70] S. Oprea, A. Bâra, "Machine learning algorithms for short-term load forecast in residential buildings using smart meters, sensors and big data solutions", IEEE Access, vol. 7, pp. 177874-177889, 2019 (doi: 10.1109/ACCESS.2019.2958383).
- [71] I. Kiprijanovska, S. Stankoski, I. Ilievski, S. Jovanovski, M. Gams, H. Gjoreski, "HousEEC: day-ahead household electrical energy consumption forecasting using deep learning", Energies, vol. 13, no. 10, Article Number: 2672, May 2020 (doi: 10.3390/en13102672).
- [72] D. Wei, J. Wang, K. Ni, G. Tang, "Research and application of a novel hybrid model based on a deep neural network combined with fuzzy time series for energy forecasting", Energies, vol. 12, no. 18, Article Number: 3588, Sept. 2019 (doi: 10.3390/en12183588).
- [73] Z. Guo, K. Zhou, X. Zhang, S. Yang, "A deep learning model for short-term power load and probability density forecasting", Energy, vol. 160, pp. 1186-1200, 2018 (doi: 10.1016/j.energy.2018.07.090).
- [74] S. K. Acharya, Y.-M. Wi, J. Lee, "Short-term load forecasting for a single household based on convolution neural networks using data augmentation", Energies, vol. 12, no. 18, Article Number: 3560, Sept. 2019 (doi: 10.3390/en12183560).
- [75] H. Chen, S. Wang, S. Wang, Y. Li, "Day-ahead aggregated load forecasting based on two-terminal sparse coding and deep neural network fusion", Electric Power Systems Research, vol. 177, Article Number: 105987, 2019 (doi: 10.1016/j.epr.2019.105987).
- [76] S. Mujeeb, N. Javaid, M. Ilahi, Z. Wadud, F. Ishmanov, M. K. Afzal, "Deep long short-term memory: A new price and load forecasting scheme for big data in smart cities", Sustainability, vol. 11, no. 4, Article Number: 987, Feb. 2019 (doi: 10.3390/su11040987).
- [77] Y. Yang, W. Li, T.A. Gulliver, S. Li, "Bayesian deep learning-based probabilistic load forecasting in smart grids", IEEE Trans. on Industrial Informatics, vol. 16, no. 7, pp. 4703-4713, 2020 (doi: 10.1109/TII.2019.2-942353).
- [78] W. Kong, Z.Y. Dong, Y. Jia, D.J. Hill, Y. Xu, Y. Zhang, "Short-term residential load forecasting based on lstm recurrent neural network", IEEE Trans. on Smart Grid, vol. 10, no. 1, pp. 841-851, 2019 (doi: 10.1109/TSG.2017.2753802).
- [79] T. Ahmad, H. Zhang, B. Yan, "A review on renewable energy and electricity requirement forecasting models for smart grid and buildings", Sustainable Cities and Society, vol. 55, Article Number: 102052, 2020 (doi: 10.1016/j.scs.2020.102052).

- [80] M. Sharifzadeh, A. Sikinioti-Lock, N. Shah, "Machine-learning methods for integrated renewable power generation: A comparative study of artificial neural networks, support vector regression, and Gaussian Process Regression", *Renewable and Sustainable Energy Reviews*, vol. 108, pp. 513-538, July 2019 (doi: 10.1016/j.rser.2019.03.040).
- [81] B. Chen, P. Lin, Y. Lai, S. Cheng, Z. Chen, L. Wu, "Very-short-term power prediction for pv power plants using a simple and effective rcc-lstm model based on short term multivariate historical datasets", *Electronics*, vol. 9, no. 2, Article Number: 289, Feb. 2020 (doi: 10.3390/electronics9020289).
- [82] M. Abdel-Nasser, K. Mahmoud, "Accurate photovoltaic power forecasting models using deep LSTM-RNN", *Neural Computing and Applications*, vol. 31, no. 7, pp. 2727-2740, 2019 (doi: 10.1007/s00521-017-3225-z).
- [83] X. Qing, Y. Niu, "Hourly day-ahead solar irradiance prediction using weather forecasts by LSTM", *Energy*, vol. 148, pp. 461-468, 2018 (doi: 10.1016/j.energy.2018.01.177).
- [84] H. Zhou, Y. Zhang, L. Yang, Q. Liu, K. Yan, Y. Du, "Short-term photovoltaic power forecasting based on long short term memory neural network and attention mechanism", *IEEE Access*, vol. 7, pp. 78063-78074, 2019 (doi: 10.1109/ACCESS.2019.2923006).
- [85] B. Zhou, X. Ma, Y. Luo, D. Yang, "Wind power prediction based on LSTM networks and nonparametric kernel density estimation", *IEEE Access*, vol. 7, pp. 165279-165292, 2019 (doi: 10.1109/ACCESS.2019.2-952555).
- [86] H.Z. Wang, G.Q. Li, G.B. Wang, J.C. Peng, H. Jiang, Y.T. Liu, "Deep learning based ensemble approach for probabilistic wind power forecasting", *Applied Energy*, vol. 188, pp. 56-70, 2017 (doi: 10.1016/j.apenergy.2016.11.111).
- [87] Y. Ju, G. Sun, Q. Chen, M. Zhang, H. Zhu, M.U. Rehman, "A model combining convolutional neural network and lightgbm algorithm for ultra-short-term wind power forecasting", *IEEE Access*, vol. 7, pp. 28309-28318, 2019 (doi: 10.1109/ACCESS.2019.2901920).
- [88] J. Jeong, H. Kim, "Multi-site photovoltaic forecasting exploiting space-time convolutional neural network", *Energies*, vol. 12, no. 23, Article Number: 4490, Nov. 2019 (doi: 10.3390/en12234490).
- [89] M.Q. Raza, N. Mithulanathan, J. Li, K.Y. Lee, H.B. Gooi, "An ensemble framework for day-ahead forecast of pv output power in smart grids", *IEEE Trans. on Industrial Informatics*, vol. 15, no. 8, pp. 4624-4634, 2019 (doi: 10.1109/TII.2018.2882598).
- [90] D. Lee, K. Kim, "Recurrent neural network-based hourly prediction of photovoltaic power output using meteorological information", *Energies*, vol. 12, no. 2, Article Number: 215, Jan. 2019 (doi: 10.3390/en12-020215).
- [91] F. Zhang, H. Fleyeh, "A review of single artificial neural network models for electricity spot price forecasting", *Proceeding of the IEEE/EEM*, pp. 1-6, 2019 (doi: 10.1109/EEM.2019.8916423).
- [92] P.H. Kuo, C.J. Huang, "An electricity price forecasting model by hybrid structured deep neural networks", *Sustainability*, vol. 10, no. 4, Article Number: 1280, April 2018 (doi: 10.3390/su10041280).
- [93] G. Díaz, J. Coto, J. Gómez-Aleixandre, "Prediction and explanation of the formation of the Spanish day-ahead electricity price through machine learning regression", *Applied Energy*, vol. 239, pp. 610-625, 2019 (doi: 10.1016/j.apenergy.2019.01.213).
- [94] U. Ugurlu, I. Oksuz, O. Tas, "Electricity price forecasting using recurrent neural networks", *Energies*, vol. 11, no. 5, Article Number: 1255, May 2018 (doi: 10.3390/en11051255).
- [95] J. Lago, F.D. Ridder, B.D. Schutter, "Forecasting spot electricity prices: Deep learning approaches and empirical comparison of traditional algorithms", *Applied Energy*, vol. 221, pp. 386-405, 2018 (doi: 10.1016/j.apenergy.2018.02.069).
- [96] J. Wang, F. Liu, Y. Song, J. Zhao, "A novel model: Dynamic choice artificial neural network (DCANN) for an electricity price forecasting system", *Applied Soft Computing*, vol. 48, pp. 281-297, 2016 (doi: 10.1016/j.asoc.2016.07.011).
- [97] R. Khalid, N. Javaid, F.A. Al-zahrani, K. Aurangzeb, E.U.H. Qazi, T. Ashfaq, "Electricity load and price forecasting using jaya-long short term memory (JLSTM) in smart grids", *Entropy*, vol. 22, no. 1, Article Number: 10, Dec.2020 (doi: 10.3390/e22010010).
- [98] L. Gigoni, A. Betti, M. Tucci, E. Crisostomi, "A scalable predictive maintenance model for detecting wind turbine component failures based on SCADA data", *Proceeding of the IEEE/PESGM*, pp. 1-5, Atlanta, GA, USA, Aug. 2019 (doi: 10.1109/PESGM40551.2019.8973898).
- [99] R. Venkataswamy, K.U. Rao, P. Meena, "Internet of things based metaheuristic reliability centered maintenance of distribution transformers", *IOP Conference Series: Earth and Environmental Science*, vol. 463, no. 1, Article Number: 012047, 2020 (doi: 10.1088/1755-1315/463/1/012047).
- [100] T.P. Carvalho, F.A.A.M.N. Soares, R. Vita, R.P. Francisco, J.P. Basto, S.G.S. Alcalá, "A systematic literature review of machine learning methods applied to predictive maintenance", *Computers and Industrial Engineering*, vol. 137, Article Number: 106024, Nov. 2019 (doi: 10.1016/j.cie.2019.106024).

- [101] F. Kabir, B. Foggo, N. Yu, "Data driven predictive maintenance of distribution transformers", Proceeding of the IEEE/CICED, pp. 312-316, Tianjin, China, Sept. 2018 (doi: 10.1109/CICED.2018.8592417).
- [102] T. Huuhtanen, A. Jung, "Predictive maintenance of photovoltaic panels via deep learning", Proceeding of the IEEE/DSW, pp. 66-70, Lausanne, Switzerland, June 2018 (doi: 10.1109/DSW.2018.8439898).
- [103] M.R. Skydt, M. Bang, H.R. Shaker, "A probabilistic sequence classification approach for early fault prediction in distribution grids using long short-term memory neural networks", Measurement, vol. 170, Article Number: 108691, Jan. 2021 (doi: 10.1016/j.measurement.2020.108691).
- [104] M. Nithya, S. Nagarajan, P. Navaseelan, "Fault detection of wind turbine system using neural networks", Proceeding of the IEEE/TIAR, pp. 103-108, Chennai, India, April 2017 (doi: 10.1109/TIAR.2017.8273694).
- [105] R. Tervo, J. Karjalainen, A. Jung, "Predicting electricity outages caused by convective storms", Proceeding of the IEEE/DSW, pp. 145-149, Lausanne, Switzerland, June 2018 (doi: 10.1109/DSW.2018.8439906).
- [106] G. Kaikai, C. Kai, G. Ran, W. Ruoyue, P. Zhonghan, S. You, "Typical ice-wind fault analysis based on correlation analysis and naive bayesian method", Proceeding of the IEEE/ICET, pp. 372-377, Chengdu, China, May 2020 (doi: 10.1109/ICET49382.2020.9119709).
- [107] Y. Li, X. Song, S. Zhao, F. Gao, "A line-fault cause analysis method for distribution network based on decision-making tree and machine learning", Proceeding of the IEEE/ACPEE, pp. 1-5, Chengdu, China, June 2020 (doi: 10.1109/ACPEE48638).
- [108] C. Cepeda, C. Orozco-Henao, W. Percybrooks, J.D. Pulgarín-Rivera, O.D. Montoya, W. Gil-González, J.C. Vélez, "Intelligent fault detection system for microgrids", Energies, vol. 13, no. 5, Article Number: 1223, March 2020 (doi: 10.3390/en13051223).
- [109] J.Y. Hsu, Y. Wang, K.C. Lin, M. Chen, J.H.Y. Hsu, "Wind turbine fault diagnosis and predictive maintenance through statistical process control and machine learning", IEEE Access, vol. 8, pp. 23427-23439, Jan. 2020 (doi: 10.1109/ACCESS.2020.2968615).
- [110] M.A. Karim, J. Currie, T. Lie, "Dynamic event detection using a distributed feature selection based machine learning approach in a self-healing microgrid", IEEE Trans. on Power Systems, vol. 33, no. 5, pp. 4706-4718, Sept. 2018 (doi: 10.1109/TPWRS.2018.2812768).
- [111] W. Li, D. Deka, M. Chertkov, M. Wang, "Real-time faulted line localization and pmu placement in power systems through convolutional neural networks", IEEE Trans. on Power Systems, vol. 34, no. 6, pp. 4640-4651, Nov. 2019 (doi: 10.1109/TPWRS.2019.2917794).
- [112] Y. Huo, G. Prasad, L. Lampe, V.C.M. Leung, "Advanced smart grid monitoring: intelligent cable diagnostics using neural networks", Proceeding of the IEEE/ISPLC, Malaga, Spain, pp. 1-6, May 2020 (doi: 10.1109/IS-PLC48789.2020.9115403).
- [113] E. Garoudja, A. Chouder, K. Kara, S. Silvestre, "An enhanced machine learning based approach for failures detection and diagnosis of PV systems", Energy Conversion and Management, vol. 151, pp. 496-513, Nov. 2017 (doi: 10.1016/j.enconman.2017.09.019).

زیرنویس‌ها

- | | |
|---|---|
| 1. Smart grid (SG) | 2. Artificial intelligence (AI) |
| 3. Machine learning | 4. Shallow neural network |
| 5. Predictive maintenance | 6. Deep neural network (DNN) |
| 7. Discriminative | 8. Advanced metering infrastructure (AMI) |
| 9. Internet of things (IoT) | 10. Gaussian |
| 11. Histogram | 12. Kernel function |
| 13. Proximity | 14. Sensor systems |
| 15. Cross-correlation | 16. Auto regressive integrated moving average |
| 17. Kalman filtering | 18. Wavelet |
| 19. Random packet sample | 20. Low-pass |
| 21. Principal component analysis (PCA) | 22. Kolmogorov |
| 23. Entropy | 24. Relative entropy |
| 25. International renewable energy agency (IRENA) | 26. Shallow neural network |
| 27. Historical data | 28. Supervised |
| 29. Unsupervised | 30. Semi-supervised |
| 31. Reinforcement learning (RL) | 32. Deep learning (DL) |
| 33. Classification | 34. Support vector machine |
| 35. K nearest neighbor (KNN) | 36. Decision tree |
| 37. One class SVM (OC-SVM) | 38. Clustering |
| 39. Association rule mining | 40. Outlier detection |
| 41. Density estimation | 42. Q Learning |

43. State-action-reward-state-action (SARSA)
45. Deep belief networks (DBN)
47. Convolutional neural networks (CNN)
49. Long-short term memory (LSTM) networks
51. Image recognition
53. Natural language processing (NLP)
55. Military
57. Sigmoid
59. Weight matrix
61. Stacked auto-encoder
63. Deep Q network
65. Deep deterministic policy gradient (DDPG)
67. Cloud
69. Edge
71. Variety
73. Value
75. Reactive power flow
77. Service oriented architecture (SOA)
79. Unified modeling language (UML)
81. Google GFS
83. Multi-layer perceptron (MLP) ensemble
85. Apache storm
87. Andrew curve
89. Distributed systems operators (DSO)
91. Learning rate
93. Data augmentation
95. Photovoltaic
97. Gated recurrent units (GRU)
99. Stacked denoising
101. AdaBoost
103. Density-based spatial clustering of applications with noise
44. Boltzmann machine (BM)
46. Feedforward deep networks (FDN)
48. Recurrent neural networks (RNN)
50. Generative adversarial networks (GAN)
52. Speech recognition
54. Health care management
56. Classic multilayer perceptron (MLP)
58. Hyperbolic tangent
60. Gradient descent (GD)
62. Markov decision process (MDP)
64. Double DQN
66. Probabilistic density function (PDF)
68. Fog
70. Volume
72. Velocity
74. Veracity
76. Meta data
78. Enterprise service bus (ESB)
80. Distributed file system (DFS)
82. Column oriented
84. Apache hadoop
86. Apache spark
88. Edge
90. Backtracking adjustment
92. Mean square error (MSE)
94. Ensemble learning
96. Gradient boosting machine (GBM)
98. Dynamic choice ANN (DCANN)
100. Random forest
102. Micro grid