



Sharif University of Technology

<https://sjie.journals.sharif.edu/>



Research Article

Developing Machine Learning Algorithm for Energy Supply Optimization in Virtual Power Plants

Bentolhoda Dehghani¹, Mohammad Mehdi Lotfi^{1*} and Alireza Sedighi²

¹Department of Industrial Engineering, Yazd University, Yazd, Iran.

² Department of Electrical Engineering, Yazd University, Yazd, Iran.

* corresponding author: (lotfi@yazd.ac.ir)

Article Info

Article history:

Received: 1 July 2025

Revised: 5 October 2025

Accepted: 19 October 2025

Keywords:

Virtual power plant,
demand side management,
unit commitment,
MILP,
machine learning.

Abstract

This research addresses the challenge of optimizing energy dispatch in restructured power markets by evaluating a Virtual Power Plant (VPP) model that integrates demand-side storage. The study aims to close the gap between energy supply and demand by employing two optimization methodologies: a precise Mixed-Integer Linear Programming (MILP) model and a hybrid algorithm based on an Extreme Learning Machine and a Genetic Algorithm (ELM-GA), which is computationally efficient. The VPP model incorporates a diverse portfolio of generation units (diesel, hydroelectric, solar, wind), supply-side storage, and a prosumer, with demand-side management actualized through a water storage system. The objectives are to maximize VPP profitability while minimizing hydroelectric energy losses and pump operational costs. Tested on a standard IEEE 24-bus system with real-world data, the results show that a VPP with demand-side storage is 1.5 times less costly than a traditional grid without storage. Furthermore, the VPP framework is 1.7 times more cost-effective than a traditional grid structure. For large-scale problems, the ELM-GA algorithm delivers near-optimal solutions (4.4% optimality gap) 16 times faster than MILP, highlighting its potential for rapid, reliable energy management and policy-making.

Funding: This research did not receive any specific grant from funding agencies in the public, commercial, or not-for-profit sectors.

Conflicts of Interest: The authors declare no conflict of interest.

Author Contributions: All authors contributed to the reported work for conceptualization, methodology, validation, writing-review and editing, and supervision.

To Cite this article:

Dehghani, B., Lotfi, M.M. and Sedighi, A. 2026. Developing machine learning algorithm for energy supply optimization in virtual power plants, Sharif Industrial Engineering and Management Journal, 41(2), pp.111-125.
<https://doi.org/10.24200/ij65.2025.66704.2433>



به کارگیری الگوریتم یادگیری ماشین برای بهینه‌سازی تأمین انرژی در نیروگاه‌های مجازی

بنت‌الهدی دهقانی^۱، محمدمهدی لطفی^{۲*} و علیرضا صدیقی^۲

^۱ گروه مهندسی صنایع، دانشگاه یزد، یزد، ایران.

^۲ دانشکده مهندسی برق، دانشگاه یزد، یزد، ایران.

*نویسنده مسئول (dotfi@yazd.ac.ir)

چکیده

در پژوهش حاضر، مسئله مشارکت بهینه‌ی واحدها در یک نیروگاه مجازی با ذخیره‌ساز سمت تقاضا، جهت کاهش شکاف بین عرضه و تقاضای انرژی با رویکردهای MILP و یادگیری ماشین مطالعه شده است. نتایج برای سیستم ۲۴ - باسه استاندارد IEEE نشان داده‌اند که گرچه استفاده از ذخیره‌ساز سمت تقاضا باعث افزایش هزینه و نوسان تولید نیروگاه مجازی می‌شود، اما هزینه‌ها در نیروگاه مجازی با ذخیره‌ساز سمت تقاضا حدود ۱/۵ برابر کمتر از هزینه‌های شبکه‌ی سنتی بدون ذخیره‌ساز است. برای حل مدل در ابعاد واقعی، از الگوریتم ترکیبی ELM-GA استفاده شده است، که پیشنهادی نزدیک به بهینه، اما با سرعت بسیار بالاتر از روش MILP ارائه می‌کند؛ زیرا آموزش و یادگیری همگرایی به نقطه‌ی بهینه را سرعت می‌بخشد. نتایج نشان می‌دهند که با افزایش ابعاد مسئله به ۶۰ واحد نیروگاهی، شکاف بهینگی به ۴/۴٪ رسیده است، در حالی که سرعت حل یادگیری ماشین ۱۶ برابر بهتر از MILP بوده است.

اطلاعات مقاله

تاریخ دریافت: ۱۴۰۴/۰۴/۱۰

تاریخ اصلاحیه: ۱۴۰۴/۰۷/۱۳

تاریخ پذیرش: ۱۴۰۴/۰۷/۲۷

واژگان کلیدی:

نیروگاه مجازی،

مدیریت سمت تقاضا،

مسئله مشارکت واحدها،

برنامه‌ریزی خطی عدد صحیح،

یادگیری ماشین.

۱. مقدمه

انسان‌ها از دیرباز از انرژی‌های تجدیدپذیر، مانند: خورشید، باد، آب، و زیست‌توده برای گرمایش، روشنایی، حمل‌ونقل، و کشاورزی استفاده کرده‌اند. با کشف آتش و سوخت‌های فسیلی، مانند: چوب، زغال‌سنگ، نفت، و گاز، مصرف انرژی افزایش یافته و تحولات صنعتی، فناوری و اقتصادی را به همراه داشته است. در قرن بیستم نیز با توسعه‌ی نیروگاه‌های هسته‌ای، انرژی هسته‌ای به‌عنوان یک منبع جدید انرژی پدیدار شده است.

لذا با افزایش نیاز به انرژی، باید برای خرید، فروش، و توزیع آن چاره‌ای اندیشیده می‌شد که نتیجه‌ی آن ایجاد بازارها و بورس‌های انرژی بوده است. نیروگاه مجازی، که مجموعه‌ای از واحدهای کوچک تولید و مصرف برق است، از نتایج بازارهای اخیر است.

از دست‌رفتن انرژی در ساعت‌های غیرپیک و قطعی آن در ساعت‌های پیک، از دلایل به‌وجودآمدن مفهومی به نام مدیریت‌کننده‌ی سمت تقاضا بود. مدیریت سمت تقاضا مفهومی است که بر مجموعه‌ی فعالیت‌ها با هدف تأثیرگذاری در

مصرف انرژی دلالت دارد و مزایایی، از جمله: افزایش پایداری شبکه، کاهش هزینه‌های عملیاتی، حفاظت از محیط‌زیست، و افزایش رضایت مشتریان دارد. یکی از مهم‌ترین روش‌های مدیریت سمت تقاضا، استفاده از ذخیره‌ساز در سمت تقاضاست؛ که بعضی از آن‌ها، به‌صورت باتری، بعضی به‌صورت حرارتی و سیستم‌های سرمایشی/گرمایشی منازل مسکونی، و بعضی نیز به‌صورت منابع آب هستند.

در پژوهش حاضر، بهینه‌سازی و زمان‌بندی یک نیروگاه مجازی کامل، شامل: چند تولیدکننده‌ی انرژی، توصیف‌کنندگان^۱، مصرف‌کنندگان، و ذخیره‌سازهای سمت عرضه و تقاضا، مطالعه و مشارکت بهینه‌ی واحدها با استفاده از یادگیری ماشین به‌دست آمده است. علاوه بر این، سناریوهایی مانند وجود یا نبود ذخیره‌ساز سمت تقاضا و شرایط آب‌وهوایی و شبکه‌ی برق ایران بررسی و با مقایسه‌ی اطلاعات به‌دست‌آمده، افزایش سود طرف‌های درگیر و لزوم وجود ذخیره‌ساز سمت تقاضا نشان داده شده است. همچنین با استفاده از الگوریتم‌های ELM-GA^۲ و MILP^۳، ساختار بهینه‌ی مشارکت واحدها در واحدهای زمانی مختلف ارائه شده است. در بخش دوم، به مرور پیشینه‌ی


^۳ Mixed-Integer Linear Programming

^۱ Prosumer

^۲ Extreme Learning Machine and a Genetic Algorithm

استناد به این مقاله:

دهقانی، بنت‌الهدی، لطفی، محمدمهدی و صدیقی، علیرضا، ۱۴۰۴. به کارگیری الگوریتم یادگیری ماشین برای بهینه‌سازی تأمین انرژی در نیروگاه‌های مجازی. مهندسی صنایع و مدیریت شریف، ۴۱(۲)، صص. ۱۱۱-۱۲۵. <https://doi.org/10.24200/j65.2025.66704.2433>



شکل ۱. نمودار عملکردی یک منبع آب به‌عنوان ذخیره‌ساز سمت تقاضا.

توصیف‌کنندگان، و واحدهای ذخیره‌سازی تحت کنترل یک واحد مرکزی بهینه‌سازی مشارکت واحدها وجود دارد.

پژوهش‌های متعددی در زمینه‌ی نیروگاه مجازی، مدیریت‌کننده‌ی سمت تقاضا، استفاده از یادگیری ماشین در نیروگاه مجازی و ترکیبی از موارد مذکور انجام شده است؛ که در جدول ۱، خلاصه‌ای از آن‌ها ارائه شده است.

همان‌طور که مشخص است، در معدود مطالعاتی^[۱] درباره‌ی استفاده از منبع آب به‌عنوان مدیریت‌کننده‌ی سمت تقاضا، شبکه و نیروگاه‌ها همه سنتی بوده و هیچ تنوعی در نیروگاه‌ها و منابع انرژی وجود نداشته و عدم قطعیت در نظر گرفته نشده است. در مطالعه‌ی حاضر، شبکه‌ای با مشارکت نیروگاه‌های دیزلی، هیدروالکتریک، پنل‌های خورشیدی، توربین‌های بادی، توصیف‌کننده، باتری یا ذخیره‌سازی سمت عرضه، مصرف‌کننده، و واحدهای مدیریت‌کننده‌ی سمت تقاضا بررسی شده‌اند. هدف مطالعه‌ی حاضر، بهینه‌سازی سود عناصر در ریزشبکه‌ی ۲۴ باسه استاندارد IEEE با استفاده از MILP و یادگیری ماشین بوده است. بیشتر نیروگاه‌های مجازی را می‌توان نوعی ریزشبکه در نظر گرفت، که تولیدکنندگان به صورت واحد ظاهر می‌شوند. در پژوهش حاضر، افزایش سود یک تولیدکننده با مشارکت در یک نیروگاه مجازی بررسی و همچنین تأثیر حضور ذخیره‌ساز سمت تقاضا تحلیل شده است.

۳. تعریف مسئله و مدل‌سازی

در پژوهش حاضر، مسئله‌ی بهینه‌سازی عملکرد یک نیروگاه مجازی در یک ریزشبکه‌ی استاندارد فرموله شده است. مسئله‌ی اصلی، یک مسئله‌ی مشارکت واحدها و توزیع بار اقتصادی بوده است. هدف، نیز تعیین راهبرد بهینه‌ی تولید، ذخیره‌سازی، و مصرف انرژی برای تمامی واحدهای تحت مدیریت نیروگاه مجازی در یک افق زمانی ۲۴ ساعته بوده است. راهبرد مذکور باید به‌گونه‌ای تعیین شود که ضمن برآورده‌ساختن تقاضای بار و رعایت تمامی محدودیت‌های فیزیکی و عملیاتی هر واحد، سود کل سیستم را بیشینه سازد.

در مدل پیشنهادی، یک ریزشبکه‌ی ۲۳ باسه استاندارد IEEE شامل یک نیروگاه مجازی در نظر گرفته شده است، که نیروگاه‌های دیزلی، هیدروالکتریک، خورشیدی، بادی عمودی داریوس، یک ماشین الکتریکی به‌عنوان توصیف‌کننده، و یک باتری را مدیریت می‌کند. علاوه بر حضور مصرف‌کنندگان، تعدادی منبع آب هم برای مدیریت سمت تقاضا در نظر گرفته شده است؛ که برای تولید

پژوهش؛ در بخش سوم، به مدل‌سازی مسئله؛ در بخش چهارم، به تجزیه و تحلیل عددی آن؛ و در پایان، به نتیجه‌گیری پرداخته شده است.

۲. مرور ادبیات

نیاز روزافزون به خرید، فروش، و توزیع انرژی، منجر به تشکیل بازارهای برق و انرژی در سراسر جهان شده است. در ابتدا، بازار به‌صورت انحصاری بوده است؛ بنابراین، دولت‌ها انرژی را از تولیدکنندگان می‌خریدند و سپس به‌عنوان عمده‌فروش، به شرکت‌های توزیع یا مستقیماً به مصرف‌کنندگان می‌فروختند. اما در سال ۱۹۹۰، عدم تنظیم قیمت برق، آسیب به محیط‌زیست، محدودیت‌های مالی، عدم شفافیت، انگیزه‌های اندک برای بهبود کیفیت، و کاهش هزینه‌ها و حمایت محدود از منابع تجدیدپذیر، مسئولان را وادار به ایجاد سیاست عمده‌فروشی در بازار برق کرده است.^[۱]

در ابتدا، یک عامل خرید معرفی می‌شده است؛ که در آن، تولیدکنندگان انرژی خود را به‌صورت گروهی توسط نماینده‌ای در بورس انرژی عرضه می‌کردند.^[۲] نماینده می‌توانست یک شرکت عمده‌فروشی یا یک شرکت بزرگ تولید دولتی باشد. در نتیجه، نیروگاه‌های مجازی به‌عنوان نوعی نماینده معرفی می‌شدند. نیروگاه مجازی، مجموعه‌ای از واحدهای تولید و مصرف کوچک است، که توسط یک سیستم کنترل مرکزی هماهنگ شده است.^[۳] اما به‌دلیل محدودیت‌های فناوری رایانه و شبکه و نبود شرایط نظارتی مناسب برای اهداف اجرایی، استفاده از نیروگاه مذکور تا سال ۲۰۰۳ به‌تعمیق افتاده است، زمانی که شرکت آلمانی RWE از شبکه‌ای از ژنراتورهای کوچک‌مقیاس استفاده کرد تا خدمات مناسب شبکه را فراهم کند. از آن زمان، نیروگاه‌های مجازی به‌عنوان راهی برای ادغام منابع انرژی تجدیدپذیر در شبکه و متعادل‌کردن تقاضا و عرضه‌ی برق به‌طور فزاینده محبوب شده‌اند.^[۴] تفاوت اصلی نیروگاه‌های مجازی و معمولی این است که نیروگاه‌های مجازی چابک‌تر، کارآمدتر، و مقرون به صرفه‌تر هستند. نیروگاه مجازی می‌تواند به سرعت به تغییرات تقاضا و شرایط بازار پاسخ دهد و به شرکت‌ها اجازه می‌دهد در سطوح بهینه با ضایعات و هزینه‌های عملیاتی کمتر فعالیت کنند.^[۵] دلایل برتری نیروگاه مجازی نسبت به سایر نیروگاه‌ها، کاهش هزینه‌های تولید واحد، افزایش سود تولیدکنندگان، کمک به تثبیت شبکه‌ی برق، کمینه‌سازی تلفات انتقال انرژی، بهبود قابلیت اطمینان و انعطاف‌پذیری، و کاهش انتشار کربن است.^[۶]

در دهه‌ی ۱۹۷۰، چالش‌هایی در صنعت برق به وجود آمده است که باعث قطعی برق و آسیب به تجهیزات الکتریکی، هزینه‌های تولید بالا در ساعت‌های اوج مصرف، و از دست‌دادن انرژی تولیدی مازاد در سایر ساعت‌ها شده است. از سوی دیگر، با وجود احداث نیروگاه‌های مختلف در سراسر جهان، با افزایش مستمر تقاضا و محدودیت‌های گسترش عرضه، مدیریت سمت تقاضا با استفاده از ذخایر ضروری به‌نظر می‌رسد. ذخیره‌سازی سمت تقاضا از سیستم‌های ذخیره‌سازی مختلفی، مثل منبع ذخیره‌سازی آب و بانک ICE، برای کاهش مصرف برق در زمان‌های اوج مصرف، افزایش زمان‌های غیرپیک، صاف‌تر کردن منحنی بار شبکه، و کاهش نوسان‌های قیمت برق استفاده می‌کند.^[۷] استفاده از دستگاه ذخیره‌سازی می‌تواند باعث ذخیره‌ی انرژی در زمان‌های خارج از پیک شود و در زمان‌های پیک به جای استفاده از نیروگاه‌های اضافی، از انرژی ذخیره‌شده استفاده شود. همچنین قابلیت اطمینان را بهبود می‌بخشد و از مصرف منابع تجدیدپذیر پشتیبانی می‌کند. در شکل ۱، یک منبع آب به‌عنوان ذخیره‌ساز سمت تقاضا مشاهده می‌شود. در یک شبکه‌ی کامل نیروگاه مجازی، چندین واحد عرضه و تقاضا شامل تولیدکنندگان انرژی، مصرف‌کنندگان،

جدول ۱. مقایسه‌ی پژوهش‌های پیشین.

Objective function	Uncertainty	Demand management	Solution method	Model	Power plant	Reference
Profit	-	-	-	Interactive method	Virtual	[8]
Fines and income	✓	-	CCP	-	Virtual	[9]
Production losses and their costs	-	✓	ELM-GA	-	Traditional	[10]
Profit	-	-	-	MIP	Virtual	[11]
Exchange scenarios in the smart grid	-	✓	MLPTA	-	Traditional	[12]
Production cost. elasticity of supply and demand	✓	✓	-	Min-Max and Max-Min	Traditional	[13]
Prediction error	✓	-	BLSTM	-	Virtual	[14]
Prediction error	✓	-	K-means	-	Virtual	[15]
Profit. pump operating costs and floating producer losses	✓	✓	ELM-GA	MILP	Virtual	Current research

جدول ۲. اندیس‌های مدل.

Index	Definition	Index	Definition
t	Time	he	Hydroelectric power plant
d	Diesel power plant	s	Solar panel
w	Wind turbine	v	Electric Vehicle
b	Battery	i	Storage
l	Time intervals in the dispatch window	p	Pump

جدول ۳. متغیرهای مدل.

Variable	Definition	Variable	Definition
$P_{he,t}$	Output power of hydroelectric power plant he at time t (kW)	$Z_{he,t}$	Binary variable; 1 if diesel power plant d is started up/shut down at time t, 0 otherwise
$P_{d,t}$	Output power of diesel power plant (d) at time t (kW)	$Z_{d,t}$	Binary variable; 1 if diesel power plant d is started up/shut down at time t, 0 otherwise
$u_{d,t}$	Binary variable; 1 if diesel power plant d is on at time t, 0 otherwise	$u_{s,t}$	Binary variable; 1 if solar panel (s) is on at time t, 0 otherwise
$P_{s,t}$	Output power of solar panel s at time t (kW)	$Z_{s,t}$	Binary variable; 1 if solar panel s is started up/shut down at time t, 0 otherwise
$P_{w,t}$	Output power of wind turbine w at time t (kW)	$u_{w,t}$	Binary variable; 1 if wind turbine w is on at time t, 0 otherwise
$Z_{w,t}$	Binary variable; 1 if wind turbine w is started up/shut down at time t, 0 otherwise	$P_{v,t}$	Charged power of the electric vehicle v at time t (kW)
$x_{v,t}$	Discharged power of the electric vehicle v at time t (kW)	$u_{x.v,t}$	Binary variable; 1 if the electric vehicle v is discharging at time t, 0 otherwise
$u_{v,t}$	Binary variable; 1 if the electric vehicle v is charging at time t, 0 otherwise	$P_{b,t}$	Charged power of the battery b at time t (kW)
$x_{b,t}$	Discharged power of the battery b at time t (kW)	$u_{b,t}$	Binary variable; 1 if the battery b is charging at time t, 0 otherwise
$u_{x.b,t}$	Binary variable; 1 if the battery (b) is discharging at time t, 0 otherwise		

راهری در زمان اوج مصرف و تقاضای بالا، به هر کدام از آن‌ها، شش پمپ متصل به موتور القایی قرار گرفته‌اند، که به درایو فرکانس متغیر متصل بوده‌اند. اندیس-ها، متغیرها، و پارامترهای مدل به ترتیب در جدول‌های ۲ الی ۴ ارائه شده‌اند.

راهری مناسب برای پاسخگویی بار و بیشینه‌سازی سود عناصر درگیر در نیروگاه مجازی تعیین شده است، تا از جهش قیمت در ساعت‌های پیک جلوگیری شود. در پژوهش حاضر، دو سناریو بررسی شده‌اند:

جدول ۴. پارامترهای مدل.

Parameter	Definition	Parameter	Definition
$C_{o,he,t}$	Repair and maintenance costs of hydroelectric power plant he at time t (currency)	$C_{he,t}$	Marginal costs of hydroelectric power plant he at time t (currency)
Y_{he}	Hydroelectric power plant on/off cost (currency)	$r_{d,t}$	Reliability of diesel power plant d at time t
$C_{f,t}$	Fuel cost at time t (currency)	$C_{d,t}$	Marginal costs of diesel power plant d at time t (currency)
$C_{o,d,t}$	Repair and maintenance costs of diesel power plant (d) at time t (currency)	Y_d	Diesel power plant on/off cost (currency)
R_d	Diesel power plant power increase rate	$P_{real,d,t}$	Rated power of diesel power plant d at time t (kW)
UT_d	Minimum operating time for diesel power plant	DT_d	Minimum downtime for diesel power plant
$C_{s,t}$	Marginal costs of solar panel s at time t (currency)	$C_{o,s,t}$	Solar panel repair and maintenance costs s at time t (currency)
Y_s	Solar panel on/off cost (currency)	R_s	Solar panel power increase rate
$P_{real,s,t}$	Rated power of solar panel s at time t (kW)	$r_{s,t}$	Reliability of solar panel s at time t
UT_s	Minimum working time for solar panel	DT_s	Minimum downtime for solar panels
E_s	Daily solar energy limit	T_r	Reference temperature (Celsius)
T_c	Average temperature (Celsius)	T_d	Course Collection
G_{AC}	Radiation at time t	G_{ST}	Standard radiation
$C_{w,t}$	Wind turbine marginal costs w at time t (currency)	$C_{o,w,t}$	Wind turbine repair and maintenance costs w at time t (currency)
Y_w	Wind turbine on/off cost (currency)	R_w	Wind turbine power increase rate
$P_{real,w,t}$	Rated power of wind turbine w at time t (kW)	$r_{w,t}$	Wind turbine reliability w at time t
UT_w	Minimum operating time for wind turbine	DT_w	Minimum downtime for wind turbine
K_{co}	Wind turbine cut-off speed (m/s)	K_r	Nominal wind turbine speed (m/s)
K_{ci}	Wind turbine cutting speed (m/s)	θ	Percentage of wind turbine electricity production
C_{deg}	Cost of destruction and depreciation of electric car (currency)	C_{con}	Cost of using an electric car (currency)
C_{mir}	Electric car repair and maintenance costs (currency)	C_v	Marginal costs of electric cars (currency)
$P_{real,v,t}$	Rated charging power of electric car v at time t (kW)	$P_{real,x,v,t}$	Rated discharge power of electric machine v at time t (kW)
η_v	Electric car efficiency	$D_{v,t}$	Electric machine load demand v at time t (kW)
SOC_v	Electric car charging status	SOC_b	Battery charge status
C_{bmc}	Battery repair and maintenance costs (currency)	C_b	Battery destruction and depreciation cost (currency)
C_{cc}	Battery charging cost (currency)	C_{dc}	Battery discharge cost (currency)
$P_{real,b,t}$	Rated battery charging power b at time t (kW)	$P_{real,x,b,t}$	Rated battery discharge power b at time t (kW)
η_b	Battery efficiency	E_b	Battery energy capacity
R	Reliability required	PRICE	Selling price per unit of energy (currency)
$D_{un,t}$	Unmet demand at time t (kW)	D_t	Load demand at time t (kW)
M	A very large positive number	ε	A very small positive number

$$\tau = t - (DT_d - 1) \cdot \sum_{\tau} (1 - u_{d,\tau}) \geq DT_d \times (1 - u_{d,t}) \quad \forall d, t \quad (6)$$

$$u_{d,t} - u_{d,t-1} = z_{d,t} \quad \forall d, t > 1 \quad (7)$$

تابع هدف نیروگاه خورشیدی نیز مطابق رابطه‌ی ۸ و محدودیت‌های آن مطابق رابطه‌های ۹ الی ۱۶ هستند:

$$C(s) = \sum_t \sum_s ((C_{s,t} \times P_{s,t}) + C_{o,s,t} + (Y_s \times z_{s,t})) \quad (8)$$

$$-R_s \leq P_{s,t} - P_{s,t-1} \leq R_s \quad \forall s, t > 1 \quad (9)$$

$$P_{s,t} \leq P_{real,s,t} \times u_{s,t} \quad \forall s, t \quad (10)$$

$$\tau = t - (UT_s - 1) \cdot \sum_{\tau} u_{s,\tau} \geq UT_s \times u_{s,t} \quad \forall s, t \quad (11)$$

$$\tau = t - (DT_s - 1) \cdot \sum_{\tau} (1 - u_{s,\tau}) \geq DT_s \times (1 - u_{s,t}) \quad \forall s, t \quad (12)$$

$$u_{s,t} - u_{s,t-1} = z_{s,t} \quad \forall s, t > 1 \quad (13)$$

همچنین، رابطه‌های ۱۴ و ۱۵ از نوشتار ژائوکسیا^۱ و همکاران (۲۰۱۷)،^[۱۶] استخراج شده‌اند:

$$Td \times P_{s,t} \leq E_s \quad \forall s \quad (14)$$

$$P_{s,t} = (P_{real,s,t} \times G_{AC}) (1 + h(T_c - T_r)) / G_{ST} \quad \forall s, t > 1 \quad (15)$$

$$u_{s,t} = \begin{cases} 0 & G_{AC} < 200 \\ 1 & G_{AC} \geq 200 \end{cases} \quad \forall s, t > 1 \quad (16)$$

در ادامه، تابع هزینه‌ی نیروگاه بادی نیز مطابق رابطه‌ی ۱۷ و محدودیت‌های در نظر گرفته‌شده در آن به شرح روابط ۱۸ الی ۲۲ هستند.

$$D(w) = \sum_t \sum_w ((C_{w,t} \times P_{w,t}) + C_{o,w,t} + (Y_w \times z_{w,t})) \quad (17)$$

$$-R_w \leq P_{w,t} - P_{w,t-1} \leq R_w \quad \forall w, t > 1 \quad (18)$$

$$P_{w,t} \leq P_{real,w,t} \times u_{w,t} \quad \forall w \quad (19)$$

$$\tau = t - (UT_w - 1) \cdot \sum_{\tau} u_{w,\tau} \geq UT_w \times u_{w,t} \quad \forall w \quad (20)$$

$$\tau = t - (DT_w - 1) \cdot \sum_{\tau} (1 - u_{w,\tau}) \geq DT_w \times (1 - u_{w,t}) \quad \forall w, t > 1 \quad (21)$$

$$u_{w,t} - u_{w,t-1} = z_{w,t} \quad \forall w, t > 1 \quad (22)$$

توان خروجی توربین بادی تابعی از سرعت باد در زمان t است؛ که با استفاده از سه پارامتر کلیدی سرعت باد، شامل: سرعت آستانه‌ی قطع، سرعت نامی، و سرعت آستانه‌ی خروج، به‌صورت تابع چندضابطه‌ای مطابق روابط ۲۳ الی ۲۵ هستند، که بر مبنای نوشتار اولاه^۲ و همکاران (۲۰۱۷)،^[۱۷] هستند:

الف) مقایسه‌ی پاسخ به بار و سود دو حالت ایجاد و بهره‌برداری از نیروگاه مجازی یا ادامه‌ی روش سنتی کنونی.

ب) بررسی، مقایسه، و تعیین راهبرد بهینه‌ی به‌کارگیری مدیریت‌کننده‌ی سمت تقاضا در سه حالت حضور در شبکه‌ی سنتی، حضور در نیروگاه مجازی، و عدم حضور.

وقتی انرژی تولیدی بیش از تقاضاست، باتری و ماشین الکتریکی شارژ و در سمت تقاضا نیز، علاوه بر پاسخ به نیاز مشترکان، با به‌حرکت درآوردن موتورهای آب ورودی در منابع موردنظر ذخیره می‌شوند. در زمان اوج مصرف و فشار بر شبکه، انرژی ذخیره‌شده در باتری و ماشین الکتریکی وارد شبکه می‌شود تا از فشار وارده بر شبکه‌ی موردنظر بکاهد. همچنین با آزادسازی آب درون منابع و به‌حرکت درآمدن پمپ‌ها و سپس موتورهای القایی، منبع تولید انرژی جدیدی خواهد بود، که انرژی تولیدی آن به‌سرعت و با طی مسیر انتقال کوتاه‌تر و هدررفت کمتر، می‌تواند شکاف در عرضه و تولید انرژی با تقاضای آن را پوشش دهد و مانع از ایجاد قطعی شود.

مفروضات شبکه‌ی پژوهش حاضر به این قرار بوده‌اند:

- پارامترهای مربوط به شرایط آب‌وهوایی (سرعت باد و تابش خورشید) و تقاضای روزانه، ذاتاً غیرقطعی هستند. با این حال، در نوشتار حاضر، از یک رویکرد بهینه‌سازی قطعی استفاده شده است؛ که در آن، فرض شده است که یک پیش‌بینی نقطه‌ای دقیق برای پارامترهای مذکور در افق زمانی ۲۴ ساعته در دسترس بوده و مدل براساس مقادیر پیش‌بینی‌شده‌ی اخیر حل شده است. بنابراین، عدم قطعیت مستقیماً در مدل ریاضی لحاظ نشده است، بلکه با استفاده از داده‌های پیش‌بینی‌شده مدیریت شده است.
- هزینه‌ها و درآمدهای مرتبط به‌صورت قطعی و ثابت فرض شده‌اند.
- خرابی‌های برنامه‌ریزی‌نشده در نظر گرفته نشده‌اند.
- مدل‌سازی پژوهش حاضر به دو بخش نیروگاه مجازی و مدیریت سمت تقاضا تقسیم و از ترکیب مبانی اصلی و عمومی نیروگاه‌ها و مدل‌سازی در پژوهش‌های پیشین استفاده شده است.

تابع هزینه در نیروگاه هیدروالکتریک به صورت رابطه‌ی ۱ بوده و محدودیت‌های آن در بخش ذخیره‌ساز ارائه شده است:

$$A(h_e) = \sum_t \sum_{h_e} ((C_{h_e,t} \times P_{h_e,t}) + C_{o,h_e,t} + (Y_{h_e} \times z_{h_e,t})) \quad (1)$$

تابع هزینه‌ی نیروگاه دیزلی به‌صورت رابطه‌ی ۲ و محدودیت‌های آن مطابق روابط ۳ الی ۷ است:

$$B(d) = \sum_t \sum_d ((C_{f,d,t} \times P_{d,t}) + C_{o,d,t} + (Y_d \times z_{d,t})) \quad (2)$$

$$-R_d \leq P_{d,t} - P_{d,t-1} \leq R_d \quad \forall d, t > 1 \quad (3)$$

$$P_{d,t} \leq P_{real,d,t} \times u_{d,t} \quad \forall d, t \quad (4)$$

$$\tau = t - (UT_d - 1) \cdot \sum_{\tau} u_{d,\tau} \geq UT_d \times u_{d,t} \quad \forall d, t \quad (5)$$

$$D_t - \sum P_t \geq \varepsilon - M(1 - u_{x,b,t}) \quad \forall b, t \quad (41)$$

عبارت ۴۲، تعادل توان را در هر ساعت تضمین می‌کند، به این معنا که مجموع تولید و انرژی تخلیه‌شده از ذخیره‌سازها باید با تقاضای بار و انرژی موردنیاز برای شارژ برابر باشد.

$$D_{un,t} + P_{d,t} + P_{s,t} + P_{w,t} + P_{b,t} + P_{ng,t} + P_{v,t} - x_{b,t} - x_{v,t} = D_t \quad \forall t \quad (42)$$

محدودیت‌های ۴۳ و ۴۴، الزام‌های اصلی کل سیستم را نشان می‌دهند. عبارت ۴۳، کمینه‌ی سطح قابلیت اطمینان سیستم را با در نظر گرفتن واحدهای در حال کار اعمال می‌کند و تابع هدف کل سیستم نیز مطابق رابطه‌ی ۴۴ است:

$$(r_{ng,t} \times u_{ng,t}) + (r_{d,t} \times u_{d,t}) + (r_{s,t} \times u_{s,t}) + (r_{w,t} \times u_{w,t}) \geq R \quad \forall t \quad (43)$$

$$\max \sum_t (D_t \times PRICE) - A(he) - B(d) - C(s) - D(w) - E(v) - F(b) \quad (44)$$

به‌طور خلاصه، چارچوب مدل‌سازی ارائه‌شده در پژوهش حاضر، یک رویکرد ترکیبی است که از یکپارچه‌سازی و تلفیق مدل‌های توسعه‌یافته در مراجع مختلف بهره می‌برد. همان‌طور که تشریح شد، اجزاء مدل براساس مدل‌های ارائه‌شده در برخی نوشتارها،^[۱۸ و ۱۹] پیاده‌سازی شده‌اند. در این میان، مدل‌سازی بخش ذخیره‌ساز و الگوریتم یادگیری ماشین، به‌طور کامل از نوشتار ناندکولیار و کوماری^۴ (۲۰۲۲)،^[۱۰] اقتباس شده است. هدف از این رویکرد یکپارچه، بهره‌گیری هم‌زمان از نقاط قوت هر یک از مدل‌های پایه به‌منظور دستیابی به عملکردی دقیق‌تر و جامع‌تر بوده است.

الگوریتم ترکیبی استفاده‌شده، الگوریتمی بوده است که در آن «الگوریتم ژنتیک (GA)» به‌عنوان موتور اصلی بهینه‌سازی عمل کرده و «ماشین یادگیری بی‌نهایت (ELM)» نقش یک شتاب‌دهنده‌ی هوشمند برای بهبود و تسریع همگرایی را داشته است. فرایند حل با الگوریتم ژنتیک آغاز شده است. GA با ایجاد یک جمعیت اولیه از راه‌حل‌های کاندید (که هر راه‌حل، یک راه‌برد کامل ۲۴ ساعته برای مشارکت واحدهاست) به جستجو در فضای جواب پرداخته و در هر نسل، با استفاده از عملگرهای انتخاب براساس شایستگی (مقدار تابع هدف)، ترکیب و جهش، جمعیت به سمت یافتن جواب‌هایی با کیفیت بالاتر هدایت شده است.

با این حال، برای جلوگیری از همگرایی زودرس به بهینه‌های محلی و افزایش سرعت رسیدن به جواب‌های با کیفیت، از ماشین یادگیری بی‌نهایت به‌عنوان یک عملگر کمکی هوشمند در طول فرایند تکامل GA استفاده شده است. پس از گذشت تعداد معینی از نسل‌ها، مجموعه‌ای از بهترین جواب‌های یافت‌شده تا آن لحظه، به‌عنوان داده‌های آموزشی برای یک شبکه‌ی ELM به‌کار رفته‌اند. ELM که یک شبکه‌ی عصبی بسیار سریع است، الگوی موجود در جواب‌های اخیر را خوب یاد می‌گیرد. سپس، در نسل‌های بعدی الگوریتم ژنتیک، برخی از جواب‌های جدید تولیدشده (فرزند) به‌عنوان ورودی به شبکه‌ی ELM آموزش‌دیده داده شده و شبکه‌ی ELM، یک نسخه‌ی اصلاح‌شده و بهبودیافته از آن جواب را براساس دانش استخراج‌شده از

$$P_{w,t} = \begin{cases} 0 & 0 \leq k \leq K_{ci} \\ P_{real,w,t} \times \frac{k - K_{ci}}{K_r - K_{ci}} & K_{ci} < k \leq K_r \\ P_{real,w,t} & K_r < k \leq K_{co} \\ 0 & K_{co} < k \end{cases} \quad \forall w, t \quad (23)$$

$$0 \leq P_{w,t} \leq \theta \times P_{real,w,t} \quad \forall w, t \quad (24)$$

$$u_{w,t} = \begin{cases} 0 & K_{ci} < 2.5 \\ 1 & K_{ci} \geq 2.5 \end{cases} \quad \forall w, t \quad (25)$$

تابع هدف ماشین الکتریکی مطابق رابطه‌ی ۲۶ و محدودیت‌های آن براساس نوشتار فلیسچر^۶ و همکاران (۲۰۱۳)،^[۱۸] مطابق رابطه‌های ۲۷ الی ۳۳ هستند:

$$E(v) = \sum_t \sum_v ((C_v + C_{deg}) \times P_{v,t}) + (C_{con} \times x_{v,t}) + C_{mir} \quad (26)$$

$$SOC_v + (\eta_v \times P_{v,t}) - \left(\frac{x_{v,t}}{\eta_v} \right) \leq D_{v,t} \quad \forall v, t \quad (27)$$

$$P_{v,t} \leq P_{real,v,t} \times u_{v,t} \quad \forall v, t \quad (28)$$

$$P_{v,t} \leq P_{real,x,v,t} \times u_{x,v,t} \quad \forall v, t \quad (29)$$

$$\sum P_t - D_t \leq M \times u_{v,t} \quad \forall v, t \quad (30)$$

$$\sum P_t - D_t \geq \varepsilon - M(1 - u_{v,t}) \quad \forall v, t \quad (31)$$

$$D_t - \sum P_t \leq M \times u_{x,v,t} \quad \forall v, t \quad (32)$$

$$D_t - \sum P_t \geq \varepsilon - M(1 - u_{x,v,t}) \quad \forall v, t \quad (33)$$

تابع هدف باتری نیز مطابق رابطه‌ی ۳۴ و محدودیت‌های آن نیز براساس نوشتار کبیری‌فر و همکاران (۲۰۲۲)،^[۱۱] مطابق رابطه‌های ۳۵ الی ۴۱ هستند.

$$F(b) = \sum_t \sum_b ((C_b \times P_{b,t}) + (C_{cc} \times P_{b,t}) + (C_{dc} \times x_{v,t}) + C_{bmc}) \quad (34)$$

$$SOC_b + (\eta_b \times P_{b,t}) - \left(\frac{x_{b,t}}{\eta_b} \right) \leq E_b \quad \forall b, t \quad (35)$$

محدودیت ۳۵، دینامیک سطح انرژی ذخیره‌شده در باتری را مدل می‌کند. همچنین تضمین می‌کند که سطح انرژی باتری در هر ساعت، با در نظر گرفتن میزان شارژ، تخلیه، و راندمان، از ظرفیت کل باتری تجاوز نکند.

$$P_{b,t} \leq P_{real,b,t} \times u_{b,t} \quad \forall b, t \quad (36)$$

$$P_{b,t} \leq P_{real,x,b,t} \times u_{x,b,t} \quad \forall b, t \quad (37)$$

$$\sum P_t - D_t \leq M \times u_{b,t} \quad \forall b, t \quad (38)$$

$$\sum P_t - D_t \geq \varepsilon - M(1 - u_{b,t}) \quad \forall b, t \quad (39)$$

$$D_t - \sum P_t \leq M \times u_{x,b,t} \quad \forall b, t \quad (40)$$

⁶Fleischer

⁴Nandkeolyar & KumarRay

جواب‌های برتر قبلی پیش‌بینی کرده است؛ که جواب اصلاح‌شده، جایگزین جواب اولیه در جمعیت GA می‌شود.

این فرایند ترکیبی باعث می‌شود که جستجوی الگوریتم ژنتیک به جای تکیه بر تغییرات کاملاً تصادفی، با استفاده از دانش انباشته‌شده در شبکه‌ی ELM، به سمت مناطق امیدبخش‌تر فضای جواب هدایت شود. در نتیجه، همگرایی به راه‌حل‌های با کیفیت و پایدار تسریع می‌شود و کیفیت نهایی جواب بهبود می‌یابد.

۴. بررسی نتایج

برای پیاده‌سازی و حل مدل‌ها از دو بستر محاسباتی مجزا استفاده شده است. مدل برنامه‌ریزی خطی عدد صحیح با استفاده از نرم‌افزار GAMS بر روی یک رایانه‌ی شخصی با مشخصات پردازنده‌ی CPU M380@2/53GHz و ۳ گیگابایت حافظه‌ی RAM حل شده است. الگوریتم ترکیبی ELM-GA نیز با استفاده از زبان برنامه‌نویسی پایتون در محیط Google Colaboratory پیاده‌سازی و اجرا شده است. برای اجرای الگوریتم ELM-GA، از منابع محاسباتی استاندارد فراهم‌شده توسط Colab، شامل شتاب‌دهنده‌ی گرافیکی (GPU) استفاده شده است، تا سرعت فرآیندهای یادگیری ماشین افزایش یابد.

نیروگاه مجازی بررسی‌شده در پژوهش حاضر، شامل: یک نیروگاه دیزلی با ظرفیت ۱۰۰ مگاوات، یک مزرعه‌ی خورشیدی با توان ۱۰۰ کیلووات، شش توربین بادی با مجموع توان ۵۰ کیلووات، نیروگاه هیدروالکتریک متشکل از چهار واحد ۵۰ مگاواتی، یک باتری با ظرفیت ۴ کیلووات، و یک ماشین الکتریکی با ظرفیت ۱۹/۲ کیلووات بوده است.

۱.۴. مطالعه‌ی موردی (داده‌ها)





مقادیر تقاضا، سرعت باد، دما، و میزان تابش در شبانه‌روز بررسی‌شده (اول دی‌ماه ۱۴۰۰)، از داده‌های واقعی استان یزد استخراج شده‌اند، که نمودارهای آن‌ها در شکل ۲ مشاهده می‌شوند.

قیمت خرید برق از هر نیروگاه به‌طور متوسط ۵۳/۰۶ تومان به ازاء هر کیلووات ساعت و هزینه‌ی سوخت برای نیروگاه دیزلی، ۴۰ تومان به ازاء هر مترمکعب و همچنین، دمای مرجع در نیروگاه خورشیدی و تابش استاندارد به ترتیب ۲۹/۵ و ۱۰۰۰ بوده است. اطلاعات توربین‌های بادی، مطابق نوشتار ژائوکسیا^۵ و همکاران (۲۰۱۷)،^[۱۶] در نظر گرفته شده است. در شبکه‌ی بررسی‌شده، ۶ ذخیره‌ساز در سمت تقاضا وجود داشته است، که حجم هر منبع ذخیره‌ساز ۷۰۰ مترمکعب و کمینه و بیشینه‌ی سطح آب داخل آن، ۱۵ و ۹۰ درصد حجم کل بوده است. منبع مذکور، که برای تأمین آب استانی با ظرفیت حدودی ۱/۳ میلیون استفاده شده است، در ارتفاع ۵ متری از سطح زمین قرار گرفته و خود آن نیز ۴ متر ارتفاع داشته است.


۲.۴. مقایسه‌ی عملکرد روش‌ها

مقایسه‌ی توان خروجی مجموعه‌ی نیروگاه‌های هیدروالکتریک با استفاده از دو روش MILP و ELM-GA در شکل ۳ مشاهده می‌شود.


در روش MILP فقط از دو واحد برای تولید انرژی استفاده شده است. چون برای پاسخ به تقاضا، فقط به انرژی تولیدی دو واحد نیاز است و هزینه‌ها و




شکل ۲. داده‌های مربوط به تقاضا، سرعت باد، دما، و تابش شبکه‌ی موردنظر در یک شبانه‌روز (اول دی‌ماه ۱۴۰۰).




شکل ۳. مقایسه‌ی توان خروجی واحدهای هیدروالکتریک در دو روش MILP و ELM-GA.




شکل ۵. مقایسه‌ی توان خروجی نیروگاه دیزلی در دو روش MILP و ELM-GA



شکل ۴. مقایسه‌ی توان خروجی توربین‌های بادی در دو روش MILP و ELM-GA



شکل ۶. مقایسه‌ی توان خروجی نیروگاه خورشیدی در دو روش MILP و ELM-GA



شکل ۷. مقایسه‌ی توان خروجی ماشین الکتریکی در دو روش MILP و ELM-GA

مقایسه‌ی توان واقعی نیروگاه دیزلی، نیروگاه خورشیدی، ماشین الکتریکی، و باتری با استفاده از دو روش MILP و ELM-GA، در شکل‌های ۵ الی ۸ مشاهده می‌شود.

نتایج روش MILP نشان می‌دهند که نیازی نیست تا نیروگاه دیزلی در توان نامی خود و یا حتی نزدیک به آن کار کند؛ بلکه فقط کافی است با بیشینه‌ی حدود ۸۳٪ ظرفیتش کار کند. نیروگاه خورشیدی نیز فقط در ۱۰ ساعت انرژی تولید می‌کند و در شبکه حضور دارد؛ زیرا مقدار تابش مناسب برای به کار افتادن پنل‌ها فقط در همان ۱۰ ساعت وجود دارد. روش اخیر نشان می‌دهد که در شبانه‌روز بررسی شده، نیازی به حضور باتری نیست و فقط هزینه‌ی وجود باتری به سیستم تحمیل می‌شود. لذا، با توجه به نتایج به‌دست‌آمده، می‌توان باتری یا به نوعی ذخیره‌ساز سمت عرضه را از سیستم حذف کرد. اما در ساعت اولیه‌ی روز نیاز است تا ماشین الکتریکی در

تلفات نیز باید به میزان کمینه برسند. روش MILP، استفاده از دو واحد را پیشنهاد کرده است و دو واحد دیگر در ۲۴ ساعت بررسی شده، انرژی تولید نکرده‌اند. پس هزینه‌ی نگهداری و تعمیرات برای ۴ واحد محاسبه شده است، در حالی که آورده‌ای ندارند؛ اما تلفات نیروگاه را کمینه می‌سازند.

در روش ELM-GA، هر چهار واحد هیدروالکتریک موجود در ریزشکبه‌ی بررسی شده در هر ساعت از شبانه‌روز در حال کار بوده و انرژی تولید کرده‌اند. علاوه بر این، نتایج پژوهش حاضر و نتایج منتشرشده در نوشتار دهقانی و همکاران (2024)^[۱۹] نشان می‌دهند که واحدهای هیدروالکتریک در ظرفیتی کمتر از ظرفیت نامی خود مشغول به کار هستند و نیازی به تولید انرژی با بیشینه‌ی ظرفیت و توان برای پاسخ به تقاضا وجود ندارند.


نتایج و ویژگی‌های روش یادگیری ماشین را با توجه به مسئله‌ی بررسی شده، می‌توان در این موارد دانست:

- در نیروگاه مجازی از موارد قبلاً احداث شده استفاده شده است، که در این صورت استفاده‌ی بیشینه از واحدهای موجود با کمینه‌ی هزینه بهتر خواهد بود.
- روش ذکرشده‌ی نیروگاه دیزلی می‌تواند با استفاده از نصف ظرفیت خود، تقاضا را پاسخ دهد. در نتیجه نیازی به کار در بیشینه‌ی ظرفیت نیست.

در شکل ۴، مقایسه‌ی توان واقعی مجموعه‌ی توربین‌های بادی با دو روش MILP و ELM-GA مشاهده می‌شود.

نتایج روش MILP به‌درستی نشان می‌دهند که توربین‌های بادی فقط در ۲۱ ساعتی که وزش باد کافی وجود داشته است، فعال بوده و توان تولید کرده‌اند و در ساعت‌های باقی‌مانده فعالیت نداشته‌اند. نتیجه‌ی اخیر، همخوانی کامل عملکرد مدل را با شرایط ورودی باد تأیید می‌کند.

همچنین روش MILP تصریح می‌کند که کمینه‌ی هزینه‌های توربین‌های بادی در صورتی اتفاق می‌افتد که بار شبکه به میزان مساوی بین توربین‌های مشابه تقسیم شود. در نتیجه، توان تولیدی توربین‌های مشابه در هر ساعت به‌طوریکسان محاسبه شده است. اما نتایج به‌دست‌آمده از روش ELM-GA نشان می‌دهند که کاهش هزینه‌ها در تولید انرژی غیریکسان در توربین‌های مشابه اتفاق افتاده است. همچنین باید گفت که نوسان تولید انرژی از طریق توربین‌های بادی در روش ELM-GA به‌طور چشمگیری کمتر از روش MILP بوده است؛ که دلیل آن را می‌توان تولید غیرمشابه توربین‌های مشابه دانست.



شکل ۹. توان مصرفی پمپ‌های ذخیره‌ساز از روش ELM-GA.


ساعات‌های شبانه‌روز روشن و در بیشینه‌ی توان خود، یعنی ۹۰ کیلووات، در حال کار باشند. در نتیجه، توان مصرفی هر ۶ ذخیره‌ساز در همه‌ی ساعات‌های شبانه‌روز یکسان و برابر با ۵۴۰ کیلووات به‌دست آمده است. همچنین تلفات تولید نیروگاه‌های هیدروالکتریک نیز برابر با مقدار $832710/2$ بوده است. هزینه‌ی عملیاتی کل پمپ‌ها را می‌توان برابر با مقدار $761/1$ و $C_{op,p}=36794/6$ تومان محاسبه کرد.

نتایج حاصل از روش ELM-GA، وجود توان رزرو را در هر ساعت و برای واحدهای درگیر تولید انرژی نشان می‌دهد. مطابق نتایج اخیر، در هر ۶ پمپ، یک ذخیره‌ساز در تمامی ساعات‌های شبانه‌روز روشن بوده است و توان مصرفی آن‌ها در شکل ۹ مشاهده می‌شود. در روش ELM-GA نیز مانند روش MILP، پمپ‌ها در همه‌ی ساعات‌ها روشن بوده‌اند، اما با ظرفیت کمتر کار کرده‌اند. همچنین تلفات تولید نیروگاه‌های هیدروالکتریک نیز برابر با مقدار 860922 به‌دست آمده است، که از مقدار به‌دست‌آمده در روش قبل بیشتر بوده است، زیرا جواب به‌دست‌آمده از روش قبل بر بهینه‌ی کل دلالت دارد.

هزینه‌ی عملیاتی کل پمپ‌ها را می‌توان برابر مقدار 264873 و $C_{op,p}=12789624/36$ تومان محاسبه کرد، که افزایش فاحش نسبت به روش MILP را نشان می‌دهد.

روش MILP برای کمینه‌ساختن هزینه‌ها و تلفات تا جای ممکن سعی می‌کند عناصر درگیر در نیروگاه مجازی، به میزان کمینه حضور داشته باشند؛ ولی با بیشینه‌ی توان موردنیاز استفاده شوند. علاوه بر این، نشان داده شده است که برای رسیدن به اهداف تعریف‌شده، تقسیم بار بین واحدهای مشابه و تولید مقادیر انرژی مشابه از طریق واحدهای مذکور بر سایر روش‌ها ارجحیت دارد. اما در روش ELM-GA، همه‌ی عناصر نیروگاه مجازی به انجام وظایف خود پرداخته و هیچ‌کدام هزینه‌ی نگهداری را بدون داشتن آورده‌ای به سیستم تحمیل نکرده‌اند. درنهایت، مشارکت بهینه‌ی واحدها در دو روش، در شکل‌های ۱۰ و ۱۱ مشاهده می‌شود.

در شرایط ذکرشده و بدون حضور و استفاده از نیروگاه مجازی و مدیریت‌کننده‌ی سمت تقاضا، نیروگاه‌ها باید به‌تنهایی کار کنند و در هر ساعت، با توجه به شرایط جوی، توان تولیدی بیشینه را فراهم سازند. همچنین در شرایط واقعی، باتری و ماشین الکتریکی در زمانی که مازاد تولید وجود دارد، شارژ و در ساعات‌های پیک



شکل ۸. مقایسه‌ی توان خروجی باتری در دو روش MILP و ELM-GA.

بیشینه‌ی توان خود شارژ شود؛ تا علاوه بر کاهش هزینه‌ها، شکاف بین عرضه و تقاضا نیز کاهش یابد؛ زیرا در آن ساعت، مازاد تولید اتفاق می‌افتد.

با توجه به شکل‌های اخیر می‌توان این موارد را استنتاج کرد:

- نیروگاه دیزلی در روش ELM-GA، نوسان بیشتری را تجربه می‌کند؛ اما فقط از حدود نصف ظرفیت نامی برای تولید انرژی استفاده می‌کند. این در حالی است که در روش MILP از حدود ۸۳٪ ظرفیت نامی بهره می‌برد.
- بیشینه‌ی تولید نیروگاه خورشیدی در روش MILP در حدود ۷ صبح اتفاق می‌افتد؛ اما در روش ELM-GA، بیشینه‌ی تولید در ۱۱ صبح اتفاق می‌افتد.
- در روش MILP ماشین الکتریکی فقط در ساعت اول شارژ می‌شود؛ اما در روش ELM-GA، ماشین الکتریکی شارژ و تخلیه را با توجه به نیاز شبکه در ساعات‌های مختلف تجربه می‌کند.
- باتری در روش MILP هیچ شارژ و تخلیه‌ای را تجربه نمی‌کند و فقط هزینه‌ی نگهداری را به سیستم تحمیل می‌کند؛ اما در روش ELM-GA، باتری نیز در نیروگاه مجازی نقش دارد و شارژ و تخلیه را تجربه می‌کند.


۳.۴. تحلیل سناریوها

مقدار تابع هدف مربوط به نیروگاه مجازی در روش MILP، یعنی سود حاصل برابر با مقدار 1350 - میلیون تومان به‌دست آمده است. البته با توجه به اینکه مقدار درآمد از هزینه‌ها کمتر بوده است، مقدار به‌دست‌آمده، زیان شبکه را نشان می‌دهد. مقدار تابع هدف مربوط به نیروگاه مجازی در روش ELM-GA برابر با مقدار 1678 - میلیون تومان به‌دست آمده است؛ که نشان می‌دهد هزینه‌ها در روش ELM-GA بیشتر از روش MILP است و جواب روش قبل بر بهینه‌ی کلی دلالت دارد. روش ELM-GA به نقطه‌ی بهینه نزدیک شده است، اما نتوانسته است به بهینه‌ی کل دست پیدا کند.

مطابق نتایج به‌دست‌آمده از روش MILP، وجود توان رزرو برای هر واحد نیروگاه هیدروالکتریک در ساعات‌های مختلف ضروری است. حتی با اینکه ۲ واحد از ۴ واحد در شبانه‌روز موردبحث انرژی تولید نمی‌کنند، در ساعات‌های مختلف نیاز به توان رزرو دارند. روش موردنظر برای کمینه‌ساختن هزینه‌ی عملیاتی پمپ‌ها پیشنهاد داده است که هر ۶ پمپ یک ذخیره‌ساز، در تمامی



شکل ۱۰. مشارکت واحدهای درگیر در نیروگاه مجازی در روش MILP.



شکل ۱۱. مشارکت واحدهای درگیر در نیروگاه مجازی در روش ELM-GA.

جدول ۵. مجموع توان نامی هر نوع نیروگاه بررسی شده در مطالعه‌ی ژائوکسیا و همکاران.^[۱۶]

Power plant	Diesel	Solar	Wind	Battery
Total rated power (kW)	30	40	50	4

نسبت به پژوهش ذکر شده کاهش یافته است، که می‌تواند نشانگر تأثیر استفاده و بهره‌گیری از نیروگاه مجازی در کاهش هزینه‌ها باشد.

برای مقایسه‌ی عملکرد نیروگاه مجازی در حضور مدیریت‌کننده‌ی سمت تقاضا و عدم حضور آن، پژوهش حاضر با پژوهش ژائوکسیا و همکاران (۲۰۱۷)،^[۱۶] مقایسه شده است؛ که ایشان، یک نیروگاه مجازی شامل ۶ توربین بادی، ۴ پنل خورشیدی، ۱ واحد نیروگاه دیزلی، و ۱ باتری را در نظر گرفته و توان خروجی هر واحد و هزینه‌های آن‌ها را محاسبه کرده‌اند. مجموع توان هر نوع نیروگاه بررسی شده توسط ایشان، در جدول ۵ ارائه شده است.

مصرف تخلیه می‌شوند. اما نتایج حاصل از روش‌های پیشنهادی، تصمیم‌های دیگری را برای دو عضو مذکور اتخاذ کرده‌اند. در این حالت، سود فروش انرژی به مقدار ۳۰۱۵۷۷۰۰۱۰۰- رسیده است. این رقم درحالی به‌دست آمده است که سود روش برنامه‌ریزی خطی برابر با ۱۳۵۰- و سود روش یادگیری ماشین برابر با ۱۶۷۸- بوده است. مقایسه‌ی اعداد نشان می‌دهد که استفاده از نیروگاه مجازی در کاهش زیان مؤثر و راه‌حل مناسب‌تری نسبت به بازار انحصاری بوده است. ناندکئولیار و کومار ری (۲۰۲۲)،^[۱۰] شبکه‌ای سنتی به همراه مدیریت‌کننده‌ی سمت تقاضا را در نظر گرفته و تعداد دفعه‌های تغییر وضعیت پمپ‌ها از روشن به خاموش و بالعکس را در حالت MILP برابر با ۱۱۰۸ و در حالت استفاده از الگوریتم ELM-GA برابر با ۷۸۲ بار در یک شبانه‌روز به‌دست آورده‌اند. همچنین نمودارهای ارائه شده در پژوهش اخیر نشان می‌دهند که توان مصرفی پمپ‌ها در هر ساعت متفاوت بوده و نوسان را تجربه کرده‌اند.

با توجه به نتایج، دفعه‌های تغییر پمپ‌ها به وضعیت روشن و خاموش در هر دو حالت حل از مقادیر به‌دست آمده در نوشتار ناندکئولیار و کومار ری (۲۰۲۲)،^[۱۰] کمتر بوده و توان مصرفی پمپ‌ها نیز نوسان کمتری را تجربه کرده‌اند. در نتیجه، هزینه‌های عملیاتی پمپ‌ها و هزینه‌ی ذخیره‌سازها در پژوهش حاضر

جدول ۶. مقایسه‌ی توان‌های واقعی تولیدی با نوشتار ژائوکسیا و همکاران (۲۰۱۷)^[۱۶] (کیلووات).

Time	[16]	MILP	ELM-GA
00:00-1:00	29.6	43.7	156.3
1:00-2:00	19.2	42.1	157.9
2:00-3:00	25.6	54.0	166.5
3:00-4:00	13.8	63.4	180.5
4:00-5:00	11.5	73.4	177.6
5:00-6:00	11.1	70.6	173.8
6:00-7:00	18.9	76.0	172.4
7:00-8:00	30.9	54.0	150.8
8:00-9:00	58.6	64.5	157.5
9:00-10:00	34.0	58.3	153.2
10:00-11:00	75.6	46.2	146.7
11:00-12:00	69.8	52.3	150.0
12:00-13:00	63.2	41.0	138.8
13:00-14:00	60.2	34.8	135.9
14:00-15:00	80.5	59.6	155.2
15:00-16:00	60.0	50.1	151.9
16:00-17:00	48.3	35.9	140.6
17:00-18:00	44.7	37.6	138.8
18:00-19:00	31.5	37.2	139.4
19:00-20:00	30.0	36.5	140.1
20:00-21:00	30.0	50.6	148.5
21:00-22:00	30.0	48.7	150.0
22:00-23:00	32.6	48.6	151.2
23:00-24:00	29.6	46.7	153.1

جهت مقایسه‌ی نتایج پژوهش حاضر با نتایج نوشتار ژائوکسیا و همکاران (۲۰۱۷)^[۱۶] واحدهای تولیدکننده‌ی انرژی باید متناسب‌سازی شوند؛ بدین صورت که واحدهای هیدروالکتریک و ماشین‌الکتریکی از پژوهش حاضر حذف و مجموع توان نامی واحدهای باقی‌مانده مطابق جدول ۵ در نظر گرفته شده و توان‌های واقعی به‌دست‌آمده در بخش‌های قبل، متناسب‌سازی شده‌اند. در بخش حاضر، وابستگی توان تولیدی به تقاضا نادیده گرفته شده است.

مجموع توان واقعی تولیدی توسط واحدهای دو پژوهش بررسی شده در هر ساعت شبانه‌روز، در جدول ۶ ارائه شده‌اند؛ که مطابق آن، توان تولیدی در نیروگاه مجازی با حضور مدیریت‌کننده‌ی سمت تقاضا بیشتر از حالت عدم حضور مدیریت‌کننده بوده است؛ در نتیجه، هزینه‌ها نیز در حضور مدیریت‌کننده‌ی سمت تقاضا بیشتر بوده است، که می‌تواند ناشی از نیاز پمپ‌ها به مصرف انرژی علاوه‌بر تقاضای مؤثر شبکه باشد. با وجود افزایش هزینه‌ها در کوتاه‌مدت، نوسان انرژی تولیدی در حالتی که مدیریت‌کننده‌ی سمت تقاضا

وجود دارد، کمتر از حالت دیگر است. به‌عبارت دیگر، کاهش نوسان می‌تواند نشان‌دهنده‌ی کاهش شکاف بین عرضه و تقاضا باشد، که یکی از اهداف اصلی استفاده از نیروگاه مجازی است. همچنین می‌توان اظهار داشت که کاهش نوسان تولید انرژی، فشار کمتری به شبکه و نیروگاه موردنظر وارد می‌کند و هزینه‌ها، به‌خصوص هزینه‌ی نگهداری و تعمیرات را در بلندمدت کاهش می‌دهد.

۴.۴. تحلیل حساسیت

کارایی الگوریتم ترکیبی ELM-GA، ریشه در نقش کلیدی مؤلفه‌ی یادگیری ماشین (ELM) در بهبود فرآیند بهینه‌سازی دارد. در صورت حذف بخش ELM، الگوریتم به یک الگوریتم ژنتیک (GA) استاندارد تبدیل می‌شود، که برای رسیدن به جواب با کیفیت، نیازمند بودجه‌ی محاسباتی بسیار بالایی (شامل جمعیت بزرگ‌تر و تعداد نسل‌های بیشتر) و در نتیجه، زمان حل طولانی‌تری است. در ساختار ترکیبی، ELM به‌عنوان یک عملگر هوشمند، با یادگیری الگوهای موجود در جواب‌های برتر، جستجوی الگوریتم ژنتیک را به سمت مناطق امیدبخش‌تر فضای جواب هدایت می‌کند. فرآیند اخیر، هم از همگرایی زودرس جلوگیری می‌کند و هم سرعت رسیدن به یک جواب همگرا تر و باکیفیت‌تر را به‌طور قابل‌توجهی تسریع می‌سازد.

برای مقایسه‌ی سرعت و کیفیت حل دو روش مذکور، براساس تعداد واحدهای حاضر در نیروگاه مجازی، مسائلی با داده‌های تصادفی در سه محدوده‌ی ابعادی کوچک (تا ۲۰ واحد نیروگاهی)، متوسط (۲۰ تا ۴۰ واحد نیروگاهی) و بزرگ (۴۰ تا ۶۰ واحد نیروگاهی) در نظر گرفته شده‌اند. برای تحلیل اخیر، واحدهای جدید به‌صورت تصادفی و با مشخصات فنی و اقتصادی مشابه با انواع واحدهای تعریف‌شده در مطالعه‌ی موردی اصلی (شامل واحدهای دیزلی، خورشیدی، بادی، و...) تولید شده‌اند. بازه‌ی زمانی ۴۸ ساعت برای رسیدن به پاسخ معین شده است. در مقایسه‌ی انجام‌شده، مقدار جمعیت در روش ELM-GA برابر ۱۰ و تعداد تولید نسل برابر ۵۰ در نظر گرفته شده است؛ که نتایج آن در جدول‌های ۷ الی ۹ ارائه شده است.

همان‌طور که در جدول‌های اخیر مشخص است، در مسائلی با ابعاد کوچک و متوسط، روش MILP علاوه‌بر دستیابی به بهینه‌ی کلی، زمان کمتری نیز در رسیدن به جواب صرف کرده است. این در حالی است که در روش ELM-GA نه فقط زمان بیشتری صرف شده است، بلکه مقدار نزدیک به بهینه به‌دست آمده است. اما با بالا رفتن ابعاد مسئله و رسیدن به ۶۰ واحد، زمان روش MILP به‌طرز چشمگیری بالا رفته است، در حالی که در روش دیگر زمان بسیار کمتری صرف شده است. با توجه به نتایج سایر مسئله‌ها و نزدیک‌بودن جواب به‌دست‌آمده از روش ELM-GA به بهینه‌ی کلی، می‌توان در مسائلی با ابعاد بزرگ از روش اخیر برای صرف زمان کمتر استفاده کرد و اطمینان داشت که جواب به‌دست‌آمده به بهینه‌ی کلی نزدیک است.

از این ویژگی می‌توان برای توسعه‌ی زیرساخت‌های تولید انرژی متناسب با تغییر تقاضا و تعریف سیاست‌های مناسب استفاده کرد. بدین صورت که با استفاده از داده‌های پیشین و تاریخچه‌ی هواشناسی و مصرف انرژی در مکانی خاص، ماشین آموزش داده می‌شود و سپس به‌وسیله‌ی داده‌ها و پیش‌بینی‌های هواشناسی روز-های آتی، از ماشین خواست تا پیش‌بینی تقاضای انرژی در روزهای موردنظر را ارائه کند. در نتیجه، با صرف زمانی کمتر، نتایجی نزدیک به بهینه به‌دست می‌آید، که می‌تواند مبنای تصمیم‌گیری و سیاست‌گذاری باشد.

جدول ۷. مقایسه‌ی سرعت و کیفیت حل دو روش MILP و ELM-GA در مسائلی با ابعاد کوچک.

Number of units	Solution time (seconds)		Objective function (million)		Optimality gap (%)
	MILP	ELM-GA	MILP	ELM-GA	
10	0.129	4.5	-991.3	-1036	45.1
12	0.137	5	-1022.5	-1177	15.1
14	0.252	7	-1022.5	-1215	18.8
16	0.255	9	-1022.6	-1285	25.7
18	0.258	11	-1922.6	-1340	31.0

جدول ۸. مقایسه‌ی سرعت و کیفیت حل دو روش MILP و ELM-GA در مسائلی با ابعاد متوسط.

Number of units	Solution time (seconds)		Objective function (million)		Optimality gap (%)
	MILP	ELM-GA	MILP	ELM-GA	
20	0.42	23	-2124.97	-2173	2.3
24	0.97	67	-2125	-2320	9.2
28	1.45	94	-2125.02	-2338	10.0
32	1.80	131	-2125.03	-2341	10.2
36	2.54	173	-2125.01	-2397	12.8

جدول ۹. مقایسه‌ی سرعت و کیفیت حل دو روش MILP و ELM-GA در مسائلی با ابعاد بزرگ.

Number of units	Solution time		Objective function		Optimality gap (%)
	MILP	ELM-GA	MILP	ELM-GA	
42	6 (s)	14 (min)	-3227	-3886	20.4
50	100 (s)	56 (min)	-4330	-4755	10.3
60	More than 48 hour	180 (min)	-5432	-5670	4.4

۵. نتیجه‌گیری

هدف از انجام پژوهش حاضر، تشویق به گذر از بازار انحصاری با احداث نیروگاه مجازی و کاهش شکاف بین عرضه و تقاضا با استفاده از ذخیره‌سازها در سمت تقاضا بوده است؛ که با مقایسه‌ی شبکه‌ی برق سنتی با نیروگاه مجازی در حضور و عدم حضور مدیریت‌کننده‌ی سمت تقاضا و بررسی سود و زیان ناشی آن دنبال شده است. از اهداف دیگر پژوهش حاضر، می‌توان به استفاده از یادگیری ماشین برای افزایش سرعت حل مدل‌ها و پیش‌بینی جهت برنامه‌ریزی آینده اشاره کرد. فراتر از نتایج فنی، یافته‌های پژوهش حاضر، بینش‌های مدیریتی مهمی را برای سیاست‌گذاران و مدیران این حوزه فراهم کرده است. اولاً، توجه‌پذیری اقتصادی چارچوب نیروگاه مجازی به‌عنوان یک جایگزین برتر برای شبکه‌ی سنتی، یک دلیل محکم برای سرمایه‌گذاری در تجمیع منابع انرژی پراکنده است. ثانیاً، نتایج نشان می‌دهند که مدیریت سمت تقاضا، علی‌رغم هزینه‌های

عملیاتی اولیه، یک سرمایه‌گذاری راهبردی بلندمدت برای افزایش پایداری شبکه و کاهش هزینه‌های آتی نگهداری است. درنهایت، مقایسه‌ی روش‌های حل به مدیران نشان می‌دهد که برای تصمیم‌گیری‌های راهبردی و آفلاین، دقت روش‌های دقیقی مانند MILP ارجحیت دارد، در حالی که برای عملیات روزانه و آنلاین که سرعت، یک مسئله‌ی حیاتی است، ابزارهای هوشمند و سریع (ELM-GA) کارایی بسیار بیشتری دارند.

مدل پیشنهادی شامل بهینه‌سازی تابع سود و کمینه‌سازی تلفات نیروگاه هیدروالکتریک و هزینه‌ی عملیاتی پمپ‌ها بوده و با در نظر گرفتن عدم قطعیت تقاضا و شرایط آب‌وهوایی در شبانه‌روز، با استفاده از روش‌های MILP و ELM-GA حل و نتایج مقایسه شده‌اند. در پژوهش‌های آینده می‌توان مواردی از جمله بررسی و مدل‌سازی بازار رقابت عمده‌فروشی، در نظر گرفتن خرابی‌های برنامه‌ریزی‌نشده، و سایر الگوریتم‌های یادگیری ماشین را بررسی کرد.

References – منابع

1. Awerbuch, S. and Preston, A., 1997. The Virtual Utility: Accounting, Technology & Competitive Aspects of the Emerging Industry. *Springer: Berlin/Heidelberg*.
<https://books.google.com/books?hl=en&lr=&id=BX3rBwAAQBAJ&oi=fnd&pg=PR13&dq=1.%09Awerbuch,+S.,+Preston,+A.,+1997.+The+Virtual+Utility:+Accounting,+Technology+%26+Competitive+Aspects+of+the++++Emerging+Industry.+Springer:+Berlin/Heidelberg&ots=n5ySfEIyFp&sig=64S7tKZufYrpka9Zw4gI429REpM>
2. Borenstein, S. and Bushnell, J., 2015. The U.S. electricity industry after 20 years of restructuring. *National Bureau of Economic Research*, 7(1), pp.437-463. <https://doi.org/10.1146/annurev-economics-080614-115630>
3. Narkhede, M., Chatterji, S. and Ghosh, S., 2013. Multi objective optimal dispatch in a virtual power plant using genetic algorithm. *International Conference on Renewable Energy and Sustainable Energy*.
<https://doi.org/10.1109/ICRESE.2013.6927822>
4. Mao, T., Guo, X., Xie, P., Zhou, J., Zhou, B., Han, S., Wu, W. and Sun., L., 2020. Virtual power plant platforms and their applications in practice: a brief review. 2020 *IEEE Sustainable Power and Energy Conference (iSPEC)* pp.2071-2076. *IEEE*.
[10.1109/iSPEC50848.2020.9351147](https://doi.org/10.1109/iSPEC50848.2020.9351147)
5. Abdelaziz, Y. A., Hegazy, Y. G., Elkhattam, W. and Othman, M., 2013. Virtual power plant: The future of power delivery systems. *Second European Workshop on Renewable Energy Systems*. pp.1-2.
https://www.academia.edu/download/72762869/VIRTUAL_POWER_PLANT_THE_FUTURE_OF_POWER_20211015-20727-10e0k2l.pdf
6. Rouzbahani, H. M., Karimipour, H. and Lei, L., 2021. A review on virtual power plant for energy management. *Sustainable Energy Technologies and Assessments*, 47, pp.101370.
<https://doi.org/10.1016/j.seta.2021.101370>
7. Warren, P., 2014. A review of demand-side management policy in the UK. *Renewable and Sustainable Energy Reviews*, 29, pp.941-951.
<https://doi.org/10.1016/j.rser.2013.09.009>
8. Park, S. and Son, S., 2020. Interaction-based virtual power plant operation methodology for distribution system operator's voltage management. *Applied Energy*, 271, pp.115222.
<https://doi.org/10.1016/j.apenergy.2020.115222>
9. Aguilar, J., Bordons, C. and Arce, A., 2021. Chance Constraints and Machine Learning integration for uncertainty management in Virtual Power Plants operating in simultaneous energy markets. *International Journal of Electrical Power & Energy Systems*, 133, pp.107304.
<https://doi.org/10.1016/j.ijepes.2021.107304>
10. Nandkeolyar, S. and KumarRay, P., 2022. Multi objective demand side storage dispatch using hybrid extreme learning machine trained neural networks in a smart grid. *Journal of Energy Storage*, 51, pp.104439.
<https://doi.org/10.1016/j.est.2022.104439>
11. Kabirifar, M., Pourghaderi, N. and Moeini-Aghaie, M., 2022. Optimal operation strategy of virtual power plant considering EVs and ESSs. *Scheduling and Operation of Virtual Power Plants*, pp.257-297.
<https://doi.org/10.1016/B978-0-32-385267-8.00017-2>
12. Ali, Y., 2023. A novel machine learning-based power trading algorithm (MLPTA) for demand side management (DSM). 2023 *International Conference on Emerging Power Technologies (ICEPT)* pp.1-5. *IEEE*.
<https://doi.org/10.1109/ICEPT58859.2023.10152394>
13. Karimi, H., Jadid, S. and Hasanzadeh, S., 2023. Optimal-sustainable multi-energy management of microgrid systems considering integration of renewable energy resources: A multi-layer four-objective optimization. *Sustainable Production and Consumption*, 36, pp.126-138.
<https://doi.org/10.1016/j.spc.2022.12.025>
14. Ahmadian, A., Ponnambalam, K., Almansoori, A. and Elkamel, A., 2023. Optimal management of a virtual power plant consisting of renewable energy resources and electric vehicles using mixed-integer linear programming and deep learning. *Energies*, 16(2), pp.1000. <https://doi.org/10.3390/en16021000>
15. Singh, S., Subburaj, V., Sivakumar, K., Kumar, R., Muthuramam, M. S., Rastogi, R., Patil, V. R. and Rajaram, A., 2024. Optimum power forecasting technique for hybrid renewable energy systems using deep learning. *Electric Power Components and Systems*, pp.1-18.
<https://doi.org/10.1080/15325008.2024.2316251>
16. Zhaoxia, X., Jiakai, N., Guerrero, J. and Hongwei, F., 2017. Multiple time-scale optimization scheduling for islanded microgrids including PV, wind turbine, diesel generator and batteries. *IECON 2017 - 43rd Annual Conference of the IEEE Industrial Electronics Society*, pp.2594-2599. *IEEE*.
<https://doi.org/10.1109/IECON.2017.8216436>
17. Ullah, Z., Arshad, and Hassanin, H., 2017. Modeling, optimization, and analysis of a virtual power plant demand response mechanism for the internal electricity market considering the uncertainty of renewable energy sources. *Energies*, 15(14), pp.5296.
<https://doi.org/10.3390/en15145296>

18. Fleischer, C., Waag, W., Bai, Z. and Sauer, D.U., 2013. Adaptive on-line state-of-available-power prediction of lithium-ion batteries. *Journal of Power Electronics*, 13(4), pp.516-527. <https://doi.org/10.6113/JPE.2013.13.4.516>
19. Dehghani, B., Lotfi, M. and Sedighi, A., 2024. Development of machine learning algorithm for energy supply management in virtual power plant. <https://ganj.irandoc.ac.ir/#/articles/0e46b15100029e1032001d2255207137>. [In Persian]