Computational Intelligence in Electrical Engineering
Vol. 17, No. 03, 2026
pp. 1-20
Research Paper

Determining the Dispatchable Region of Conventional Generators in the Presence of Renewable Resources Using a Deep Learning Method with an Explainable AI Interpreter

Ali Beiranvand [1], MahmoudReza Shakarami [2], Meysam Doostizadeh[3*]
[1] Dept. of Electrical Engineering, University of Lorestan, KhoramAbad, Iran
[2] Dept. of Electrical Engineering, University of Lorestan, KhoramAbad, Iran
[3] Dept. of Electrical Engineering, University of Lorestan, KhoramAbad, Iran

Abstract:
The increasing penetration rate of renewable resources in power systems, due to their variable nature and uncertainty, has created many challenges in the operation of power networks and also in the determination of the dispatchable region. Mathematical analytical methods for determining such regions, due to the need for accurate modeling and solving large-scale nonlinear optimization problems, often face computational challenges such as time consumption, a lack of suitable and fast nonlinear solvers, and their inefficiency in real-time operations. To determine the dispatchable region, this paper presents a new solution using the capabilities and advantages of artificial intelligence methods such as deep learning, equipped with Explainable Artificial Intelligence (XAI) and an analyzer that can analyze the behavior of the model and identify key factors affecting the determination of dispatchable regions. Furthermore, to make the problem of determining the dispatchable region robust against load uncertainty, load variations are also considered. The results of simulations performed on the IEEE-30 Bus standard power system indicate the high accuracy and speed of the proposed model compared to exact methods, and it also allows for the determination of the dispatchable region under load change conditions.

Keywords: Real-Time Operations, Dispatchable Region, Deep Learning, Renewable Resources, Explainable Artificial Intelligence.

This is an open access article under the CC BY-NC-ND/4.0/ License (https://creativecommons.org/licenses/by-nc-nd/4.0/).
https://doi.org/10.22108/isee.2026.148114.1779

مقاله پژوهشی

تعیین ناحیهٔ قابل تخصیص ژنراتورهای متداول در حضور منابع تجدیدپذیر با به‌کارگیری روش یادگیری عمیق مجهز به یک مفسر هوشمند

علی بیرانوند[۱]، محمودرضا شاکرمی[۲]، میثم دوستی‌زاده[۳]*

۱- دانشجوی دکتری، دانشکدهٔ فنی و مهندسی، دانشگاه لرستان، خرم‌آباد، ایران
beiran87@gmail.com
۲- استاد، دانشکدهٔ فنی و مهندسی، دانشگاه لرستان، خرم‌آباد، ایران
shakarami.mr@lu.ac.ir
۳- دانشیار، دانشکدهٔ فنی و مهندسی، دانشگاه لرستان، خرم‌آباد، ایران
doostizadeh.m@lu.ac.ir

چکیده: افزایش نرخ نفوذپذیری منابع تجدیدپذیر در سیستم‌های قدرت به واسطهٔ ماهیت متغیر و عدم قطعیت در آنها، چالش‌های زیادی را در بهره‌برداری از شبکه‌های برق و همچنین تعیین ناحیهٔ قابل تخصیص ایجاد کرده است. روش‌های تحلیلی ریاضی برای تعیین این‌گونه نواحی، به دلیل نیاز به مدل‌سازی دقیق و حل مسائل بهینه‌سازی غیرخطی با ابعاد بزرگ، معمولاً با چالش‌های محاسباتی مانند زمان‌بربودن، نبود حل‌کننده‌های غیرخطی مناسب و سریع و عدم کارایی آنها در فعالیت‌های زمان-واقعی مواجه هستند. این مقاله، به منظور تعیین ناحیهٔ قابل تخصیص، راه‌حلی نوین با بهره‌گیری از قابلیت و مزایای روش‌های هوش مصنوعی مانند یادگیری عمیق مجهز به یک مفسر و تحلیل‌گر هوشمند (XAI) ارائه می‌کند که می‌تواند رفتار مدل را تحلیل و عوامل کلیدی مؤثر بر تعیین نواحی قابل تخصیص را شناسایی کند. علاوه بر آن، به منظور مقاوم‌کردن مسئلهٔ تعیین ناحیهٔ قابل تخصیص در برابر نوسانات بار، تغییرات بار نیز در نظر گرفته می‌شود. نتایج شبیه‌سازی‌های انجام‌شده بر روی سیستم قدرت نمونهٔ استاندارد IEEE 30-bus نشان‌دهندهٔ دقت و سرعت بسیار زیاد مدل پیشنهاد شده نسبت به روش‌های دقیق است و امکان تعیین ناحیهٔ قابل تخصیص در شرایط تغییر بار را نیز فراهم می‌کند.

واژه‌های کلیدی: بهره‌برداری زمان-واقعی، ناحیهٔ قابل تخصیص، یادگیری عمیق، منابع تجدیدپذیر، مفسر هوشمند.

۱- مقدمه

امروزه، سیستم‌های قدرت به واسطهٔ افزایش نرخ نفوذپذیری منابع تجدیدپذیر در آنها، با چالش‌های بسیار زیادی از نظر امنیت، انعطاف‌پذیری، حفاظت و عدم قطعیت در تولید مواجه هستند [۱]. سرعت نرخ رشد استفاده از منابع تجدیدپذیر در سال‌های اخیر به صورت فزاینده در حال افزایش بوده است؛ به گونه‌ای که مطابق بررسی‌های انجام‌شده توسط [۲]، پیش‌بینی می‌شود حدود ۳۲ درصد از کل برق تولیدی در اتحادیهٔ اروپا توسط منابع تجدیدپذیر تأمین شود و این نرخ تولید توان توسط این منابع هرساله در حال افزایش است. در بین سال‌های ۲۰۱۱-۲۰۲۰، تولید توان توسط منابع تجدیدپذیر در اروپا و آسیا به ترتیب حدود ۵۲/۵ و ۶۶/۳۹ درصد افزایش داشته است. با توجه به رشد روزافزون توان تولیدی توسط منابع تجدیدپذیر، شبکهٔ قدرت باید قابلیت

[۱] تاریخ ارسال مقاله : ۱۴۰۴/۰۹/۰۸
تاریخ پذیرش مقاله : ۱۴۰۵/۰۸/۱۳
نام نویسنده مسئول : میثم دوستی‌زاده

نشانی نویسنده مسئول : ایران، خرم‌آباد، دانشگاه لرستان، دانشکده مهندسی

تحمل آن را داشته باشد و اپراتورهای سیستم قدرت باید بتوانند در سریع‌ترین زمان ممکن، برنامه‌ریزی‌های لازم برای نحوهٔ تخصیص توان توسط ژنراتورها را انجام دهند. در این مقاله، سعی بر آن است که به منظور جلوگیری از تزریق بیش از حد توان توسط منابع تجدیدپذیر به شبکهٔ قدرت، ناحیهٔ قابل قبول برای میزان توان تولیدی منابع تجدیدپذیر تعریف شود. با توجه به ماهیت بزرگ‌مقیاس‌بودن شبکهٔ قدرت و زمان‌بربودن انجام محاسبات پخش بار، از ابزارهای هوش مصنوعی مانند یادگیری عمیق مجهز به یک مفسر هوشمند (XAI)[1] کمک گرفته خواهد شد.

در سال‌های گذشته، مطالعات زیادی در ارتباط با تعیین ناحیهٔ قابل تخصیص (DR)[2] انجام شده‌اند. مرجع [۳] ناحیهٔ قابل تخصیص را برای منابع تولید توان بادی ارائه می‌کند. مرجع [٤] ابتدا منطقه یا ناحیهٔ قابل تخصیص را تعریف و سپس بیان می‌کند منطقهٔ قابل تخصیص به ناحیه‌ای گفته می‌شود که در آن، بیشینهٔ تولید توان توسط منابع تجدیدپذیر با در نظر گرفتن قیود و محدودیت‌های شبکهٔ قدرت تعیین می‌شود. سپس، حساسیت ژنراتورهای متداول شبکه را نسبت به مرزهای این ناحیه محاسبه می‌کند. مرجع [۵] بر اساس قیود امنیتی یک سیستم قدرت، تعیین ناحیهٔ امنیتی به منظور کنترل میزان توان تزریقی توسط منابع تجدیدپذیر به شبکه‌های نمونهٔ استاندارد IEEE مانند ۹، ۳۰ و ۱۱۸ شینه را بررسی می‌کند. مرجع [٦] نیز یک مدل جدید برای تعیین ناحیهٔ امنیتی بهره‌برداری احتمالی (POSR)[3] را برای منابع تجدیدپذیر دارای نرخ نفوذ زیاد در سیستم قدرت ارائه می‌کند و به منظور کاهش فضای جست‌وجوی حل مسئله، از یک الگوریتم ابتکاری استفاده و مرزهای این ناحیه را تعیین می‌کند. مرجع [۷]، علاوه بر در نظر گرفتن توان اکتیو در محاسبات تعیین ناحیهٔ قابل تخصیص، توان راکتیو را نیز در محاسبات لحاظ کرده و با استفاده از یک الگوریتم ابتکاری توانسته است ناحیهٔ قابل تخصیص ژنراتورهای متداول را تحت تأثیر عدم قطعیت زیاد منابع تجدیدپذیر تعیین کند.

علاوه بر مفاهیم ناحیهٔ قابل تخصیص و ناحیهٔ امنیتی که اوایل در بسیاری از نوشتارها در نظر گرفته می‌شد، در سال‌های بعد، از مفاهیمی دیگر مانند ناحیهٔ انعطاف‌پذیر، ناحیهٔ ممکن، ناحیهٔ حل‌پذیری و ناحیهٔ مجاز نیز استفاده شده است که همگی تقریباً دارای مفاهیمی یکسان هستند. برای مثال، مرجع [۸] تعیین ناحیهٔ ممکن (FR)[4] برای شبکه‌های توزیع سه فاز نامتعادل را بررسی می‌کند. مرجع [۹] نیز به تعیین ناحیهٔ ممکن برای شبکه‌های توزیع به منظور مشارکت این شبکه‌ها در بازار انرژی سطح انتقال توجه دارد. مرجع [۱۰] با هدف اطمینان از حل‌پذیربودن پخش بار در یک شبکهٔ توزیع، تعیین ناحیهٔ مجاز برای منابع تجدیدپذیر را بررسی می‌کند. مرجع [۱۱] از نظر حل‌پذیربودن پخش بار AC، تعیین ناحیهٔ حل‌پذیری یک سیستم قدرت در حضور منابع تجدیدپذیر را بررسی و تمامی مرزهای آن را از طریق حل یک مسئلهٔ بهینه‌سازی چندهدفه تعیین می‌کند.

با توجه به زمان‌بربودن تعیین دقیق کلیهٔ مرزهای ناحیهٔ قابل تخصیص و همچنین عدم فعال‌شدن بسیاری از این مرزها، با توجه به محدودیت‌های میزان توان خروجی منابع تجدیدپذیر، مرجع [۱۲] با استفاده از روش داده‌محور و به‌کارگیری خروجی‌های تاریخی منابع تجدیدپذیر، تعیین مرزهای بالقوهٔ فعال (PABs)[5] را بررسی کرده است. این کار باعث افزایش سرعت در تعیین مرزها و جلوگیری از حل مستقیم مسئلهٔ پیچیدهٔ تعیین مرزها و نواحی قابل تخصیص به روش تحلیلی می‌شود. استفاده از چنین روشی شاید بتواند مرزهای ناحیهٔ قابل تخصیص را به صورت داده‌محور ارائه کند، اما به دلیل عدم داشتن حافظه برای به خاطر سپردن جواب‌های مربوط به میزان توان تولیدی ژنراتورهای متداول به‌ازای تغییرات ایجادشده در میزان توان منابع تجدیدپذیر، لازم است به‌ازای هر بار تغییر در خروجی منابع تجدیدپذیر، عملیات حل پخش بار سیستم قدرت برای تعیین خروجی واحدهای متداول انجام شود. به‌کارگیری چنین روشی در شبکه‌های قدرت بزرگ‌مقیاس عملاً امکان‌پذیر نیست و در برابر تغییرات بار سیستم قدرت نیز مقاوم نخواهد بود.

در این مقاله، با بهره‌گیری از مزایای روش یادگیری عمیق که در سال‌های اخیر کاربردهای زیادی در حل مسائل پخش بار داشته است [۱۳]، [۱٤]، [۱۵] و [۱٦]، تعیین ناحیهٔ قابل تخصیص ژنراتورهای متداول در یک سیستم قدرت نمونه بررسی خواهد شد.

با مرور مطالعات انجام‌شده در زمینهٔ تعیین ناحیهٔ قابل تخصیص، می‌توان دریافت روش‌های موجود با چالش‌های

زیر مواجه هستند:

- روش‌های تحلیلی ریاضی: نیازمند مدل‌سازی دقیق و حل مسائل بهینه‌سازی غیرخطی با ابعاد بزرگ و عدم کارایی در کاربردهای زمان-واقعی.
- روش‌های داده‌محور: زمان‌بربودن انجام محاسبات پرحجم در صورت ازدیاد منابع تجدیدپذیر در شبکه و همچنین عدم مقاوم‌بودن در برابر تغییرات بار و نیاز به حل مکرر پخش بار.
- روش‌های مبتنی بر یادگیری عمیق در ناحیهٔ مجاز: تمرکز بیشتر بر تعیین مرزهای ناحیه و عدم توجه کافی به تحلیل حساسیت عناصر شبکه و شناسایی عوامل بحرانی.
- روش‌های تفسیرپذیر **OPF**: تمرکز بیشتر بر تفسیر ضرایب مدل به‌جای ارائهٔ تحلیل‌های فیزیکی از رفتار سیستم قدرت.

بر این اساس، شکاف پژوهشی اصلی این مقاله فقدان یک چارچوب یکپارچه است که بتواند موارد زیر را به صورت هم‌زمان انجام دهد:

۱- تعیین ناحیهٔ قابل تخصیص ژنراتورهای متداول در حضور منابع تجدیدپذیر.

۲- پیش‌بینی توان تولیدی ژنراتورها بدون حل مکرر پخش بار.

۳- مقاوم‌بودن در برابر تغییرات بار.

٤- فراهم‌کردن قابلیت تفسیرپذیری از طریق یک مفسر هوشمند.

نوآوری‌های این مقاله به شرح زیر است:

۱- ارائهٔ یک مدل یادگیری عمیق به عنوان جانشین سریع برای حل مکرر **OPF**: برخلاف روش‌های داده‌محور که فقط مرزها را تخمین می‌زنند، مدل پیشنهادی توان تولیدی ژنراتورهای متداول و توان عبوری خطوط را به صورت مستقیم و با دقت زیاد پیش‌بینی می‌کند.

۲- طراحی یک مفسر هوشمند چندسطحی: این مفسر بر پایهٔ **XAI**، ضمن تعیین اهمیت ویژگی‌ها، حساسیت خطوط و ژنراتورها را نسبت به تغییرات بار و تولید تجدیدپذیر تحلیل و خطوط بحرانی و گلوگاه‌های شبکه را شناسایی می‌کند. این قابلیت در روش‌های پیشین به‌خوبی بررسی نشده است.

۳- مقاوم‌سازی مدل در برابر تغییرات بار: مدل آموزش‌دیده بدون نیاز به آموزش مجدد، در برابر تغییرات بار شین‌ها مقاوم است. این ویژگی در روش‌های داده‌محور[6] که نیاز به حل مکرر پخش بار دارند، دیده نمی‌شود.

٤- تعیین ناحیهٔ قابل تخصیص بدون نیاز به تعیین مرزهای تحلیلی: برخلاف روش‌های تحلیلی و برخی از روش‌های داده‌محور، روش پیشنهادی نیازی به حل کامل مسئلهٔ تعیین ناحیه و تعیین مرزهای آن ندارد و فقط با استفاده از طبقه‌بندی آموزش‌دیده، امکان‌پذیری نقاط جدید را تعیین می‌کند.

مزیت‌های این روش نسبت به روش‌های قبلی (تحلیلی و داده محور) به صورت زیر است:

- جلوگیری از حل کامل مسئلهٔ تعیین ناحیهٔ قابل تخصیص.
- عدم نیاز به تعیین مرزهای قابل تخصیص.
- مقاوم‌کردن مسئله در برابر تغییرات بار در سیستم‌های قدرت.
- تعیین آنی مقدار توان تولیدی توسط ژنراتورهای متداول پس از تغییر در میزان خروجی منابع تجدیدپذیر بدون نیاز به حل مجدد مسئلهٔ پخش بار.
- داشتن قابلیت تفسیرپذیری از طریق یک سیستم مفسر هوشمند که می‌تواند رفتار مدل را تحلیل و عوامل کلیدی مؤثر را شناسایی کند.
- امکان شناسایی خطوط بحرانی و گلوگاه‌های شبکه با انجام تحلیل‌های حساسیت پیشرفته توسط مفسر هوشمند.
- امکان کمک به انجام تصمیم‌گیری صحیح توسط بهره‌بردار سیستم قدرت از طریق انجام تحلیل‌های کمّی و کیفی بر روی رفتار سیستم.

این خصوصیات مدل، در شرایطی که منابع تجدیدپذیر با نرخ نفوذ زیاد در یک سیستم قدرت حضور دارند، مزیت‌های عملیاتی قابل ملاحظه‌ای را برای بهره‌برداران سیستم قدرت ایجاد خواهند کرد.

۲- تعریف مسئلهٔ تعیین ناحیهٔ قابل تخصیص

در این مقاله، برای تعیین ناحیهٔ قابل تخصیص از روش پخش بار بهینهٔ DC (DC-OPF) استفاده می‌شود. پخش بار بهینهٔ DC در حالت کلی به صورت زیر نوشته می‌شود [۱۷]:

$$Minimize \quad f(x,u) \tag{۱}$$

$$h(x,u)=۰ \tag{۲}$$

$$g(x,u)\le b \tag{۳}$$

در معادلات (۱) تا (۳)، $\boldsymbol{x}$ بردار متغیرهای حالت شامل زوایای ولتاژ شین‌ها (δ) است. در مدلDC-OPF، دامنهٔ ولتاژ شین‌ها ثابت و برابر ۱ پریونیت فرض می‌شود و بنابراین، جزء متغیرهای حالت نیست. بردار u مربوط به متغیرهای تصمیم شامل توان تولیدی ژنراتورهای متداول (P_g) است. توان تولیدی منابع تجدیدپذیر (ω_e) به عنوان پارامتر ورودی در نظر گرفته می‌شود. تابع $f(x,u)$ تابع هدف (هزینهٔ تولید) است. قید $h(x,u)=۰$ مربوط به معادلهٔ توازن توان در شین‌ها و $g(x,u)\le b$ مجموعهٔ قیود بهره‌برداری شامل حدود تولید، محدودیت خطوط و محدودیت زاویه است.

هدف از پخش بار بهینهٔ DC تعیین توان تولیدی توسط ژنراتورهای متداول است؛ به گونه‌ای که هزینهٔ تولید توان در آن شبکه به حداقل برسد؛ بنابراین، در این مسئله، تابع هدف **f** فقط شامل یک چندجمله‌ای برحسب توان تولیدی توسط واحدهاست، یعنی:

$$f(P_g)=a.P_g^{۲}+b.P_g+c \tag{٤}$$

در تابع هزینهٔ (٤)، پارامتر **c** یک جملهٔ ثابت است و صفر قراردادن آن تأثیری بر نقطهٔ بهینهٔ مسئله ندارد و این معادل حذف یک عدد ثابت از تابع هدف است. ضریب a مربوط به جملهٔ درجهٔ دوم است و صفر قراردادن آن باعث خطی‌سازی تابع هزینه می‌شود. این تقریب به دلایل زیر قابل قبول است:

۱- ناحیهٔ قابل تخصیص توسط قیود بهره‌برداری تعیین می‌شود و به تابع هزینه وابسته نیست؛ بنابراین، خطی‌سازی تابع هزینه مرزهای این ناحیه را تغییر نمی‌دهد.

۲- تبدیل مسئلهٔ OPF از برنامه‌ریزی درجهٔ دو به برنامه‌ریزی خطی سرعت حل را به طرزی چشمگیر افزایش می‌دهد که برای تولید حجم زیاد داده‌های آموزشی ضروری است.

۳- در بسیاری از کاربردهای عملی و بازارهای برق، از تابع هزینهٔ خطی یا تکه‌ای خطی استفاده می‌شود.

٤- مدل یادگیری عمیق به عنوان یک جانشین کلی برای نگاشت OPF طراحی شده است و در صورت نیاز می‌توان آن را با تابع هزینهٔ درجهٔ دو نیز بازآموزی کرد؛ بنابراین، این تقریب برای هدف این مقاله (تعیین ناحیهٔ قابل تخصیص و ارائهٔ یک جایگزین سریع) کاملاً موجه و قابل قبول است.

با اضافه‌کردن توان تولیدی توسط منابع تجدیدپذیر به مسئلهٔ DC-OPF تعریف‌شده توسط [۱۸]، [۱۹] و [۲۰]، شکل جدید این مسئله به صورت زیر بازنویسی می‌شود:

$$Minimize f(P_g,\omega_e)=\sum_{g=1}^{N_g} b_g.P_g+\sum_{e=1}^{N_\omega} 0.\omega_e \tag{۵}$$

$$\sum_{g=1}^{N_g} P_g+\sum_{e=1}^{N_e} w_e-\sum_{d=1}^{N_d} P_d=\sum_{ij\in S_b} P_{ij} \tag{٦}$$

$$\boldsymbol{P_{ij}=b_{ij}(\delta_i-\delta_j)} \tag{۷}$$

$$P_g^{\min}\le P_g\le P_g^{\max} \quad \forall_g \tag{۸}$$

$$-P_{ij}^{\max}\le P_{ij}\le P_{ij}^{\max} \quad \forall_{ij} \tag{۹}$$

$$w_e^{\min}\le w_e\le w_e^{\max} \quad \forall_e \tag{۱۰}$$

$$\delta_i^{\min}\le \delta_i\le \delta_i^{\max} \quad \forall_i \tag{۱۱}$$

در مسئلهٔ بالا، معادلهٔ (۵) مربوط به تابع هدف یا هزینهٔ تولید توان توسط ژنراتورهای متداول است. در این مقاله، هزینهٔ تولید منابع تجدیدپذیر برابر صفر فرض شده است. معادلهٔ (٦) تعادل بین توان تولیدی توسط ژنراتورهای متداول ($\boldsymbol{P_g}$) و منابع تجدیدپذیر ($\boldsymbol{\omega_e}$)، توان مصرفی ($\boldsymbol{P_d}$) و توان انتقالی توسط خطوط ($\boldsymbol{P_{ij}}$) را نشان می‌دهد. معادلهٔ (۷) نشان‌دهندهٔ میزان توان عبوری از خطوط برحسب مقدار سوسپتانس خط ($\boldsymbol{b_{ij}}$) و اختلاف زاویهٔ شین‌های دو طرف آن ($\boldsymbol{\delta}$) است. نابرابری‌های (۱۱)-(۸) به ترتیب نشان‌دهندهٔ مقادیر کمینه ($P_g^{\min}$) و بیشینهٔ ($P_g^{\max}$) توان تولیدی توسط ژنراتورهای متداول، بیشینهٔ توان عبوری از خطوط ($P_{ij}^{\max}$)، کمینه ($\omega_e^{\min}$) و بیشینهٔ ($\omega_e^{\max}$) توان تولیدی توسط منابع تجدیدپذیر و کمینه ($\delta_i^{\min}$) و بیشینهٔ ($\delta_i^{\max}$) زاویهٔ شین‌های شبکه است. پارامترهای N_g، N_ω و N_d به ترتیب نشان‌دهندهٔ تعداد ژنراتورهای متداول، تعداد منابع تجدیدپذیر و تعداد بارهای شبکه است. مسئلهٔ (۱۱)-(۵) به صورت یک مسئلهٔ برنامه‌ریزی خطی (**LP**[۷]) است و به وسیلهٔ بیشتر حل‌کننده‌های مرسوم قابل حل است.

۳- مقاوم‌کردن مسئلهٔ تعیین ناحیهٔ قابل تخصیص در برابر تغییرات بار شبکه

بارهای الکتریکی موجود در یک سیستم قدرت واقعی دارای ماهیت متغیر با زمان و به صورت پیوسته در حال تغییر هستند؛ بنابراین، تعیین ناحیهٔ قابل تخصیص با فرض ثابت‌بودن بارهای شبکه، عملاً کارایی لازم را نخواهد داشت و لازم است تغییرات بار در مسئلهٔ تعیین ناحیهٔ قابل تخصیص در نظر گرفته شود. به همین منظور، در مسئلهٔ **DC-OPF** تعریف‌شده در (۱۱)-(۵)، معادلهٔ (٦) با افزودن میزان تغییرات بار، به صورت زیر بازنویسی می‌شود:

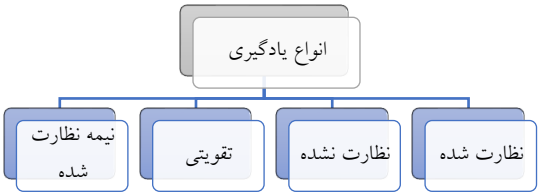
$$\sum_{g=1}^{N_g} P_g + \sum_{e=1}^{N_e} w_e - \sum_{d=1}^{N_d} (P_d^e + \Delta P_d) = \sum_{ij \in S_b} P_{ij} \qquad (۱۲)$$

که در آن، P^e_d مقدار بار مصرفی قطعی و پیش‌بینی‌شده در شین d است و ΔP_d تغییرات ناشی از وجود عدم قطعیت در مقدار بار مصرفی سیستم قدرت خواهد بود. با استفاده از معادلهٔ (۱۲)، می‌توان مسئلهٔ تعیین ناحیهٔ قابل تخصیص را مقاوم کرد تا در صورت تغییر میزان بار شین‌های شبکهٔ قدرت، قیود شبکه دچار تخطی نشوند و مسئله دارای جواب ممکن باشد.

میزان تغییرات بار (ΔP_d)، با توجه به شرایط شبکه، ممکن است به صورت مقادیر مثبت و منفی باشد تا بتواند تغییرات ناشی از افزایش یا کاهش بار را به طور کامل پیش‌بینی کند.

٤- نحوهٔ به‌کارگیری یادگیری عمیق در تعیین ناحیهٔ قابل تخصیص

امروزه، ابزارهای هوش مصنوعی مانند یادگیری عمیق که زیرمجموعه‌ای از یادگیری ماشین (**ML**)[۸] است، نقشی بسیار مهم در سیستم‌های قدرت مانند استفاده از آنها در پیش‌بینی بار، نظارت، کنترل و دیگر اقدامات بهینه‌سازی دارند [۲۱]. به دلیل بزرگ‌مقیاس‌بودن سیستم‌های قدرت و کثرت داده‌های کنترلی در آن، ابزارهای هوش مصنوعی مانند **DL**[۹] می‌توانند در دسته‌بندی و سپس تجزیه‌وتحلیل داده‌ها و استخراج الگوهای رفتاری مناسب بین آنها کمک کنند و سرعت رسیدن به پاسخ را افزایش دهند [۲۲]. مدل یادگیری عمیق از نظر روش آموزش‌دهی به چهار دسته تقسیم می‌شود که در شکل (۱) نشان داده شده است [۲۳]، [۲٤] و [۲۵].



شکل (۱): انواع روش‌های آموزش مدل یادگیری عمیق

در این مقاله، به منظور آموزش‌دادن مدل یادگیری عمیق، از روش نظارت‌شده استفاده می‌شود:

الف) آموزش مدل یادگیری عمیق به روش نظارت‌شده

به منظور آموزش مدل یادگیری عمیق به روش نظارت‌شده، ابتدا مسئلهٔ پخش بار بهینهٔ **DC** به‌ازای داده‌هایی مختلف حل می‌شود که از تغییرات بار شین‌ها و مقادیر توان اکتیو تولیدشده توسط منابع تجدیدپذیر به دست می‌آیند. پس از حل مسئلهٔ پخش بار، به‌ازای هر کدام از این داده‌ها، این‌گونه داده‌ها از نظر ممکن بودن یا نبودن برچسب‌گذاری می‌شوند و سپس، در صورت ممکن‌بودن آنها، خروجی حل مسئلهٔ پخش بار که مقدار توان تولیدی توسط ژنراتورهای متداول و مقدار توان عبوری از خطوط است، به عنوان خروجی مدل یادگیری عمیق در نظر گرفته می‌شود و داده‌های مربوط به بار و مقدار توان منابع تجدیدپذیر نیز به عنوان داده‌های ورودی این مدل لحاظ می‌شوند. کل این کار فرایند برچسب‌گذاری داده‌ها به صورت نظارت‌شده نامیده می‌شود. نمایش ریاضی ورودی‌های مدل یادگیری عمیق به صورت معادلهٔ (۱۳) است:

$$x = [w_{e_1} \quad w_{e_2} \quad \hat{P}_{d1} \quad \cdots \quad \hat{P}_{dn}]^T \qquad (۱۳)$$

که در آن، w_{ek} مقدار تولید توان توسط منبع تجدیدپذیر kام و $\hat{P}_{dj}$ مقدار بار مصرفی موجود در شین jام است. مدل یادگیری عمیق پیشنهادی در این مقاله به صورت زیر در نظر گرفته می‌شود:

$$\hat{y} = f_{DL}(x;\theta) \qquad (۱٤)$$

که در آن، x بردار ورودی شامل متغیرهای سیستم، $\hat{y}$ بردار خروجی پیش‌بینی‌شده برای هر کدام از لایه‌های مدل (در

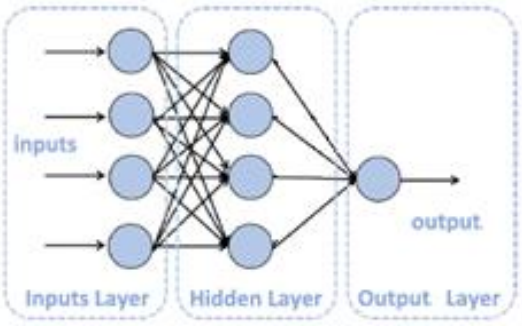
اینجا، لایهٔ خروجی)، θ پارامترهای مدل یادگیری و f_{DL} تابع نگاشت غیرخطی مدل عصبی است. بردار خروجی $\hat{y}$ به صورت معادلهٔ (۱۵) تعریف می‌شود:

$$\hat{\boldsymbol{y}} = \left[\hat{P}_{g1}, \ldots, \hat{P}_{g_{ng}}, \hat{S}_{\ell 1}, \ldots, \hat{S}_{\ell nl}\right]^T \qquad (۱۵)$$

که در آن، $\hat{P}_{g_i}$ توان پیش‌بینی‌شدهٔ تولیدی ژنراتور iام، $\hat{S}_{\ell l}$ توان ظاهری پیش‌بینی‌شدهٔ عبوری از خط l، ng تعداد ژنراتورهای متداول و nl تعداد خطوط شبکه است.

ب) گراف شبکهٔ عصبی مربوط به مدل یادگیری عمیق

مدل یادگیری عمیق در این مقاله اطلاعات مربوط به بارهای سیستم قدرت و توان تولیدی توسط منابع تجدیدپذیر را به عنوان داده‌های ورودی در نظر می‌گیرد. کل فرایند یادگیری مدل، به دست آوردن ارتباط بین ورودی و خروجی است که در این مسئله، به صورت تعیین توان تولیدی توسط ژنراتورهای متداول تعریف شده است. ارتباط بین داده‌های ورودی و خروجی از طریق لایه‌های پنهان برقرار می‌شود که نیاز است به وسیلهٔ داده‌های برچسب‌گذاری‌شده آموزش داده شود. گراف کلی مربوط به مدل یادگیری عمیق به صورت **شکل (۲)** نشان داده می‌شود [۲۶] و [۲۷].



شکل (۲): نمای کلی مدل یادگیری عمیق [۲۸]

معماری کلی مدل یادگیری عمیق با L لایهٔ پنهان استفاده‌شده به صورت معادلهٔ (۱۶) بیان می‌شود:

$$\begin{aligned} \boldsymbol{z}^{(1)} &= \boldsymbol{W}^{(1)}.\boldsymbol{x} + \boldsymbol{b}^{(1)} \\ \boldsymbol{a}^{(1)} &= \boldsymbol{\phi}(\boldsymbol{z}^{(1)}) \\ \boldsymbol{z}^{(\ell)} &= \boldsymbol{W}^{(\ell)}.\boldsymbol{a}^{(\ell-1)} + \boldsymbol{b}^{(\ell)} \\ \boldsymbol{a}^{(\ell)} &= \boldsymbol{\phi}(\boldsymbol{z}^{(\ell)}) \\ \hat{\boldsymbol{y}} &= \boldsymbol{W}^{(L+1)}.\boldsymbol{a}^{(L)} + \boldsymbol{b}^{(L+1)} \end{aligned} \qquad (۱۶)$$

که در آن، $\mathbf{x}$ بردار ورودی، $\mathbf{z}^{(l)}$ بردار پیش‌فعال‌سازی لایهٔ l، $\mathbf{W}^{(l)}$، $\mathbf{a}^{(l)}$ و $\mathbf{b}^{(l)}$ به ترتیب ماتریس وزن، بردار فعال‌سازی و بردار بایاس لایهٔ lام، φ تابع فعال‌ساز، L تعداد لایهٔ پنهان و $\hat{y}$ بردار خروجی پیش‌بینی‌شده است.

پ) آموزش مدل یادگیری عمیق و ارزیابی آن

مدل یادگیری عمیق درنظرگرفته‌شده در این مقاله به وسیلهٔ داده‌های ورودی آموزش داده می‌شود که شامل مقدار بار شین‌ها و توان تولیدی توسط منابع تجدیدپذیر است. به همین منظور، چنانچه کل داده‌ها برابر N باشد، در آن صورت، معمولاً تعداد αN از آنها به عنوان دادهٔ آموزشی در نظر گرفته می‌شود و مابقی داده‌ها (یعنی $N_e=N(1-\alpha)$) به منظور صحت‌سنجی و ارزیابی عملکرد مدل یادگیری استفاده می‌شوند. مقدار α معمولاً حدود ۰/۸ فرض می‌شود.

معمولاً شاخص‌های عملکرد مختلفی مانند ریشهٔ میانگین مربعات خطا (**RMSE**)[۱۰]، میانگین قدر مطلق درصد خطا (**MAPE**)[۱۱]، میانگین خطای مطلق (**MAE**)[۱۲] و میانگین مربعات خطا (**MSE**)[۱۳] برای ارزیابی عملکرد مدل یادگیری عمیق وجود دارند [۲۹]. روش ارزیابی **RMSE** به صورت زیر تعریف می‌شود:

$$RMSE = \sqrt{MSE} = \sqrt{\frac{1}{N_e}\sum_{i=1}^{N_e}\left(y_i^{pred} - y_i^{actual}\right)^2} \qquad (۱۷)$$

که در آن، MSE میانگین مربعات خطا، $RMSE$ ریشهٔ میانگین مربعات خطا، N_e تعداد داده‌های درنظرگرفته‌شده برای ارزیابی عملکرد مدل یادگیری، y_i^{pred} مقدار خروجی حاصل از مدل برای دادهٔ iام و y_i^{actual} مقدار خروجی واقعی مربوط به دادهٔ iام است. هرچه مقدار $RMSE$ کوچک‌تر باشد، یادگیری مدل بهتر انجام می‌شود و مقادیر خروجی آن به مقادیر واقعی نزدیک‌تر خواهد بود.

روش ارزیابی MAE به صورت زیر تعریف می‌شود:

$$MAE = \sqrt{\frac{1}{N_e}\sum_{i=1}^{N_e}\left|y_i^{pred} - y_i^{actual}\right|} \qquad (۱۸)$$

روش ارزیابی $MAPE$ به صورت زیر تعریف می‌شود:

$$MAPE = \sqrt{\frac{1}{N_e}\sum_{i=1}^{N_e}\frac{\left|y_i^{pred} - y_i^{actual}\right|}{y_i^{actual}}} \quad (۱۹)$$

ضریب تعیین (R^2) به عنوان معیاری برای سنجش میزان توضیح‌دهندگی مدل رگرسیون، به صورت زیر تعریف می‌شود [۳۰]:

$$R^2 = 1 - \frac{\sum_{i=1}^{N_e}\left(y_i^{actual} - y_i^{pred}\right)^2}{\sum_{i=1}^{N_e}\left(y_i^{actual} - \bar{y}_i^{actual}\right)^2} \quad (۲۰)$$

که در آن، $\overline{y}_i^{actual}$ میانگین مقادیر واقعی است. هرچه مقدار بالا به عدد یک نزدیک‌تر باشد، نشان‌دهندهٔ دقت زیاد مدل است. یکی از مدل‌های یادگیری عمیق در این مقاله به دسته‌بندی نقاط بهره‌برداری به دو گروه ممکن و ناممکن اختصاص دارد. عملکرد مدل دسته‌بندی علاوه بر شاخص ***Accuracy***، با استفاده از شاخص‌های ***Precision***، ***Recall*** و ***F1-score*** نیز ارزیابی می‌شود [۳۱]. شاخص ***Accuracy*** نسبت تعداد نمونه‌هایی را که به‌درستی دسته‌بندی شده‌اند به کل نمونه‌های آزمون نشان می‌دهد و از رابطهٔ (۲۱) محاسبه می‌شود:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (۲۱)$$

شاخص ***Precision*** بیانگر نسبت نمونه‌های واقعی ممکن در میان نمونه‌هایی است که توسط مدل به عنوان دادهٔ ممکن پیش‌بینی شده‌اند و به صورت زیر محاسبه می‌شود:

$$Precision = \frac{TP}{TP + FP} \quad (۲۲)$$

شاخص ***Recall*** نشان‌دهندهٔ توانایی مدل در شناسایی صحیح نمونه‌های ممکن از میان تمامی نمونه‌های واقعی امکان‌پذیر است و مطابق رابطهٔ زیر تعریف می‌شود:

$$Recall = \frac{TP}{TP + FN} \quad (۲۳)$$

به منظور ارائهٔ یک معیار ترکیبی از شاخص‌های ***Precision*** و ***Recall***، از ***F1-score*** استفاده می‌شود که برابر میانگین این دو شاخص است و به صورت زیر محاسبه می‌شود:

$$F1 - Score = \frac{2 \times (Precision \times Recall)}{Precision + Recall} \quad (۲۴)$$

در این معادلات، **TP** تعداد نمونه‌های ممکنی است که مدل به‌درستی ممکن تشخیص داده، **TN** تعداد نمونه‌های ناممکنی است که مدل به‌درستی ناممکن تشخیص داده، **FP** تعداد نمونه‌های ناممکنی است که مدل به‌اشتباه ممکن تشخیص داده و **FN** نیز تعداد نمونه‌های ممکنی است که مدل به‌اشتباه ناممکن تشخیص داده است. علاوه بر این شاخص‌ها، ماتریس درهم‌ریختگی برای نمایش تعداد نمونه‌های صحیح و خطای دسته‌بندی نیز استفاده قرار می‌شود:

$$ConfusionMatrix = \begin{bmatrix} TN & FP \\ FN & TP \end{bmatrix} \quad (۲۵)$$

در انتهای این بخش، کل فرایند مربوط به تولید داده‌ها، آموزش و ارزیابی مدل یادگیری در فلوچارت **شکل (۳)** نشان داده شده است.

ت) مدل مفسر هوشمند

در حالت کلی، مدل یادگیری عمیق فقط به صورت یک جعبه‌سیاه است که بر اساس داده‌های مختلف، آموزش داده شده است و چنانچه یک بردار ورودی از جنس داده‌های آموزشی به آن داده شود، می‌تولند نتیجه را با دقتی خوب پیش‌بینی کند. این مدل و بیشتر مدل‌های هوش مصنوعی دارای قابلیت و توانمندی تحلیل نتایج نیستند و فقط می‌توانند ارتباط بین ورودی و خروجی را شناسایی کنند و آموزش ببینند.

در این مقاله، یک مدل مفسر یا تحلیل‌گر چندسطحی هوشمند به منظور شناسایی و تحلیل ارتباط بین داده‌های مختلف یک شبکهٔ قدرت، مانند چگونگی تغییر بار عبوری از خطوط ناشی از تغییر در میزان بار شبکه یا تغییر در توان تولیدی منابع تجدیدپذیر پیشنهاد شده است. مفسر هوشمند به عنوان یک بازوی تحلیل‌گر می‌تواند با انجام تحلیل‌ها و تفسیرهای دقیق خود، به بهره‌برداران و برنامه‌ریزان سیستم‌های قدرت در زمان تصمیم‌گیری کمک کند.



شکل (۳): فلوچارت مدل یادگیری عمیق

مدل‌های مختلف مفسر هوشمند پیشنهادی در ادامه تشریح خواهند شد:

۱- مدل تحلیل حساسیت خطوط انتقال

در این حالت، مفسر هوشمند با بهره‌گیری از ماتریس ضرایب توزیع انتقال توان (**PTDF**)[۱۴] و خروجی‌های مدل یادگیری عمیق، میزان تأثیرپذیری خطوط انتقال را نسبت به تغییرات پارامترهای سیستم قدرت محاسبه می‌کند. رابطهٔ حساسیت خطوط انتقال به صورت معادلهٔ (۲۶) تعریف می‌شود:

$$S_{\ell,k} = \frac{\partial P_{\ell}}{\partial x_k} \approx \frac{\Delta P_{\ell}}{\Delta x_k} \qquad (۲۶)$$

که در آن، $S_{l,k}$ حساسیت توان عبوری از خط انتقال l نسبت به تغییرات پارامتر ورودی k است.

۲- مدل تحلیل حساسیت توان تولیدی ژنراتورهای متداول

مدل تحلیل حساسیت توان تولیدی ژنراتورهای متداول در مفسر هوشمند پیشنهادی، ارتباط بین توان خروجی ژنراتورهای متداول و تغییرات پارامترهای مختلف یک سیستم قدرت را بررسی می‌کند. رابطهٔ بین حساسیت ژنراتورها نسبت به ورودی‌های مدل یادگیری عمیق به صورت معادلهٔ (۲۷) است:

$$G_{i,k} = \frac{\partial P_{gi}}{\partial x_k} \approx \frac{\Delta P_{gi}}{\Delta x_k} \qquad (۲۷)$$

که در آن، $G_{i,k}$ حساسیت توان تولیدی ژنراتور متداول i نسبت به تغییرات پارامتر ورودی k است.

۳- مدل تعیین اهمیت‌سنجی ویژگی‌ها

به منظور کمّی‌سازی میزان تأثیر هر ویژگی ورودی (مانند بار شین‌ها و توان تولیدی منابع تجدیدپذیر) بر خروجی مدل یادگیری عمیق، از روش اهمیت‌سنجی مبتنی بر جایگشت استفاده می‌شود. در این روش، اهمیت هر ویژگی بر اساس میزان افزایش خطای مدل پس از جایگشت تصادفی مقادیر آن ویژگی تعیین می‌شود. رابطهٔ پیشنهادی اهمیت ویژگی به صورت معادلهٔ (۲۸) تعریف می‌شود:

$$K_k = RMSE(f, X) - RMSE(f, X_{\pi k}) \qquad (۲۸)$$

که در آن، K_k اهمیت ویژگی k مدل یادگیری عمیق آموزش‌دیده f و $X_{\pi k}$ ماتریس ویژگی‌ها با مقادیر ویژگی k به صورت تصادفی جایگشت‌شده و X ماتریس ویژگی‌های اصلی (شامل بار شین‌ها و توان تولیدی منابع تجدیدپذیر) است. مقدار ***RMSE*** نیز از معادلهٔ (۱۷) محاسبه می‌شود. در این تعریف، هرچه مقدار K_k بزرگ‌تر و مثبت‌تر باشد، نشان‌دهندهٔ اهمیت بیشتر ویژگی k بر پیش‌بینی‌های مدل است. در این مقاله، ***RMSE*** به عنوان تابع خطا انتخاب شده است؛ زیرا برحسب **MW** قابل تفسیر است و برای مهندسان سیستم قدرت مفهومی مستقیم‌تر دارد.

۴- مدل شناسایی عناصر بحرانی

در زمان تعیین ناحیهٔ قابل تخصیص و به هنگام تغییر مقدار بار شین‌ها و میزان توان تولیدی منابع تجدیدپذیر، برخی از عناصر شبکه مانند خطوط و ژنراتورهای متداول به عنوان عامل محدودکننده عمل می‌کنند. شناسایی این‌گونه عوامل بحرانی می‌تواند در بهینه‌سازی و توسعهٔ شبکه به بهره‌برداران و برنامه‌ریزان سیستم قدرت کمک بسیاری کند. در این مقاله، معیار بحرانی‌بودن یک عنصر به صورت معادلهٔ (۲۹) تعریف می‌شود:

$$C_j = \sum_{k=1}^{K} \omega_k . S_{j,k} \quad (۲۹)$$

که در آن، C_j شاخص بحرانی‌بودن عنصر jام، ω_k وزن اهمیت ویژگی k در تعیین میزان بحرانی‌بودن عنصر j و $S_{j,k}$ حساسیت عنصر j نسبت به ویژگی k است. برای تعیین وزن ω_k، از شاخص اهمیت ویژگی K_k تعریف‌شده در معادلهٔ (۲۸) استفاده می‌شود. به این منظور، وزن هر ویژگی به صورت نرمال‌شدهٔ اهمیت آن به صورت زیر تعریف می‌شود:

$$\omega_k = \frac{K_k}{\sum_{m=1}^{K} K_m} \quad (۳۰)$$

که در آن، K تعداد کل ویژگی‌های ورودی است. در صورت صفرشدن مجموع اهمیت‌ها، وزن‌ها به صورت یکنواخت $\omega_k=1/K$ در نظر گرفته می‌شوند. دلیل چنین انتخابی آن است که ویژگی‌هایی که مدل یادگیری عمیق به آنها وابستگی بیشتری دارد، باید سهم بیشتری در شناسایی عناصر بحرانی داشته باشند. این رویکرد داده‌محور از تخصیص وزن‌های یکنواخت جلوگیری و تحلیل بحرانی‌بودن را با رفتار واقعی مدل هماهنگ می‌کند.

ث) نحوهٔ تعیین مرزهای بالقوهٔ فعال ناحیهٔ قابل تخصیص

مدل یادگیری عمیق در این مقاله به عنوان یک جانشین برای نگاشت **OPF** عمل می‌کند و به‌جای حل مکرر مسئلهٔ پخش بار بهینه، ارتباط بین ورودی‌ها (بار شین‌ها و توان تولیدی منابع تجدیدپذیر) و خروجی‌ها (توان ژنراتورهای متداول و توان عبوری خطوط) را با سرعتی زیاد تقریب می‌زند.

فرایند استخراج ناحیهٔ قابل تخصیص از این مدل به صورت زیر است:

۱- استفاده از داده‌های تولیدشدهٔ مرتبط با تغییرات خروجی منابع تجدیدپذیر در فرایند آموزش مدل‌ها برای نمایش کل فضای ممکن و ناممکن. در هر نقطه، مقدار بار شین‌ها ثابت (یا مطابق سناریو) در نظر گرفته می‌شود.

۲- ارزیابی ممکن‌بودن با استفاده از تابع طبقه‌بندی‌کننده: بردار ورودی هر نقطه به شبکهٔ طبقه‌بندی‌کننده داده و احتمال ممکن‌بودن آن محاسبه می‌شود. اگر این احتمال از آستانهٔ مدنظر (معمولاً حدود ۰/۹) بیشتر باشد، نقطه به عنوان دادهٔ ممکن و در غیر این صورت، به عنوان دادهٔ ناممکن برچسب‌گذاری می‌شود.

۳- استخراج مرزهای بالقوهٔ ناحیه: مجموعهٔ نقاط ناممکن به الگوریتم شناسایی مرز (روش ارائه‌شده در مرجع [۳۲]) داده می‌شود تا مرز جداکنندهٔ این دو دسته استخراج شود. این مرز همان مرز ناحیهٔ قابل تخصیص است.

با تعیین مرزهای بالقوهٔ فعال، ناحیهٔ قابل تخصیص یا ممکن ژنراتورهای متداول برحسب میزان تغییرات مجاز منابع تجدیدپذیر تعیین خواهد شد.

۵- نتایج عددی

به منظور بررسی عملکرد مدل یادگیری عمیق در به دست آوردن ناحیهٔ قابل تخصیص ژنراتورهای متداول، از سیستم قدرت نمونهٔ استاندارد **IEEE 30-bus** استفاده می‌شود که اطلاعات آن در [۳۳] داده شده است. در این سیستم قدرت نمونه، دو منبع تجدیدپذیر در شین‌های ۱ و ۲۲ با تولید توان قابل پیش‌بینی هر کدام برابر **۲۰MW** در نظر گرفته شده است. تغییرات توان تولیدی این منابع نسبت به حالت پایه و برحسب **MW** به ترتیب به صورت [۲۰ و ۵-] و [۵۵ و ۱۰-] است. به منظور مقاوم‌کردن مدل یادگیری عمیق در برابر تغییرات بار شین‌ها، مقدار بار مصرفی در محدودهٔ $\pm$۱۰٪ مقدار نامی تغییر داده می‌شود. میزان تغییرات قابل قبول در توان خروجی ژنراتورهای متداول پس از ایجاد یک تغییر در خروجی منابع تجدیدپذیر برابر ۰/۳ حداکثر توان تولیدی آن در نظر گرفته شده است؛ به این معنا که توان خروجی هر کدام از ژنراتورهای متداول پس از ایجاد یک تغییر در میزان توان منابع تجدیدپذیر، فقط می‌تواند به اندازهٔ $\pm 0/3 P_g^{\max}$ تغییر یابد. تعداد کل داده‌ها برای یادگیری مدل برابر ۵۰۰۰ داده است. در این مقاله، نسبت داده‌های آموزشی به کل داده‌ها (یعنی α) برابر ۰/۸ در نظر گرفته شده است. با افزایش α (برای مثال، ۰/۹)، حجم دادهٔ آموزش بیشتر می‌شود و خطای آموزش کاهش می‌یابد، اما احتمال بیش‌برازش و افزایش خطای آزمون وجود خواهد داشت. با کاهش α (برای مثال، ۰/۷)، داده‌های آموزش کمتر و خطر کم‌برازش و افزایش $RMSE$ بیشتر می‌شود؛ بنابراین، α=۰/۸ تعادلی مناسب بین دقت و تعمیم‌پذیری برقرار می‌کند. با انتخاب این مقدار برای α، تعداد داده‌های آموزشی برابر

٤۰۰۰ داده و تعداد داده‌های مورد نیاز برای ارزیابی عملکرد مدل یادگیری نیز برابر ۱۰۰۰ داده خواهد بود. گفتنی است، از مجموع کل ۵۰۰۰ دادهٔ آموزشی، ۳۳٤۱ داده از آنها به عنوان دادهٔ ممکن و معتبر برچسب‌گذاری و ۱٦۵۹ داده نیز به عنوان دادهٔ ناممکن در نظر گرفته می‌شوند.

گفتنی است، برای تولید داده‌ها، ۵۰۰۰ سناریو با نمونه‌گیری تصادفی یکنواخت از بازه‌های مشخص با تغییر بارها و توان منابع تجدیدپذیر ایجاد شدند. از این تعداد، ۳۳٤۱ سناریو معتبر (ممکن) و ۱٦۵۹ سناریو ناممکن بودند. برای طبقه‌بندی داده‌ها، ۸۰ درصد داده‌ها (٤۰۰۰ نمونه) برای آموزش و ۲۰ درصد آنها (۱۰۰۰ نمونه) برای آزمون؛ و برای رگرسیون، از ۳۳٤۱ سناریوی معتبر، ۸۰ درصد (۲٦۷۲ نمونه) برای آموزش و ۲۰ درصد دیگر (٦٦۹ نمونه) برای آزمون استفاده شد.

شبکهٔ طبقه‌بندی امکان‌پذیری با ۸۰ درصد از کل ۵۰۰۰ سناریو (٤۰۰۰ نمونه، شامل هر دو دستهٔ ممکن و ناممکن) آموزش دیده و ۲۰ درصد باقی‌مانده (۱۰۰۰ نمونه) برای آزمون استفاده شده است. شبکه‌های رگرسیون نیز با ۸۰ درصد از ۳۳٤۱ نمونهٔ ممکن (۲٦۷۲ نمونه) آموزش دیده و ۲۰ درصد باقی‌ملانده (٦٦۹ نمونه) برای آزمون به کار رفته‌لند. نمونه‌های ناممکن در آموزش شبکه‌های رگرسیون استفاده نمی‌شوند.

در این مسئله، تعداد متغیرهای ورودی در قسمت تهیهٔ داده‌های آموزشی برابر مجموع تعداد شین‌های دارای بار (۲۰ شین) و منابع تجدیدپذیر (۲ واحد) است که در مجموع، ۲۲ متغیر ورودی هستند و تعداد متغیرهای خروجی شامل ژنراتورهای متداول (٦ ژنراتور) و توان عبوری از خطوط (٤۱ خط) است که در مجموع، ٤۷ متغیر خروجی وجود دارند. پس از آموزش مدل و در قسمت تعیین مقادیر خروجی ژنراتورهای متداول و توان عبوری از خطوط، ورودی مدل برابر مقدار خروجی منابع تجدیدپذیر و بار شین‌های سیستم قدرت است. تعداد لایه‌های پنهان درنظرگرفته‌شده برای آموزش مدل برابر ۲ لایه با تعداد ۱۵ متغیر در هر لایه است. برای آموزش مدل یادگیری عمیق از جعبه‌ابزار یادگیری عمیق موجود در نرم‌افزار متلب مانند **patternnet**، **fitnet** و **feedforwardnet** استفاده شده است. لازم به توضیح اینکه در این مقاله، عبارت «یادگیری عمیق» برای یک شبکهٔ عصبی پیش‌خور چندلایه با دو لایهٔ پنهان به کار رفته است. هرچند این معماری در مقایسه با دیگر شبکه‌های عمیق بزرگ فشرده به نظر می‌رسد، از نظر مفهومی، وجود بیش از یک لایهٔ پنهان غیرخطی که به صورت سرتاسری با الگوریتم پس‌انتشار آموزش می‌بیند، آن را در دستهٔ شبکه‌های عصبی عمیق قرار می‌دهد. تفاوت اصلی آن با یک **MLP** ساده (تک‌لایهٔ پنهان) در توانایی یادگیری نگاشت‌های غیرخطی سلسله‌مراتبی و پیچیده‌تر است. در این مطالعه، سه شبکهٔ مجزا برای طبقه‌بندی امکان‌پذیری، رگرسیون توان ژنراتورها و رگرسیون توان عبوری از خطوط آموزش داده شده‌اند. انتخاب تعداد لایه‌ها و نورون‌ها بر اساس آزمون و خطا و معیار ***RMSE*** انجام شده است؛ به گونه‌ای که افزایش عمق بیشتر بهبودی معنادار در دقت ایجاد نمی‌کند و فقط موجب افزایش زمان آموزش می‌شود. همچنین، برای مقایسه، یک شبکه با یک لایهٔ پنهان نیز آزموده شد که دقت کمتری در پیش‌بینی توان ژنراتورها و خطوط داشت؛ بنابراین، کاربرد عبارت یادگیری عمیق در اینجا به معنای عام و در مقابل مدل‌های خطی و شبکه‌های تک‌لایه است.

تمامی شبیه‌سازی‌ها با استفاده از یک کامپیوتر شخصی با مشخصات Pentium® Dual-Core E5200, 2.5 GHz و حافظهٔ **2.00 GB** و با استفاده از نرم‌افزار **MATLAB R2014a** انجام شده است.

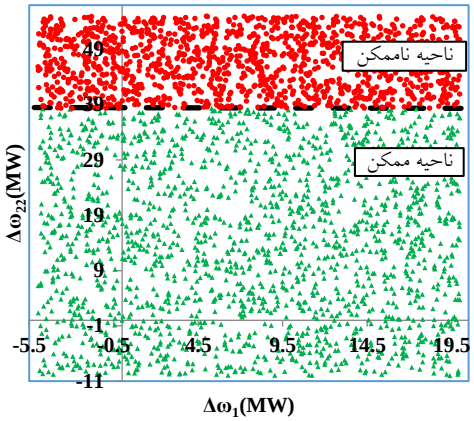
الف) تعیین ناحیهٔ قابل تخصیص

پس از آموزش کامل مدل یادگیری عمیق، داده‌های ورودی به صورت شکل(٤) دسته‌بندی می‌شوند که نشان‌دهندهٔ دسته‌بندی کامل داده‌ها به عنوان داده‌های قابل تخصیص و غیرقابل تخصیص است. در این شکل، داده‌های ناممکن در قسمت بالا و داده‌های ممکن در قسمت پایین آن ترسیم شده‌اند و به وسیلهٔ یک مرز به صورت خط‌چین از همدیگر جدا شده‌اند. محور افقی در(شکل ٤) نشان‌دهندهٔ تغییرات توان تولیدشده توسط منبع تجدیدپذیر موجود در شین شمارهٔ ۱ سیستم قدرت نمونه و محور عمودی نیز نشان‌دهندهٔ تغییرات توان تولیدشده توسط منبع تجدیدپذیر موجود در شین شمارهٔ ۲۲ است.

برخلاف روش‌های قبلی (تحلیلی ریاضی و داده‌محور)، مشاهده می‌شود نیازی به حل کامل مسئلهٔ تعیین ناحیهٔ قابل تخصیص نیست و فقط کافی است با استفاده از داده‌های آموزشی، مدل یادگیری عمیق آموزش داده شود و مقدار توان خروجی ژنراتورهای متداول را برای نقطهٔ کار جدید در

سریع‌ترین زمان ممکن به دست آورد.

به منظور ارزیابی عملکرد مدل یادگیری عمیق پیشنهادی در این مقاله، از ابزارهایی مختلف مانند شاخص ریشهٔ میانگین مربعات خطا (***RMSE***) و همچنین مقایسهٔ توان تولیدی توسط ژنراتورهای متداول (خروجی‌های مدل یادگیری عمیق) استفاده می‌شود. نتایج مقایسهٔ روش دقیق و مدل یادگیری عمیق به‌ازای مقادیر مختلف بار شین‌ها و خروجی متغیر منابع تجدیدپذیر در جدول (۱) تا جدول (۳) نشان داده شده است.



شکل (٤): تعیین ناحیهٔ قابل تخصیص با استفاده از مدل یادگیری عمیق برای سیستم قدرت نمونه

جدول (۱): مقایسهٔ خروجی‌های روش واقعی و روش پیش‌بینی‌شده توسط مدل یادگیری عمیق (ضریب بار ۰/۹۵)

(ΔW_1, ΔW_{22})						
MW	(۵- و ۵-)		(۰ و ۰)		(۱۰ و ۱۰)	
-	روش یادگیری	روش واقعی	روش یادگیری	روش واقعی	روش یادگیری	روش واقعی
Pg1	۳۸/٦۲۷	۳۸/٦۲۲	۳۷/۰۷۳	۳۷/۰۷۵	۳۳/۹۸۵	۳۳/۹۷۹
Pg2	۵۱/۲۸۸	۵۱/۲۸۳	٤۹/۵۱۳	٤۹/۵۱٤	٤۵/۹۸۳	٤۵/۹۷٦
Pg22	۲۰/۳٦۲	۲۰/۳۵۹	۱۹/۸٦۵	۱۹/۸٦٤	۱۸/۸۷٦	۱۸/۸۷۳
Pg27	۱۷/٦۸۰	۱۷/٦۸۰	۱۳/۹٦۳	۱۸/۹٦۸	٦/۵٤۹	٦/۵٤۵
Pg23	۱۰/۸۹۷	۱۰/۸۹۸	۹/٦۵۸	۹/٦٦۰	۷/۱۸٤	۷/۱۸۳
Pg13	۱۰/۹۰۱	۱۰/۸۹۸	۹/٦۵۹	۹/٦٦۰	۷/۱۸۷	۷/۱۸۳

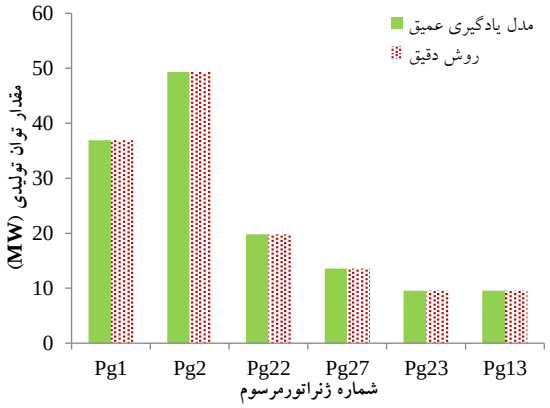
جدول (۲): مقایسهٔ خروجی‌های روش واقعی و روش پیش‌بینی‌شده توسط مدل یادگیری عمیق (ضریب بار ۱/۰)

(ΔW_1, ΔW_{22})						
MW	(۵- و ۵-)		(۰ و ۰)		(۱۰ و ۱۰)	
-	روش یادگیری	روش واقعی	روش یادگیری	روش واقعی	روش یادگیری	روش واقعی
Pg1	٤۰/۰۸۱	٤۰/۰۸۷	۳۸/۵٤۱	۳۸/۵۳۹	۳۵/٤٤۵	۳۵/٤٤۳
Pg2	۵۲/۹٤۹	۵۲/۹۵٦	۵۱/۱۹۰	۵۱/۱۸۷	٤۷/٦۵۱	٤۷/٦۵۰
Pg22	۲۰/۸۲٤	۲۰/۸۲۸	۲۰/۳۳۵	۲۰/۳۳۲	۱۹/۳۳۹	۱۹/۳٤۲
Pg27	۲۱/۱۸٦	۲۱/۱۹۱	۱۷/٤۸۰	۱۷/٤۷۹	۱۰/۰۵٤	۱۰/۰۵٦
Pg23	۱۲/۰٦۸	۱۲/۰٦۹	۱۰/۸۳۱	۱۰/۸۳۱	۸/۳۵٤	۸/۳۵۵
Pg13	۱۲/۰٦۵	۱۲/۰٦۹	۱۰/۸۳۳	۱۰/۸۳۱	۸/۳۵۵	۸/۳۵۵

جدول (۳): مقایسهٔ خروجی‌های روش واقعی و روش پیش‌بینی‌شده توسط مدل یادگیری عمیق (ضریب بار ۱/۰۵)

$(\Delta W_1, \Delta W_{22})$						
MW	(۵- و ۵-)		(۰ و ۰)		(۱۰ و ۱۰)	
-	روش یادگیری	روش واقعی	روش یادگیری	روش واقعی	روش یادگیری	روش واقعی
Pg1	٤١/٥٢١	٤١/٥٥١	٤٠/٠٠٣	٤٠/٠٠٣	٣٦/٩٠٥	٣٦/٩٠٨
Pg2	٥٤/٥٩٥	٥٤/٦٢٩	٥٢/٨٦٠	٥٢/٨٦١	٤٩/٣٢١	٤٩/٣٢٣
Pg22	٢١/٢٨٤	٢١/٢٩٦	٢٠/٨٠٢	٢٠/٨٠١	١٩/٨٠٧	١٩/٨١٠
Pg27	٢٤/٦٣٥	٢٤/٧٠٢	٢٠/٩٧٣	٢٠/٩٩١	١٣/٥٨٣	١٣/٥٦٧
Pg23	١٣/٢١٨	١٣/٢٤١	١١/٩٩٦	١٢/٠٠٢	٩/٥٣٢	٩/٥٢٦
Pg13	١٣/٢١٧	١٣/٢٤١	١٢/٠٠١	١٢/٠٠٢	٩/٥٢٦	٩/٥٢٦

به منظور مقایسهٔ بهتر نتایج حاصل از روش دقیق و روش پیشنهادی یادگیری عمیق در این مقاله، توان تولیدی توسط ژنراتورهای متداول به‌ازای ضریب بار ۱/۰۵ و تغییرات **MW** ۱۰ در هر کدام از منابع تجدیدپذیر در **شکل (۵)** نشان داده شده است که نشان‌دهندهٔ دقت بسیار زیاد روش پیشنهادی نسبت به روش دقیق است. با مشاهدهٔ جدول (۱) تا جدول (۳)، می‌توان دریافت نتایج حاصل از روش حل دقیق و روش یادگیری عمیق پیشنهادی در این مقاله با دقتی بسیار خوب مشابه هستند.



شکل (۵): نمایش دقت روش پیشنهادی یادگیری عمیق نسبت به روش دقیق در تعیین خروجی ژنراتورهای متداول سیستم قدرت نمونه

شاخص‌های ارزیابی مدل‌های طبقه‌بندی و رگرسیون به صورت جامع در **جدول (٤)** نشان داده شده است. برای شبکهٔ طبقه‌بندی امکان‌پذیری، شاخص **Accuracy** برابر ۹۸/۹۰ درصد، **Precision** برابر ۹۹/۰۸ درصد، ***Recall*** برابر ۹۹/٤۷ درصد و ***F1-score*** برابر ۹۹/۲۸ درصد به دست آمده است که بیانگر توانایی زیاد مدل در تفکیک دقیق نقاط ممکن از ناممکن است. در بخش رگرسیون ژنراتورهای متداول، ***RMSE*** برابر ۰/۰۱۵۳ مگاوات، ***MAE*** برابر ۰/۰۰۸۵ مگاوات، ***MAPE*** برابر ۰/۱۰ درصد و ضریب تعیین R^2 برابر ۱/۰۰ است که تأییدکنندهٔ دقت بسیار زیاد مدل در پیش‌بینی توان تولیدی ژنراتورهاست. برای خطوط انتقال نیز، ***RMSE*** برابر ۰/۲۲۹۷ مگاولت‌آمپر، ***MAE*** برابر ۰/۱٦۹۰ مگاولت‌آمپر و R^2 برابر ۰/۹۹۹٤ به دست آمده است. مقدار ***MAPE*** برای خطوط ۱۹/٦۸ درصد است که عمدتاً ناشی از خطوطی با توان عبوری نزدیک به صفر است؛ زیرا در این شرایط، کوچک‌ترین خطا به درصد خطای بزرگ منجر می‌شود؛ بنابراین، *معیارهای* ***MAE*** و R^2 را می‌توان برای خطوط در نظر گرفت. به طور کلی، نتایج **جدول (٤)** نشان می‌دهد مدل پیشنهادی با دقت بسیار زیاد و بدون نیاز به حل مستقیم مسئلهٔ پخش بار، قادر است توان تولیدی ژنراتورهای متداول و توان عبوری خطوط را پیش‌بینی کند. این ویژگی به ویژه برای سیستم‌های قدرت بزرگ‌مقیاس که حل مکرر پخش بار زمان‌بر است، مزیت عملیاتی قابل ملاحظه‌ای محسوب می‌شود.

علاوه بر تعیین و تحلیل شاخص‌های بالا، تحلیل نقض قیود بر روی ٦٦۹ نمونه آزمون نشان داد میانگین خطای توازن توان **MW** ۰/۰۱۲٦ و حداکثر آن **MW** ۰/۰۷٥٤ است (هیچ نمونه‌ای با خطای بیش از **MW** ۰/۱ شناسایی نشد). نقض

حدود ژنراتورها ۰ درصد و حداکثر نقض محدودیت خطوط **MVA** ۰/۵۳۸ است که در مقابل ظرفیت خطوط بسیار ناچیز است؛ بنابراین، خروجی‌های مدل از نظر امکان‌پذیربودن قابل اعتماد هستند و تابع طبقه‌بندی‌کنندهٔ امکان‌پذیری نیز با دقت زیاد نقاط ناممکن را شناسایی می‌کند.

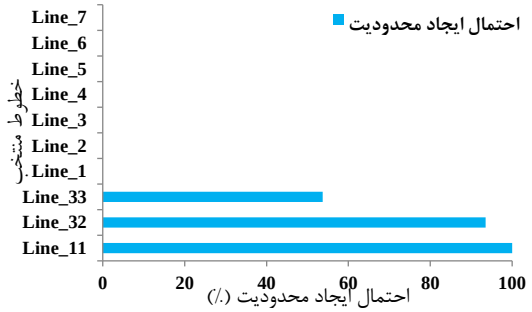
ب) استفاده از مفسر هوشمند برای تحلیل مدل یادگیری

در این بخش از مقاله، با استفاده از مفسر هوشمند پیشنهادی، عملکرد سیستم قدرت نمونه تحلیل می‌شود. نتایج حاصل از تحلیل مفسر هوشمند بر روی حساسیت توان عبوری از خطوط نسبت به تغییرات بار شین‌ها و توان تولیدی توسط منابع تجدیدپذیر در **شکل** (٦) نشان داده شده است.

با تأمل در **شکل** (٦)، می‌توان دریافت بیشترین احتمال ایجاد محدودیت در ناحیهٔ قابل تخصیص مربوط به سه خط با شماره‌های ۱۱، ۳۲ و ۳۳ است که عمدتاً به دلیل مجاورت با شین ۲۲ و همچنین بارهای سنگین است. دو خط ۳۲ و ۳۳، هر دو به شین شمارهٔ ۲۲ متصل هستند که تغییرات توان تزریقی منبع تجدیدپذیر در این شین بیشترین تأثیر را بر روی میزان پرشدگی این دو خط خواهد داشت. خط شمارهٔ ۱۱ (بین دو شین ٦ و ۸) نیز یکی از مسیرهای اصلی انتقال توان از شین ۲۲ به دیگر شین‌های شبکه با بار سنگین است. عامل محدودکننده در سیستم قدرت نمونهٔ داده‌شده، خط شمارهٔ ۳۲ است که بین دو شین ۲۱ و ۲۲ قرار دارد و دارای ظرفیت حرارتی محدودی به اندازهٔ **MVA** ۳۲ است. این مورد از طریق ضرایب **PTDF** نیز قابل تشخیص است؛ زیرا این خط دارای بیشترین ضریب **PTDF** نسبت به توان تزریقی به شین ۲۲ است. در صورت تزریق توان بیش از حدود **MW** ۵۸ توسط منبع تجدیدپذیر نصب‌شده در شین شمارهٔ ۲۲ (**MW** ۲۰ مقدار اولیهٔ تولید به علاوهٔ **MW** ۳۸ مگاوات تغییرات در مقدار آن)، میزان توان عبوری از خط شمارهٔ ۳۲ از ظرفیت آن فراتر می‌رود و دچار اضافه بار خواهد شد. به عملیات به دست آوردن نواحی ممکن و ناممکن، تعیین ناحیهٔ قابل تخصیص گفته می‌شود؛ بنابراین، تفسیر و تحلیل مفسر هوشمند در تعیین خطوط محدودکننده بسیار دقیق است.

جدول (٤): شاخص‌های ارزیابی مدل‌های رگرسیون و طبقه‌بندی

نوع مدل	شاخص	واحد	مقدار
طبقه‌بندی امکان‌پذیری	*Accuracy*	٪	۹۸/۹۰
	Precision	٪	۹۹/۰۸
	Recall	٪	۹۹/٤۷
	F1-score	٪	۹۹/۲۸
رگرسیون ژنراتورها	*RMSE*	MW	۰/۰۱۵۳
	MAE	MW	۰/۰۰۸۵
	MAPE	٪	۰/۱۰
	R^2	-	۱/۰۰
رگرسیون خطوط	*RMSE*	MVA	۰/۲۲۹۷
	MAE	MVA	۰/۱٦۹۰
	MAPE	٪	۱۹/٦۸
	R^2	-	۰/۹۹۹٤

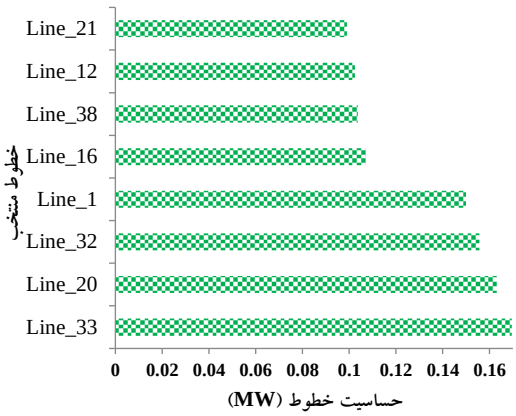


شکل (٦): نمایش میزان احتمال ایجاد محدودیت توسط خطوط منتخب ناشی از تغییرات بار و توان منابع تجدیدپذیر

در **شکل** (۷)، خطوط با بیشترین حساسیت نسبت به تغییرات توان تزریقی توسط منابع تجدیدپذیر نمایش داده شده که به وسیلهٔ مفسر هوشمند استخراج شده است. اعداد نشان‌داده‌شده در این شکل نشان‌دهندهٔ میزان تغییرات توان عبوری از خطوط به‌ازای تغییر **MW** ۱ در توان تولیدی منابع تجدیدپذیر است. مطابق شکل (۷)، بیشترین ضریب حساسیت خطوط نسبت به تزریق توان توسط منابع تجدیدپذیر مربوط به سه خط با شماره‌های ۳۳، ۲۰ و ۳۲ است که عمدتاً به دلیل مجاورت با شین ۲۲ است. دو خط ۳۲ و ۳۳، هر دو به شین شمارهٔ ۲۲ متصل هستند که تغییرات توان تزریقی منبع تجدیدپذیر در این شین بیشترین تأثیر را بر روی میزان بار عبوری این دو خط خواهد داشت. خط شمارهٔ ۲۰ (بین دو شین ۱۰ و۲۱) نیز به صورت موازی با خط شمارهٔ ۳۲ قرار دارد که تحت تأثیر توان تزریقی به شین ۲۲ قرار می‌گیرد.

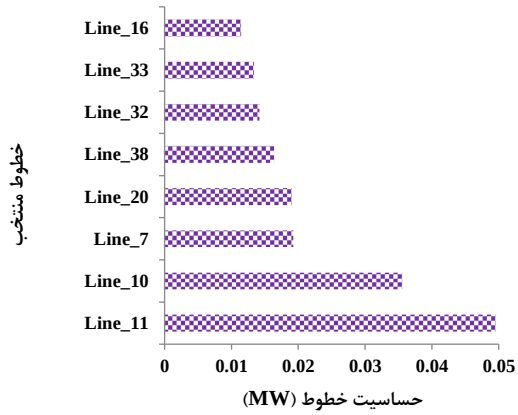
با استفاده از این شکل می‌توان عامل محدودکننده را

به‌خوبی شناسایی و نسبت به برطرف‌کردن این محدودیت از طریق احداث خط جدید یا تعویض هادی موجود با هادی پرظرفیت اقدام کرد. خروجی این مدل می‌تولند به بهره‌برداران و برنامه‌ریزان سیستم قدرت در مکان‌یابی منابع تجدیدپذیر در شبکه با توجه به تاب‌آوری عناصر آن کمک کند.



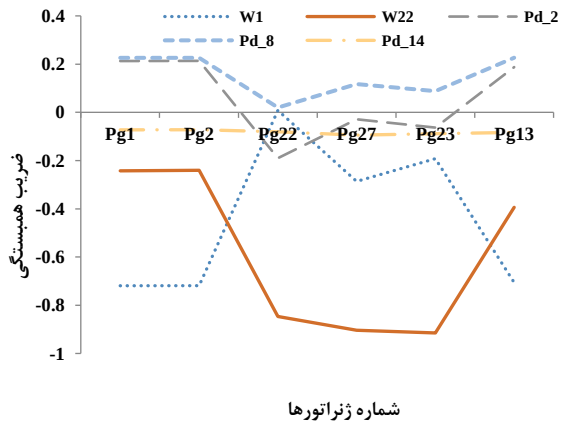
شکل (۷): نمایش میزان حساسیت خطوط منتخب نسبت به تغییرات توان منابع تجدیدپذیر

مشابه همین موضوع، حساسیت توان عبوری از خطوط نسبت به تغییرات بار در شین‌های بار سیستم قدرت نمونه محاسبه و در **شکل (۸)** نشان داده شده است. از **شکل (۸)** می‌توان دریافت خطوط شمارهٔ ۱۱، ۱۰ و ۷ نیز دارای حساسیت زیادی نسبت به تغییرات بار هستند و در صورت تغییرات بار می‌توانند عامل محدودیت در شبکه باشند. عمدهٔ حساسیت این خطوط نسبت به تغییرات بار به دلیل قرارگیری آنها در مسیر تبادلی ناحیهٔ جنوب با شمال شبکه (خطوط شمارهٔ ۱۰ و ۱۱) یا مجاورت با بارهای سنگین (خط شمارهٔ ۷ در مجاورت بار شین ۷) است.



شکل (۸): نمایش میزان حساسیت خطوط منتخب نسبت به تغییرات بار شین‌ها

شکل (۹) ضرایب همبستگی بین بارهای منتخب و منابع تجدیدپذیر را با توان تولیدی ژنراتورهای متداول نشان می‌دهد. در این شکل، مقادیر واقعی ضرایب همبستگی (با علامت) ترسیم شده‌اند؛ زیرا علامت ضریب همبستگی اطلاعاتی مهم دربارهٔ جهت رابطه ارائه می‌دهد. ضریب همبستگی منفی به معنای رابطهٔ معکوس است؛ یعنی با افزایش یک متغیر (مانند توان تولیدی منبع تجدیدپذیر یا بار)، توان تولیدی ژنراتور مدنظر کاهش می‌یابد. برای نمونه، منبع بادی ω_{22} دارای همبستگی منفی قوی با ژنراتورهای Pg_{22} و Pg_{27} (ضریب همبستگی به ترتیب حدود ۰/۸۵- و ۰/۹۱-) است که نشان می‌دهد با افزایش تولید توان تجدیدپذیر در شین ۲۲، توان تولیدی این ژنراتورها به دلیل اولویت اقتصادی منابع تجدیدپذیر کاهش می‌یابد. همچنین، بارهای Pd_2 و Pd_8 با ژنراتورهای Pg_1 و Pg_2 همبستگی مثبت (حدود ۰/۲) دارند؛ یعنی افزایش این بارها به افزایش تولید این ژنراتورها منجر می‌شود. در مقابل، بار Pd_2 با Pg_{22} و Pg_{27} همبستگی منفی دارد. این نتایج به بهره‌برداران کمک می‌کند تا اثر تغییرات بار و منابع تجدیدپذیر را بر هر ژنراتور به صورت کمّی ارزیابی کنند. گفتنی است، در نسخهٔ قبلی، قدر مطلق ضرایب نمایش داده شده بود که جهت رابطه را پنهان می‌کرد؛ در نسخهٔ اصلاحی، مقادیر واقعی با علامت ارائه شده‌اند تا تفسیری دقیق‌تر امکان‌پذیر باشد.



شکل (۹): نمایش میزان همبستگی بارهای منتخب و منابع تجدیدپذیر نسبت به تغییرات توان ژنراتورهای متداول

یکی دیگر از مزایای روش‌های مبتنی بر یادگیری عمیق، در صورت آموزش کامل و جامع آنها، کاهش زمان محاسبات تعیین خروجی ژنراتورهای متداول پس از هر تغییر در خروجی منابع تجدیدپذیر یا بار شبکه است. در سیستم قدرت ۳۰شینهٔ استاندارد، زمان مورد نیاز برای اجرای یک پخش بار بهینهٔ **DC** پس از هر گونه تغییر در تولید منابع تجدیدپذیر و بارهای شبکه حدود ۲۲۵ میلی‌ثانیه است؛ در حالی که با استفاده از مدل یادگیری عمیق آموزش‌دیده، این زمان به حدود ۳۸ میلی‌ثانیه کاهش می‌یابد. به عبارت دیگر، برای سیستم مورد مطالعه، استفاده از مدل آموزش‌دیده باعث بهبود زمان تا حدود ۸۳ درصد و افزایش سرعت حدود ٦ برابر می‌شود. زمان مورد نیاز برای تعیین کل ناحیهٔ قابل تخصیص با مدل‌های آموزش‌دیده نیز حدود ۲/۰٤ ثانیه است. به منظور بررسی مقیاس‌پذیری روش پیشنهادی، شبکهٔ ۱۱۸شینه **IEEE** با دو منبع تجدیدپذیر در شین‌های ٤۹ و ۷۲ در نظر گرفته می‌شود. مقدار تولید پیش‌بینی‌شدهٔ این دو منبع به ترتیب برابر **MW** ۱۲۰ و **MW** ۱۷۰ فرض می‌شود و تغییرات توان آنها نیز به ترتیب به صورت [۲۰ و ۵-] و [۵۵ و ۱۰-] برحسب **MW** است و تغییرات بار شین‌ها نیز در محدودهٔ ۱۰٪± مقدار نامی تغییر داده می‌شود. با انجام محاسبات مشابه برای شبکهٔ ۱۱۸شینه، زمان اجرای **DC-OPF** و زمان مورد نیاز برای پیش‌بینی خروجی‌ها با استفاده از مدل آموزش‌دیدهٔ یادگیری عمیق به ترتیب برابر ۳٤۰ و ٤۵ میلی‌ثانیه به دست می‌آید. برای چنین سیستمی، استفاده از مدل آموزش‌دیده باعث بهبود زمان تا حدود ۹۷/۸ درصد و افزایش سرعت حدود ۷/٦ برابر می‌شود که نشان از مقیاس‌پذیری روش یادشده است. چنین مزیتی فقط زمانی حاصل خواهد شد که مدل‌های یادگیری عمیق به‌خوبی آموزش دیده و در برابر تغییرات پارامترهای شبکه مقاوم شده باشند؛ در غیر این صورت، زمان تولید داده و آموزش مدل‌ها با حفظ دقت مناسب قابل ملاحظه خواهد بود. **جدول (۵)** مقایسهٔ عملکرد زمانی روش‌های مختلف تعیین ناحیهٔ قابل تخصیص ژنراتورهای متداول را نشان می‌دهد.

جدول (۵): مقایسهٔ عملکرد زمانی مدل مبتنی بر یادگیری عمیق با الگوریتم‌های پیشین در تعیین ناحیهٔ قابل تخصیص ژنراتورهای متداول

الگوریتم	روش اجرایی	زمان اجرای محاسبات (ثانیه)	
		۳۰شینه	۱۱۸شینه
الگوریتم پیشنهادی این مقاله	مدل یادگیری عمیق – ۵۰۰۰ داده (کل فرایند تولید داده، آموزش مدل‌ها و ارزیابی)	۸٤۲/۱٤	۱۲٤۹/٦۵
	مدل یادگیری عمیق آموزش‌دیده (زمان پیش‌بینی)	۲/۰۸	۲/۰۹
الگوریتم مرجع [۳۲]	داده‌محور با الگوریتم دسته‌بندی–۵۰۰ داده	۳/۰۹	۱۰/۵۸
الگوریتم مرجع [۱۲]	داده‌محور بدون الگوریتم دسته‌بندی –۵۰۰ داده	۸/۳۱	۲۹/۳۸

با تأمل در **جدول (۵)** و مقایسهٔ زمان‌های مورد نیاز برای تعیین ناحیهٔ قابل تخصیص، می‌توان موارد زیر را استخراج کرد:

- از آنجا که در روش مبتنی بر یادگیری عمیق برای دست‌یابی به دقت مناسب، به تولید داده‌های انبوه نیاز است، فرایند تولید داده، آموزش مدل‌ها و ارزیابی آنها نسبت به دیگر روش‌ها زمان‌بر و در مقایسه با روش‌های داده‌محور قابل ملاحظه است.
- در صورتی که مدل به‌خوبی آموزش دیده و در برابر تغییرات پارامترهای شبکه مقاوم شده باشد، زمان تعیین ناحیهٔ قابل تخصیص ژنراتورهای متداول در مقایسه با دیگر روش‌ها به طرزی چشمگیر کاهش می‌یابد.

برای شناسایی هم‌زمان خطوطی که هم به مرز ظرفیت نزدیک می‌شوند و هم به تغییرات بار و تولید تجدیدپذیر حساس هستند، یک شاخص بحرانی ترکیبی به صورت $C_j = ۰/۵\tilde{P}_{cp,j} + ۰/۵\tilde{S}_j$ تعریف می‌شود که در آن، $\tilde{P}_{cp,j}$ مقدار نرمال‌شدهٔ احتمال محدودیت و $\tilde{S}_j$ مقدار نرمال‌شدهٔ مجموع حساسیت خط j به همهٔ ویژگی‌ها است. **شکل (۱۰)** این شاخص را برای هشت خط بحرانی نشان می‌دهد و **جدول (٦)** مقادیر تفصیلی آن را ارائه می‌کند. همان‌طور که مشاهده می‌شود، خطوط ۳۲، ۳۳ و ۱۱ بالاترین شاخص ترکیبی را دارند. خط ۳۲ با احتمال محدودیت زیاد (۹۳/۵ درصد) و

حساسیت زیاد به منبع تجدیدپذیر شین ۲۲، بحرانی‌ترین خط شبکه محسوب می‌شود. خط ۳۳ با بیشترین حساسیت نسبت به منبع تجدیدپذیر موجود در شین ۲۲ در رتبهٔ دوم قرار دارد. خط ۱۱ با احتمال محدودیت ۱۰۰ درصد، اما داشتن حساسیت کم، نشان می‌دهد احتمال محدودیت زیاد لزوماً به معنای حساسیت زیاد نیست. همچنین، خطوط ۳۸، ۲۰، ۱ و ۱٤ نیز به دلیل حساسیت زیاد نسبت به تغییرات بار و تغییرات توان منابع تجدیدپذیر در رتبه‌های بعدی قرار می‌گیرند.

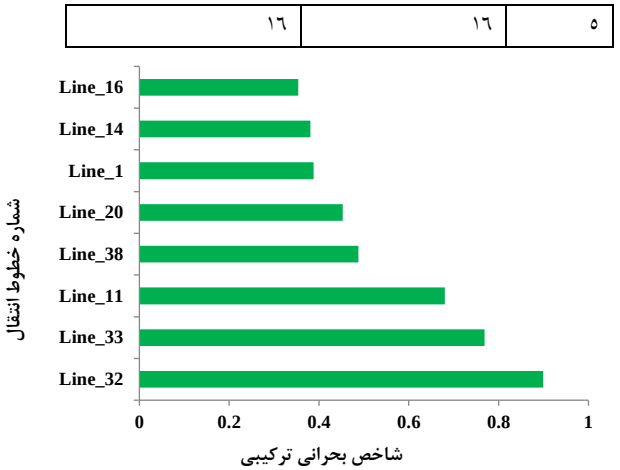
برای تفکیک سهم مفسر هوشمند از تحلیل فیزیکی خطی، ۵ خط اول بحرانی با استفاده از **XAI** و **PTDF** استخراج و در **جدول** (۷) مقایسه شده‌اند. هم‌پوشانی ٦۰ درصد (۳ خط از ۵ خط: خطوط ۲۰، ۱٦ و ۳۲) وجود دارد؛ با این حال، خطوط منحصربه‌فرد **XAI** (خطوط ۳۳ و ۳۸) دارای میانگین احتمال محدودیت ۲٦/۸۸ درصد هستند، در حالی که خطوط منحصربه‌فرد **PTDF** (خطوط ۱ و ۱۲) دارای احتمال محدودیت ۰ درصد هستند. این یافته نشان می‌دهد **XAI**، علاوه بر بازتولید حساسیت‌های خطی، قادر است خطوط بحرانی ناشی از اثرات غیرخطی بار و تولید تجدیدپذیر را نیز شناسایی و اطلاعات اضافی فراتر از **PTDF** ارائه کند.

جدول (٦): مقادیر تفصیلی شاخص بحرانی ترکیبی

خط	احتمال محدودیت (٪)	مجموع حساسیت **(MW)**	شاخص ترکیبی C_j
۳۲	۹۳/۵	۰/۲۳	۰/۹۰
۳۳	۵۳/۷٦	۰/۲٦	۰/۷۷
۱۱	۱۰۰	۰/۰۹	۰/٦۸
۳۸	۰	۰/۲٦	۰/٤۵
۲۰	۰	۰/۲٤	۰/٤۵
۱	۰	۰/۲۱	۰/۳۹
۱٤	۰	۰/۲۰	۰/۳۸
۱٦	۰	۰/۱۹	۰/۳۵

جدول (۷): مقایسهٔ ۵ خط اول بحرانی **XAI** و **PTDF**

رتبه	خط بحرانی شناسایی‌شده با **XAI**	خط بحرانی شناسایی‌شده با **PTDF**
۱	۳۳	۱
۲	۲۰	۲۰
۳	۳۲	۳۲
٤	۳۸	۱۲



شکل (۱۰): شاخص بحرانی ترکیبی خطوط انتقال بر اساس ترکیب نرمال‌شدهٔ احتمال محدودیت و مجموع حساسیت به تغییرات بار و تولید تجدیدپذیر

۶- نتیجه‌گیری

در این مقاله، ابتدا چالش‌های ناشی از افزایش نرخ نفوذپذیری منابع تجدیدپذیر در سیستم‌های قدرت بررسی شدند و سپس، ضرورت‌های تعیین ناحیهٔ قابل تخصیص به منظور جلوگیری از نقض محدودیت‌های سیستم قدرت در نتیجهٔ تزریق بیش از حد توان توسط این منابع تبیین شد. با توجه به پیچیدگی حل مسئلهٔ تعیین ناحیهٔ قابل تخصیص با روش‌های تحلیلی ریاضی و داده‌محور، از روش‌های مبتنی بر هوش مصنوعی مانند یادگیری عمیق استفاده شد. روش یادگیری عمیق به واسطهٔ مزایایی مانند سرعت زیاد، دقت مناسب و مقاوم‌بودن در برابر تغییرات بار، می‌تولند کاربردی چشمگیر در تعیین نواحی قابل تخصیص داشته باشد.

به منظور افزایش کارآمدی مدل یادگیری عمیق، یک مفسر هوشمند برای تحلیل داده‌های مدل یادگیری به کار گرفته شد. مفسر پیشنهادی به عنوان یک تحلیل‌گر هوشمند عمل و با تحلیل داده‌های مدل یادگیری عمیق، رفتار و حساسیت عناصر سیستم قدرت را نسبت به تغییرات بار شین‌ها و توان تزریقی توسط منابع تجدیدپذیر تعیین و عناصر محدودکننده را به‌خوبی شناسایی می‌کند. نتایج عددی شبیه‌سازی بر روی سیستم قدرت نمونهٔ استاندارد این موارد را تأیید کرد و نشان داد نتایج روش دقیق و روش یادگیری عمیق بسیار نزدیک به یکدیگر هستند. با توجه به زمان لازم برای پیش‌بینی خروجی ژنراتورهای متداول، روش پیشنهادی و تحلیل‌های ارائه‌شده

توسط مفسر هوشمند آن می‌تواند گزینه‌ای مناسب برای حل مسائل پخش بار و تعیین نواحی قابل تخصیص در سیستم‌های قدرت بزرگ‌مقیاس به صورت زمان–واقعی باشد.

گفتنی است، روش پیشنهادی این مقاله مبتنی بر **DC-OPF** است و محدودیت‌های ولتاژ، توان راکتیو و تلفات شبکه را در نظر نمی‌گیرد. این محدودیت‌ها می‌توانند مرز ناحیهٔ قابل تخصیص را تحت تأثیر قرار دهند؛ بنابراین، کاربرد روش حاضر به سیستم‌هایی محدود می‌شود که تقریب **DC** در آنها قابل قبول باشد. تعمیم روش به چارچوب **AC-OPF** به عنوان کار آینده پیشنهاد می‌شود. در این راستا، ساختار مدل یادگیری عمیق و مفسر هوشمند قابل تعمیم است و نیازمند تولید داده‌های آموزشی **AC-OPF**، آموزش مجدد شبکه‌ها و لحاظ‌کردن متغیرهای ولتاژ و توان راکتیو در ورودی‌ها و خروجی‌های مدل خواهد بود.

مراجع

[1] M. Mishra, J. G. Singh, “A comprehensive review on deep learning techniques in power system protection: Trends, challenges, applications and future directions”, Results in Engineering, pp. 103884, 2025. https://doi.org/10.1016/j.rineng.2024.103884

[2] S. Islam, N. K. Roy, “Renewables integration into power systems through intelligent techniques: Implementation procedures, key features, and performance evaluation”, Energy Reports, Vol. 9, pp. 6063-6087, 2023. https://doi.org/10.1016/j.egyr.2023.05.063

[3] W. Wei, F. Liu, S. Mei, “Dispatchable region of the variable wind generation”, IEEE Transactions on Power Systems, Vol. 30, No. 5, pp. 2755-2765, 2014. https://doi.org/10.1109/TPWRS.2014.2365555

[4] L. Deng, L. Tu, L. Huang, H. Cai, "Time-constrained Preventive Dispatch of Hybrid AC/DC Transmission Systems based on Dispatchable Region of Offshore Wind Power", 6th International Conference on Electrical, Electronic Information and Communication Engineering (EEICE), pp. 23-28, 2025. https://doi.org/10.1109/EEICE65049.2025.11034265

[5] Z. Wang, T. Niu, S. Fang, G. Chen, N. Feng, Y. Feng, L. Xue, “Convex Hull Approximation of Probabilistic Security Region of Bulk Power System with High Renewable Energy Penetration Considering N− k Contingencies”, IEEE Transactions on Power Systems, 2025. https://doi.org/10.1109/TPWRS.2025.3559596

[6] X. Hu, C. Wan, Z. He, Z. Chen, Z. He, Y. Peng, "Probabilistic Forecasting-Based Operational Security Region for Power Systems With Renewable Energy Sources", 4th International Conference on Smart Grid and Green Energy (ICSGGE), pp. 66-71, 2025. https://doi.org/10.1109/ICSGGE64667.2025.10985212

[7] H. Xu, C. Guo, F. Sun, Y. Lin, "The Power Grid’s Convex Hull-Based Economic Dispatching Region for PQ Under Renewable Energy Uncertainties", 6th Asia Energy and Electrical Engineering Symposium (AEEES), pp. 745-749, 2024. https://doi.org/10.1109/AEEES61147.2024.10544817

[8] B. Liu, J. Ma, "Feasible region for DERs in unbalanced distribution networks with uncertain line impedances", IEEE Power & Energy Society General Meeting (PESGM), pp. 1-5, 2023. https://doi.rog/10.1109/PESGM52003.2023.10253037

[9] T. Zhao, J. Zhao, B. Cen, Z. Chen, Y. Jia, “Integrating High-DER-Penetrated Distribution Systems into Energy Market with Feasible Region and Accompanying Strategic Bidding”, Energies, Vol. 18, No. 21, pp. 5630, 2025. https://doi.org/10.3390/en18215630

[10] Z. Shen, W. Wei, T. Ding, Z. Li, S. Mei, “Admissible region of renewable generation ensuring power flow solvability in distribution networks”, IEEE Systems Journal, Vol. 16, No. 3, pp. 3982-3992, 2022, https://doi.org/10.1109/JSYST.2021.3138908

[11] Q. Ma, W. Wei, W. Chai, S. Mei, "Solvability Region of AC Power Flow with Volatile Renewable Generation and Operating Constraints", 40th Chinese Control Conference (CCC), pp. 1698-1702, 2021. https://doi.org/10.23919/CCC52363.2021.9549609

[12] Y. Liu, Z. Li, W. Wei, J. Zheng, H. Zhang, “Data-driven dispatchable regions with potentially active boundaries for renewable power generation: concept and construction”, IEEE Transactions on Sustainable Energy, Vol. 13, No. 2, pp. 882-891, 2022. https://doi.org/10.1109/TSTE.2021.3138125

[13] O. S. T. Al-Butti, M. Burunkaya, "Develop a Hybrid Optimization Technique (DNN-PSO) to Optimal Power Flow", International Conference on Artificial Intelligence, Computer, Data Sciences and Applications (ACDSA), pp. 1-9, 2025. https://doi.org/10.1109/ACDSA65407.2025.11166060

[14] H. You, J. Yang, C. Lou, "Deep Learning-Based Real-time Approach for Robust Optimal Power Flow in Three-Phase Unbalanced Distribution Systems", 8th International Conference on Power and Renewable Energy (ICPRE), pp. 559-564, 2023. https://doi.org/10.1109/ICPRE59655.2023.10353675

[15] A. Velloso, P. Van Hentenryck, “Combining deep learning and optimization for preventive security-constrained DC optimal power flow”, IEEE Transactions on Power Systems, Vol. 36, No. 4, pp. 3618-3628, 2021. https://doi.org/10.1109/TPWRS.2021.3054341

[16] M. H. Dinh, F. Fioretto, M. Mohammadian, K. Baker, "An analysis of the reliability of ac optimal power flow deep learning proxies", IEEE PES Innovative Smart Grid Technologies Latin America (ISGT-LA), pp. 170-174, 2023. https://doi.org/10.1109/ISGT-LA56058.2023.10328223

[17] G. Poyrazoglu, H. Oh, “Optimal topology control with physical power flow constraints and N-1 contingency criterion”, IEEE Transactions on Power Systems, Vol. 30, No. 6, pp. 3063-3071, 2015. https://doi.org/10.1109/TPWRS.2014.2379112

[18] E. B. Fisher, R. P. O'Neill, M. C. Ferris, “Optimal transmission switching”, IEEE Transactions on Power Systems, Vol. 23, No. 3, pp. 1346-1355, 2008. https://doi.org/10.1109/TPWRS.2008.922256

[19] J. D. Fuller, R. Ramasra, A. Cha, “Fast heuristics for transmission-line switching”, IEEE Transactions on Power Systems, Vol. 27, No. 3, pp. 1377-1386, 2012. https://doi.org/10.1109/TPWRS.2012.2186155

[20] M. Numan, M. F. Abbas, M. Yousif, S. S. Ghoneim, A. Mohammad, A. Noorwali, “The role of optimal transmission switching in enhancing grid flexibility: A review”, IEEE Access, Vol. 11, pp. 32437-32463, 2023. https://doi.org/10.1109/ACCESS.2023.3261459

[21] V. Shajin, P. Arun, P. Ansho, J. Juno, S. Rexley, “Role of Machine Learning in Power Systems: A Review”, International Journal of Scientific Research in Engineering and Management, Vol. 09, pp. 1-9, Vol. 9, No. 19, 2025. https://doi.org/10.55041/IJSREM52655

[22] S. Sadeghi, A. Hesami Naghshbandy, P. Moradi, N. Rezaei, “Introduction and Literature Review of the Application of Machine Learning/Deep Learning to Control Problems of Power Systems”, Application of Machine Learning and Deep Learning Methods to Power System Problems, pp. 83-117, 2021. https://doi.org/10.1007/978-3-030-77696-1_5

[23] A. Mathew, P. Amudha, S. Sivakumari, "Deep learning techniques: an overview", International Conference on Advanced Machine Learning Technologies and Applications, pp. 599-608, 2020, https://doi.org/10.1007/978-981-15-3383-9_54

[24] I. Sarker, "Machine learning: algorithms, real-world applications and research directions. SN Comput Sci 2: 160”, 2021. https://doi.org/10.1007/s42979-021-00592-x

[25] 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, pp. 104000, 2020. https://doi.org/10.1016/j.engappai.2020.104000

[26] H. Wang, Z. Lei, X. Zhang, B. Zhou, J. Peng, “A review of deep learning for renewable energy forecasting”, Energy Conversion and Management, Vol. 198, pp. 111799, 2019. https://doi.org/10.1016/j.enconman.2019.111799

[27] A. K. Ozcanli, F. Yaprakdal, M. Baysal, “Deep learning methods and applications for electrical power systems: A comprehensive review”, International Journal of Energy Research, Vol. 44, No. 9, pp. 7136-7157, 2020. https://doi.org/10.1002/er.5331

[28] S. Akhtar, M. Adeel, M. Iqbal, A. Namoun, A. Tufail, K.-H. Kim, “Deep learning methods utilization in electric power systems”, Energy Reports, Vol. 10, pp. 2138-2151, 2023. https://doi.org/10.1016/j.egyr.2023.09.028

[29] M. M. Forootan, I. Larki, R. Zahedi, A. Ahmadi, “Machine learning and deep learning in energy systems: A review”, Sustainability, Vol. 14, No. 8, pp. 4832, 2022. https://doi.org/10.3390/su14084832

[30] D. C. Montgomery, E. A. Peck, and G. G. Vining, Introduction to Linear Regression Analysis, 6th ed. Hoboken, NJ, USA: Wiley, 2021.

[31] H. G. Kim, Y. Park, “Calibrating f1 scores for fair performance comparison of binary classification models with application to student dropout prediction”, IEEE Access, 2025. https://doi.org/10.1109/ACCESS.2025.3594735

[32] A. Beiranvand, M. Shakarami, M. Doostizadeh, “Expanding Generator Flexibility Regions in Renewable-Rich Grid via Optimal Transmission Switching and Dynamic Line Rating”, International Journal of Industrial Electronics Control and Optimization, pp. -, 2026. https://doi.org/10.22111/ieco.2026.53986.1731

[33] R. D. Zimmerman, C. E. Murillo-Sánchez, R. J. Thomas, “MATPOWER: Steady-state

operations, planning, and analysis tools for power systems research and education", IEEE Transactions on Power Systems, Vol. 26, No. 1, pp. 12-19, 2010. https://doi.org/10.1109/TPWRS.2010.2051168

[1] Explainable Artificial Intelligence
[2] Dispatchable Region
[3] Probabilistic Operational Security Region
[4] Feasible Region
[5] Potentially Active Boundaries
[6] Data-Driven Methods
[7] Linear Programming
[8] Machine Learning
[9] Deep Learning
[10] Root Mean Square Error
[11] Mean Absolute Percentage Error
[12] Mean Absolute Error
[13] Mean Square Error
[14] Power Transfer Distribution Factor