

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

بنت‌الهدی دهقانی

کارشناسی‌ارشد، گروه مهندسی صنایع، دانشگاه یزد، یزد، ایران hodadehghani@stu.yazd.ac.ir

محمد مهدی لطفی^۱

استاد، گروه مهندسی صنایع، دانشگاه یزد، یزد، ایران lotfi@yazd.ac.ir

علیرضا صدیقی

دانشیار، دانشکده مهندسی برق، دانشگاه یزد، یزد، ایران sedighi@yazd.ac.ir

چکیده

در این پژوهش، مسأله مشارکت بهینه واحدها در یک نیروگاه مجازی با ذخیره‌ساز سمت تقاضا، جهت کاهش شکاف بین عرضه و تقاضای انرژی، با رویکردهای *MILP* و یادگیری ماشین مطالعه می‌شود. نتایج برای سیستم 24-بازه استاندارد *IEEE* نشان می‌دهد 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 1.5 برابر کمتر از هزینه‌های شبکه سنتی بدون ذخیره‌ساز است. برای حل مدل در ابعاد واقعی، از الگوریتم ترکیبی *ELM-GA* استفاده می‌شود که پیشنهادی نزدیک به بهینه اما با سرعت بسیار بالاتر از روش *MILP* ارائه می‌کند زیرا آموزش و یادگیری همگرایی به نقطه بهینه را تسریع می‌کند. نتایج نشان می‌دهد که با افزایش ابعاد مسأله به 60 واحد نیروگاهی، شکاف بهینگی به 4.4 درصد رسیده در حالی که سرعت حل یادگیری ماشین 16 برابر بهتر از *MILP* خواهد بود.

کلمات کلیدی: نیروگاه مجازی، مدیریت سمت تقاضا، مسئله مشارکت واحدها، برنامه‌ریزی خطی عدد صحیح، یادگیری ماشین.

^۱ نویسنده مسئول

Developing machine learning algorithm for energy supply optimization in virtual power plants

B.H. Dehghani, hodadehghani@stu.yazd.ac.ir

M.Sc. degree, Department of Industrial Engineering, Yazd University, Yazd, Iran

M. M. Lotfi, (corresponding author), lotfi@yazd.ac.ir

Professor, Department of Industrial Engineering, Yazd University, Yazd, Iran

A. Sedighi, sedighi@yazd.ac.ir

Associate Professor, Department of Electrical Engineering, Yazd University, Yazd, Iran

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 33-bus system with real-world data, the results show that a VPP with demand-side storage is 1.2 times less costly than a traditional grid without storage. Furthermore, the VPP framework is 1.5 times more cost-effective than a traditional grid structure. For large-scale problems, the ELM-GA algorithm delivers near-optimal solutions (1.5% optimality gap) 16 times faster than MILP, highlighting its potential for rapid, reliable energy management and policy-making.

Introduction

The evolution of energy markets from centralized, monopolistic structures to restructured wholesale models created an urgent need for more flexible and efficient management systems. This transition was driven by challenges including price deregulation, environmental concerns, and a lack of incentive for improving efficiency in the traditional model. In response, the Virtual Power Plant (VPP) emerged as a key innovation. A VPP is an aggregated system of decentralized, small-scale power generating and consuming units, all coordinated by a central control system to act as a single entity in the energy market. VPPs offer significant advantages over conventional power plants, including greater agility, efficiency, and cost-effectiveness, allowing them to adapt rapidly to market and demand changes while minimizing operational costs and waste.

Concurrently, the electricity industry has grappled with the persistent problem of balancing supply and demand—specifically, managing power outages during peak hours and wasted surplus energy during off-peak times. Demand-Side Management (DSM) provides a strategic solution, using various techniques to influence consumption patterns for enhanced grid stability and reduced costs. A critical DSM method is the use of demand-side storage, such as batteries, thermal systems, or water resources. By storing energy when it is cheap and plentiful and releasing it during peak demand, these systems smooth the network's load curve and mitigate price volatility.

This research integrates these concepts by developing and optimizing a VPP that includes diverse producers, storage, and a prosumer, alongside a water-based demand-side storage system. The study's

objective is to model the optimal participation of these units, comparing the VPP framework against traditional grid operations and analyzing the economic impact of including DSM to demonstrate its role in increasing profitability and grid stability.

Methodology

The problem is modeled on an IEEE 33-bus standard micro grid that contains a Virtual Power Plant managing a diverse portfolio of assets: a diesel generator, a hydroelectric plant, solar panels, wind turbines, an electric vehicle (prosumer), and a battery for supply-side storage. Demand-Side Management (DSM) is implemented via several water resources acting as storage, each equipped with pumps that can consume energy to store water or generate energy when releasing it. The core objective is to determine the optimal unit commitment strategy that maximizes profit for all entities while preventing price spikes during peak demand.

The research evaluates two primary scenarios: first, a comparison of the VPP's economic performance versus a traditional grid, and second, an analysis of deploying a DSM system within both a traditional grid and a VPP framework. The model's operational logic is straightforward: during times of surplus energy, storage units (battery, EV, water reservoirs) are charged; during peak demand, this stored energy is dispatched back into the grid. The model assumes uncertainty in weather conditions and demand while treating costs and revenues as deterministic.

The problem is addressed using two distinct solution approaches:

Mixed-Integer Linear Programming (MILP): A mathematical optimization method used to find the globally optimal solution for the unit commitment problem. It involves detailed cost functions and operational constraints for each system component, based on established models.

Hybrid ELM-GA Algorithm: A machine learning approach combining an Extreme Learning Machine (ELM) with a Genetic Algorithm (GA). This method is designed to find a near-optimal solution far more quickly than MILP, making it highly suitable for large-scale, time-sensitive applications.

Results

The model was tested using real-world data from Yazd, Iran, for a 24-hour period. The VPP simulation included a 100 MW diesel plant, a 100 kW solar panel, six wind turbines (60 kW total), four 0.5 MW hydroelectric units, a 5 kW battery, and a 19.2 kW electric vehicle.

The MILP and ELM-GA methods produced distinctly different operational strategies. The cost-focused MILP solution opted to use fewer generating units at higher capacity, such as running only two of four hydroelectric units and leaving the battery entirely unused, thereby treating it as a sunk cost. It also mandated equal load sharing among similar units like wind turbines to minimize costs. In contrast, the ELM-GA solution dynamically engaged all available assets, operating them at varied, lower capacities. This strategy resulted in less output fluctuation and demonstrated active use of storage, with both the battery and electric vehicle charging and discharging based on grid needs.

Financially, the MILP method achieved the optimal solution, calculating a network loss of -1350 million currency units. The ELM-GA solution yielded a slightly higher loss of -1678 million currency units, confirming its near-optimal status. However, both VPP approaches were vastly superior to the traditional, non-VPP operational mode, proving the economic viability of the VPP structure. The inclusion of DSM increased immediate operational costs due to pump energy consumption but significantly reduced energy production volatility. This smoothing effect implies less long-term stress on the grid and lower maintenance costs.

Algorithm performance was benchmarked across problems of varying scales. For small and medium-sized problems, MILP was faster and found the optimal solution. However, for large-scale problems (e.g., 60

units), MILP's solution time became impractically long, whereas ELM-GA was 16 times faster while achieving a small optimality gap of just 4.4%. This highlights the machine learning approach as a highly effective tool for real-world energy dispatch problems.

Conclusion

This research successfully demonstrates that a Virtual Power Plant framework, particularly when enhanced with demand-side storage, is a significantly more profitable and stable alternative to traditional, centralized electricity markets. By quantitatively showing that a VPP can reduce financial losses and narrow the gap between supply and demand, the study validates its implementation as a core strategy for modern energy management. The findings underscore that while DSM introduces short-term costs, its ability to reduce production volatility leads to greater long-term grid health and lower maintenance expenses.

Furthermore, the study confirms that a hybrid machine learning algorithm (ELM-GA) is a powerful and practical tool for solving complex, large-scale energy optimization problems. While traditional methods like MILP guarantee optimality, their computational demands are prohibitive for large systems. The ELM-GA method provides a crucial trade-off, delivering near-optimal results with remarkable speed, making it invaluable for real-time operational planning and adaptive policy-making. Future research could extend this model to simulate competitive wholesale markets, incorporate the risk of unplanned outages, and explore other advanced machine learning algorithms to further refine optimization solutions.

Keywords: Virtual Power Plant, Demand Side Management, Unit Commitment, MILP, Machine Learning.

۱. مقدمه

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

از این‌رو با افزایش نیاز به انرژی، باید برای خرید، فروش و توزیع آن چاره‌ای اندیشه می‌شد که نتیجه آن ایجاد بازارها و بورس‌های انرژی بود. نیروگاه مجازی که مجموعه‌ای از واحدهای کوچک تولید و مصرف برق است، از نتایج این بازارها است.

از دست‌رفتن انرژی در ساعات غیرپیک و قطعی آن در ساعات پیک، از دلایل به‌وجودآمدن مفهومی به نام مدیریت‌کننده سمت تقاضا بود. مدیریت سمت تقاضا مفهومی است که بر مجموعه فعالیت‌ها باهدف تأثیرگذاری بر مصرف انرژی دلالت داشته 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 تقاضا است. بعضی از این ذخیره‌سازها، به‌صورت باتری، بعضی به‌صورت حرارتی و سیستم‌های سرمایشی/گرمایشی منازل مسکونی هستند و بعضی نیز به‌صورت منابع آب.

در این پژوهش بهینه‌سازی و زمان‌بندی یک نیروگاه مجازی کامل شامل چند تولیدکننده انرژی، توصیف‌کنندگان، مصرف‌کنندگان و ذخیره‌سازهای سمت عرضه و تقاضا مطالعه و مشارکت بهینه واحدها با استفاده از یادگیری ماشین به دست می‌آید. علاوه بر این، سناریوهایی مانند وجود یا عدم وجود ذخیره‌ساز سمت تقاضا و شرایط آب‌وهوایی و شبکه برق ایران بررسی و با مقایسه اطلاعات به‌دست‌آمده، افزایش سود طرف‌های درگیر و لزوم وجود ذخیره‌ساز سمت تقاضا نشان داده می‌شود. همچنین با


استفاده از الگوریتم $ELM-GA^2$ و $MILP$ ، ساختار بهینه مشارکت واحدها در واحدهای زمانی مختلف ارائه می‌شود. در بخش بعد به‌مرور پیشینه پژوهش پرداخته، در بخش سوم مدل‌سازی مسئله و در بخش چهارم تجزیه و تحلیل عددی آن ارائه می‌شود. در پایان، نتیجه‌گیری موردنظر بیان می‌شود.

۲. مرور ادبیات

نیاز روزافزون به خرید، فروش و توزیع انرژی منجر به تشکیل بازارهای برق و انرژی در سراسر جهان شد. در ابتدا بازار به‌صورت انحصاری بود، بنابراین دولت‌ها انرژی را از تولیدکنندگان می‌خریدند و سپس به‌عنوان عمده‌فروش، به شرکت‌های توزیع یا مستقیماً به مصرف‌کنندگان می‌فروختند. اما در سال 1990، 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 کرد [۱].

در ابتدا یک عامل خرید معرفی شد 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 به عنوان نوعی نماینده معرفی شدند. نیروگاه مجازی مجموعه‌ای از واحدهای تولید و مصرف کوچک است که توسط یک سیستم کنترل مرکزی هماهنگ شده است [۳]. اما به دلیل محدودیت‌های فناوری رایانه و شبکه و نبود شرایط نظارتی مناسب برای اهداف اجرایی، استفاده از این نوع نیروگاه تا سال 2003 به تعویق افتاد، زمانی که شرکت آلمانی RWE از شبکه‌ای از ژنراتورهای کوچک مقیاس استفاده کرد تا خدمات مناسب شبکه را فراهم کند. از آن زمان، نیروگاه‌های مجازی به عنوان راهی برای ادغام منابع انرژی تجدیدپذیر در شبکه و متعادل کردن تقاضا و عرضه برق به طور فزاینده محبوب شده‌اند [۴]. تفاوت اصلی نیروگاه‌های مجازی و معمولی این است که نیروگاه‌های مجازی چابک‌تر،

در یک شبکه کامل نیروگاه مجازی، چندین واحد عرضه و تقاضا شامل تولیدکنندگان انرژی، مصرف‌کنندگان، توصرف-کنندگان و واحدهای ذخیره‌سازی تحت کنترل یک واحد مرکزی بهینه‌سازی مشارکت واحدها وجود دارد.



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

Fig 1. Functional diagram of a water source as a demand-side storage device.

پژوهش‌های متعددی در زمینه نیروگاه مجازی، مدیریت‌کننده سمت تقاضا، استفاده از یادگیری ماشین در نیروگاه مجازی و ترکیبی از این موارد انجام شده است. در جدول ۱ خلاصه‌ای از برخی از این پژوهش‌ها ارائه می‌شود.

جدول ۱. مقایسه پژوهش‌های پیشین.

Table 1. Comparison of previous research.

Reference	Power plant	Model	Solution method	Demand management	Uncertainty	Objective function
[۸]	Virtual	Interactive method	-	-	-	Profit
[۹]	Virtual	-	CCP	-	✓	Fines and income
[۱۰]	Traditional	-	ELM-GA	✓	-	Production losses and their costs
[۱۱]	Virtual	MIP	-	-	-	Profit
[۱۲]	Traditional	-	MLPTA	✓	-	Exchange scenarios in the smart grid

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 شبکه برق، به حداقل رساندن تلفات انتقال انرژی، بهبود قابلیت اطمینان و انعطاف‌پذیری، و کاهش انتشار کربن است [۶].

در دهه ۱۹۷۰، چالش‌هایی در صنعت برق به وجود آمد که باعث قطعی برق و آسیب به تجهیزات الکتریکی، هزینه‌های تولید بالا در ساعات اوج مصرف و از دست دادن انرژی تولیدی مازاد در سایر ساعات شد. 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 به نظر 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 نوسانات قیمت برق استفاده می‌کند [۷]. استفاده از دستگاه ذخیره‌سازی می‌تواند باعث ذخیره انرژی در زمان‌های خارج از پیک شده 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 نشان داده شده است.

[۱۳]	Traditional	Min-Max and Max-Min	-	✓	✓	Production cost, elasticity of supply and demand
[۱۴]	Virtual	-	BLSTM	-	✓	Prediction error
[۱۵]	Virtual	-	K-means	-	✓	Prediction error
Current research	Virtual	MILP	ELM-GA	✓	✓	Profit, pump operating costs and floating producer losses

اصلی، یک مسئله مشارکت واحدها و توزیع بار اقتصادی است. هدف، تعیین استراتژی بهینه تولید، ذخیره‌سازی و مصرف انرژی برای تمامی واحدهای تحت مدیریت نیروگاه مجازی در یک افق زمانی ۲۴ ساعته است. این استراتژی باید به گونه‌ای تعیین شود که ضمن برآورده ساختن تقاضای بار و رعایت تمامی محدودیت‌های فیزیکی و عملیاتی هر واحد، سود کل سیستم را حداکثر نماید.

در این مدل، یک ریزشکه ۲۴ باسه استاندارد *IEEE* شامل یک نیروگاه مجازی در نظر گرفته شده که نیروگاه‌های دیزلی، هیدروالکتریک، خورشیدی، بادی عمودی داریوس، یک ماشین الکتریکی بعنوان توصیف کننده و یک باتری را مدیریت می‌کند. علاوه بر حضور مصرف کنندگان، تعدادی منبع آب هم برای مدیریت سمت تقاضا وجود دارد. برای تولید انرژی در زمان اوج مصرف و تقاضای بالا، به هر کدام از این منابع، شش پمپ متصل به موتور القایی نیز وجود دارد که خود به درایو فرکانس متغیر متصل‌اند. اندیس‌ها، متغیرها و پارامترهای مدل به ترتیب در جداول ۲، ۳ و ۴ ارائه شده‌اند.

همان‌طور که مشخص است در محدود مطالعات درباره استفاده از منبع آب به عنوان مدیریت کننده سمت تقاضا، مانند [۱۰]، شبکه و نیروگاه‌ها همه سنتی هستند. هیچ تنوعی در نیروگاه‌ها و منابع انرژی وجود ندارد و عدم قطعیت در نظر گرفته نشده است. در این مطالعه، شبکه‌ای با مشارکت نیروگاه‌های دیزلی، هیدروالکتریک، پنل‌های خورشیدی، توربین‌های بادی، توصیف کننده^۲، باتری یا ذخیره‌سازی سمت عرضه، مصرف کننده و واحدهای مدیریت کننده سمت تقاضا مطالعه می‌شود. هدف از این مطالعه، بهینه‌سازی سود عناصر در ریزشکه ۲۴ باسه استاندارد *IEEE* با استفاده از *MILP* و یادگیری ماشین است. اکثر نیروگاه‌های مجازی را می‌توان نوعی ریزشکه در نظر گرفت که تولیدکنندگان به صورت واحد ظاهر می‌شوند. در این پژوهش، افزایش سود یک تولیدکننده با مشارکت در یک نیروگاه مجازی بررسی می‌شود. همچنین تأثیر حضور ذخیره‌ساز سمت تقاضا تحلیل می‌شود.

۳. تعریف مسئله و مدل‌سازی

در این پژوهش، مسئله بهینه‌سازی عملکرد یک نیروگاه مجازی در یک ریزشکه استاندارد فرموله می‌شود. مسئله

جدول ۲. اندیس‌های مدل.

Table 2. Model indices.

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.

Table 3. Model variables.

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
$P_{d,t}$	Diesel power plant output 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		

جدول ۴. پارامترهای مدل.

Table 4. Model parameters.

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

است و مدل بر اساس این مقادیر پیش‌بینی شده حل می‌شود. بنابراین، عدم قطعیت به صورت مستقیم در مدل ریاضی لحاظ نشده، بلکه از طریق استفاده از داده‌های پیش‌بینی شده مدیریت می‌شود.

- هزینه‌ها و درآمدهای مربوطه به صورت قطعی و ثابت فرض شده است.
- خرابی‌های برنامه‌ریزی نشده در نظر گرفته نشده‌اند.
- مدل‌سازی این پژوهش به دو بخش نیروگاه مجازی و مدیریت سمت تقاضا تقسیم شده و از ترکیب مبانی اصلی و عمومی نیروگاه‌ها و مدل‌سازی در پژوهش-های پیشین استفاده می‌شود.

تابع هزینه در نیروگاه هیدروالکتریک به شرح زیر بوده و محدودیت‌های آن در بخش ذخیره‌ساز ارائه می‌شود:

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

تابع هزینه نیروگاه دیزلی به شرح زیر است:

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

محدودیت‌های این نیروگاه نیز به مطابق زیر است:

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

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

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

$$(6)$$

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

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

تابع هدف نیروگاه خورشیدی نیز در زیر آمده است.

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

محدودیت‌های این نیروگاه به قرار زیر است. عبارات (۱۴) و (۱۵) از پژوهش [۱۶] استخراج شده است.

استراتژی مناسب برای پاسخگویی بار و حداکثرسازی سود عناصر درگیر در نیروگاه مجازی تعیین می‌شود تا از جهش قیمت در ساعات پیک جلوگیری شود. در این پژوهش دو سناریو موردبررسی قرار خواهند گرفت:

الف: مقایسه پاسخ به بار و سود دو حالت ایجاد و بهره‌برداری از نیروگاه مجازی یا ادامه روش سنتی کنونی.

ب: بررسی، مقایسه و تعیین استراتژی بهینه به کارگیری مدیریت‌کننده سمت تقاضا در سه حالت حضور در شبکه سنتی، حضور در نیروگاه مجازی و عدم حضور.

وقتی انرژی تولیدی بیش از تقاضا است، باتری و ماشین الکتریکی شارژ شده و در سمت تقاضا نیز، علاوه بر پاسخ به نیاز مشترکین، با به حرکت درآوردن موتورها، آب ورودی در منابع موردنظر ذخیره می‌شوند. در زمان اوج مصرف و فشار بر شبکه، انرژی ذخیره‌شده در باتری و ماشین الکتریکی وارد شبکه شده تا از فشار وارده بر شبکه موردنظر بکاهد. همچنین با آزادسازی آب درون منابع و به حرکت درآمدن پمپ‌ها و سپس موتورهای القایی، منبع تولید انرژی جدیدی خواهیم داشت که انرژی تولیدی آن به سرعت و با طی مسیر انتقال کوتاه‌تر و هدررفت کمتر، می‌تواند شکاف در عرضه و تولید انرژی با تقاضای آن را پوشش داده و مانع از ایجاد قطعی شود.

مفروضات شبکه این پژوهش به قرار زیر است:

- پارامترهای مربوط به شرایط آب‌وهوایی (سرعت باد و تابش خورشید) و تقاضای روزانه، ذاتاً غیرقطعی هستند. با این حال، در این مقاله از یک رویکرد بهینه‌سازی قطعی استفاده شده است. در این رویکرد، فرض می‌شود که یک پیش‌بینی نقطه‌ای دقیق برای این پارامترها در افق زمانی ۲۴ ساعته در دسترس

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

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

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

تابع هدف ماشین الکتریکی برابر است با:

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

محدودیت‌های ماشین الکتریکی بر اساس گفته‌های [۱۸] به قرار زیر است:

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

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

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

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

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

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

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

تابع هدف باتری نیز به قرار است:

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

محدودیت‌های باتری نیز بر اساس گفته‌های [۱۱] به شرح زیر است. عبارت (۳۵) دینامیک سطح انرژی ذخیره شده در باتری را مدل می‌کند. این محدودیت تضمین می‌کند که سطح انرژی باتری در هر ساعت، با در نظر گرفتن میزان شارژ، تخلیه و راندمان، از ظرفیت کل باتری تجاوز نکند.

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

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

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

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

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

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

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

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

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

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

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

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

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

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

در ادامه تابع هزینه نیروگاه بادی ارائه شده است.

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

محدودیت‌های در نظر گرفته شده در این نیروگاه به شرح زیر است. سه عبارت (۲۳)، (۲۴) و (۲۵) بر مبنای [۱۷] استفاده شده است.

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

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

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

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

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

توان خروجی توربین بادی تابعی از سرعت باد در زمان t است. این رابطه، با استفاده از سه پارامتر کلیدی سرعت باد شامل سرعت آستانه قطع، سرعت نامی و سرعت آستانه خروج، به صورت تابع چند ضابطه‌ای زیر مدل‌سازی می‌شود:

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

محدودیت‌های زیر، الزامات اصلی کل سیستم را نشان می‌دهند. عبارت (42)، تعادل توان را در هر ساعت تضمین می‌کند، به این معنی که مجموع تولید و انرژی تخلیه‌شده

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

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

در آخر، تابع هدف کل سیستم عبارت است از:

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

خوب را یاد می‌گیرد. سپس، در نسل‌های بعدی الگوریتم ژنتیک، برخی از جواب‌های جدید تولید شده (فرزندان) به‌عنوان ورودی به این شبکه *ELM* آموزش‌دیده داده می‌شوند. شبکه *ELM* یک نسخه اصلاح‌شده و بهبودیافته از آن جواب را بر اساس دانش استخراج‌شده از جواب‌های برتر قبلی، پیش‌بینی می‌کند. این جواب اصلاح‌شده، جایگزین جواب اولیه در جمعیت *GA* می‌شود.

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

۴. بررسی نتایج

برای پیاده‌سازی و حل مدل‌ها از دو بستر محاسباتی مجزا استفاده گردید. مدل برنامه‌ریزی خطی عدد صحیح با استفاده از نرم‌افزار *GAMS* بر روی یک رایانه شخصی با مشخصات پردازنده Intel(R) Core(TM) i3 CPU 2,53GHz @ 380 M و 4/00 گیگابایت حافظه *RAM* حل شده است. الگوریتم ترکیبی *ELM-GA* نیز با استفاده از زبان برنامه‌نویسی پایتون در محیط *Google Colaboratory* پیاده‌سازی و اجرا گردید. برای اجرای این الگوریتم، از منابع محاسباتی استاندارد فراهم‌شده توسط *Colab*، شامل شتاب‌دهنده گرافیکی (*GPU*)، استفاده شد تا سرعت فرآیندهای یادگیری ماشین افزایش یابد.

نیروگاه مجازی مورد بررسی در این پژوهش شامل یک نیروگاه دیزلی با ظرفیت 100 مگاوات، یک مزرعه خورشیدی با توان 100 کیلو وات، شش توربین بادی با مجموع توان 50 کیلو وات، نیروگاه هیدروالکتریک متشکل

به طور خلاصه، چارچوب مدل‌سازی ارائه شده در این پژوهش، یک رویکرد ترکیبی است که از یکپارچه‌سازی و تلفیق مدل‌های توسعه‌یافته در مراجع مختلف بهره می‌برد. همان‌طور که تشریح شد، اجزای مدل بر اساس مدل‌های ارائه شده در مراجع مختلف از جمله [11] و [18] پیاده‌سازی شده‌اند. در این میان، مدل‌سازی بخش ذخیره‌ساز و الگوریتم یادگیری ماشین، به طور کامل از پژوهش انجام‌شده در [10] اقتباس شده است. هدف از این رویکرد یکپارچه، بهره‌گیری همزمان از نقاط قوت هر یک از مدل‌های پایه به منظور دستیابی به عملکردی دقیق‌تر و جامع‌تر می‌باشد.


الگوریتم ترکیبی استفاده شده، الگوریتمی است که در آن «الگوریتم ژنتیک (*GA*)» به‌عنوان موتور اصلی بهینه‌سازی عمل کرده و «ماشین یادگیری بی‌نهایت (*ELM*)» نقش یک شتاب‌دهنده هوشمند برای بهبود و تسریع همگرایی را ایفا می‌کند. فرایند حل با الگوریتم ژنتیک آغاز می‌شود. *GA* با ایجاد یک جمعیت اولیه از راه‌حل‌های کاندید (که هر راه‌حل، یک استراتژی کامل 24 ساعته برای مشارکت واحدهاست) به جستجو در فضای جواب می‌پردازد. در هر نسل، با استفاده از عملگرهای انتخاب بر اساس شایستگی (مقدار تابع هدف)، ترکیب و جهش، جمعیت به سمت یافتن جواب‌هایی باکیفیت بالاتر هدایت می‌شود.

باین‌حال، برای جلوگیری از همگرایی زودرس به بهینه‌های محلی و افزایش سرعت رسیدن به جواب‌های باکیفیت، از ماشین یادگیری بی‌نهایت به‌عنوان یک عملگر کمکی هوشمند در طول فرایند تکامل *GA* استفاده می‌شود. پس از گذشت تعداد معینی از نسل‌ها، مجموعه‌ای از بهترین جواب‌های یافت‌شده تا آن لحظه، به‌عنوان داده‌های آموزشی برای یک شبکه *ELM* به کار می‌روند. *ELM* که یک شبکه عصبی بسیار سریع است، الگوی موجود در این جواب‌های

از چهار واحد 50 مگاواتی، یک باتری با ظرفیت 4 کیلو وات و یک ماشین الکتریکی با ظرفیت 19.2 کیلووات می- باشد.

۴.۱. مطالعه موردی (داده‌ها)

مقادیر تقاضا، سرعت باد، دما و میزان تابش در شبانه‌روز مورد بررسی (اول دی‌ماه 1400)، از داده‌های واقعی استان یزد استخراج شده که در نمودارهای شکل ۲ قابل مشاهده- اند:



شکل ۲. داده‌های مربوط به تقاضا، سرعت باد، دما و تابش شبکه مورد نظر در یک شبانه‌روز (اول دی‌ماه 1400).


Fig 2. Data related to demand, wind speed, temperature, and radiation of the desired network in one day (December 22, 2021).

قیمت خرید برق از هر نیروگاه به طور متوسط 53.06 تومان به ازای هر کیلووات ساعت و هزینه سوخت برای نیروگاه دیزلی، 40 تومان به ازای هر متر مکعب می‌باشد. دمای مرجع در نیروگاه خورشیدی و تابش استاندارد به ترتیب 29.5 و 1000 می‌باشد. اطلاعات توربین‌های بادی، مطابق پژوهش [۱۶] است. در شبکه مورد بررسی،

6 ذخیره‌ساز در سمت تقاضا وجود دارد که حجم هر منبع ذخیره‌ساز 7000 مترمکعب بوده که حداقل و حداکثر سطح آب داخل آن، 15 و 90 درصد حجم کل است. این منبع که برای تأمین آب استانی با ظرفیت حدودی 1.3 میلیونی استفاده می‌شود، در ارتفاع 5 متری از سطح زمین قرار گرفته و خود آن نیز 4 متر ارتفاع دارد.

۴.۲. مقایسه عملکرد روش‌ها

مقایسه توان خروجی مجموعه نیروگاه‌های هیدروالکتریک با استفاده از دو روش یاد شده، در شکل ۳ نشان داده شده است.



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


Fig 3. Comparison of hydroelectric unit output power in two methods: MILP and ELM-GA

در روش MILP تنها از دو واحد برای تولید انرژی استفاده شده است. چون برای پاسخ به تقاضا تنها به انرژی تولیدی دو واحد نیاز است و هزینه‌ها و تلفات نیز باید به حداقل برسند؛ این روش استفاده از دو واحد را پیشنهاد کرده و دو واحد دیگر در 24 ساعت مورد بررسی انرژی تولید نمی- کنند. پس هزینه نگهداری و تعمیرات برای 4 واحد محاسبه می‌شود در حالی که آورده‌ای ندارند؛ اما تلفات نیروگاه را کمینه می‌کند.

در روش ELM-GA هر چهار واحد هیدروالکتریک موجود در ریزشکه مورد بررسی در هر ساعت از شبانه‌روز در حال کار بوده و انرژی تولید می‌کنند. علاوه بر این، نتایج این پژوهش و نتایج منتشر شده در [۱۹] نشان می‌دهد که واحدهای هیدروالکتریک در ظرفیتی کمتر از ظرفیت نامی خود مشغول به کار بوده و نیازی به تولید انرژی با حداکثر ظرفیت و توان برای پاسخ به تقاضا وجود ندارند.


نتایج و ویژگی‌های روش یادگیری ماشین را باتوجه به مسئله مورد بررسی، می‌توان در موارد زیر دانست:

- در نیروگاه مجازی از موارد قبلاً احداث شده استفاده می‌شود که در این صورت حداکثر




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

Fig 5. Comparison of diesel power plant output power in two methods: MILP and ELM-GA.




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

Fig 6. Comparison of solar power plant output power in two methods: MILP and ELM-GA.



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

Fig 7. Comparison of electric machine output power in two methods: MILP and ELM-GA.




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

Fig 8. Comparison of battery output power in the two MILP and ELM-GA methods

نتایج روش MILP بیان می‌دارد که نیازی نیست تا نیروگاه دیزلی در توان نامی خود و یا حتی نزدیک به آن کار کند؛ بلکه تنها کافی است این نیروگاه حداکثر با حدود ۸۳ درصد ظرفیتش کار کند. نیروگاه خورشیدی نیز تنها در ۱۰ ساعت انرژی تولید کرده و در شبکه حضور دارد؛ زیرا مقدار تابش

استفاده از واحدهای موجود با حداقل هزینه بهتر است.

- با این روش نیروگاه دیزلی می‌تواند با استفاده از نصف ظرفیت خود، تقاضا را پاسخ دهد. در نتیجه نیازی به کار در حداکثر ظرفیت نیست.
- شکل ۲، مقایسه توان واقعی مجموعه توربین‌های بادی از دو روش MILP و ELM-GA را نشان می‌دهد.



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

Fig 4. Comparison of wind turbine output power in two methods: MILP and ELM-GA.

نتایج روش MILP به درستی نشان می‌دهد که توربین‌های بادی تنها در ۲۱ ساعتی که وزش باد کافی وجود داشته، فعال بوده و توان تولید کرده‌اند و در ساعات باقی‌مانده فعالیتی نداشته‌اند. این نتیجه، همخوانی کامل عملکرد مدل با شرایط ورودی باد را تأیید می‌کند.

همچنین این روش تصریح می‌کند که حداقل 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 به طور یکسان محاسبه شده است. اما نتایج به دست آمده از روش ELM-GA نشان می‌دهد که کاهش هزینه‌ها در تولید انرژی غیریکسان در توربین‌های مشابه اتفاق می‌افتد. همچنین باید گفت که نوسان تولید انرژی از طریق توربین‌های بادی در روش ELM-GA به طور چشمگیری کمتر از روش MILP است. دلیل این نتیجه را می‌توان تولید غیرمشابه توربین‌های مشابه دانست.

مقایسه توان واقعی نیروگاه دیزلی، نیروگاه خورشیدی، ماشین الکتریکی و باتری با استفاده از دو روش یاد شده، در اشکال ۵ تا ۸ نشان داده شده است.

مناسب برای بکار افتادن پنل‌ها فقط در این ساعات وجود دارد. نتایج این روش نشان می‌دهد که در شبانه روز مورد بررسی، نیازی به حضور باتری نیست و تنها هزینه وجود باتری به سیستم تحمیل می‌شود. در نتیجه و با توجه به این نتایج می‌توان باتری، یا به نوعی ذخیره‌ساز سمت عرضه، را از سیستم حذف نمود. اما در ساعت اولیه روز نیاز است تا ماشین الکتریکی در حداکثر توان خود شارژ شود. این به دلیل است که علاوه بر کاهش هزینه‌ها، شکاف بین عرضه و تقاضا نیز باید کاهش یابد؛ زیرا در آن ساعت با مازاد تولید روبه‌رو هستیم.

باتوجه به شکل‌های فوق می‌توان موارد زیر را استنتاج کرد:

- نیروگاه دیزلی در روش *ELM-GA* نوسان

بیشتری را تجربه می‌کند؛ اما تنها از حدود نصف

ظرفیت نامی برای تولید انرژی استفاده می‌کند. این

در حالی است که در روش *MILP* از حدود ۸۳

درصد ظرفیت نامی بهره می‌بریم.

- حداکثر تولید نیروگاه خورشیدی در روش *MILP*

در حدود ۷ صبح اتفاق می‌افتد؛ اما در روش دیگر

حداکثر تولید در ۱۱ صبح اتفاق می‌افتد.

- در روش *MILP* ماشین الکتریکی تنها در ساعت

اول شارژ می‌شود؛ اما در روش *ELM-GA* ماشین

الکتریکی شارژ و تخلیه را باتوجه به نیاز شبکه در

ساعات مختلف تجربه می‌کند.

- باتری در روش *MILP* هیچ شارژ و تخلیه‌ای را تجربه

نمی‌کند و تنها هزینه 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.

۴.۳. تحلیل سناریوها

مقدار تابع هدف مربوط به نیروگاه مجازی در روش *MILP*

، یعنی سود حاصله، برابر با مقدار «-1350» میلیون

تومان به دست آمد. البته با توجه به این که مقدار درآمد از

هزینه‌ها کمتر است، مقدار بدست آمده، زیان شبکه را نشان

می‌دهد. مقدار تابع هدف مربوط به نیروگاه مجازی در روش

ELM-GA برابر با مقدار «-1678» میلیون تومان به

دست آمد. این عدد حاکی از این است که هزینه‌ها در روش

ELM-GA بیشتر از روش *MILP* بوده و جواب روش قبل


بر بهینه کلی دلالت دارد. روش *ELM-GA* به نقطه بهینه

نزدیک شده، اما نتوانسته به بهینه کل دست پیدا کند.

مطابق نتایج به‌دست آمده از روش *MILP*، وجود توان رزرو برای هر واحد نیروگاه هیدروالکتریک در ساعات مختلف ضروری است. حتی با اینکه دو واحد از چهار واحد در شبانه‌روز مورد بحث انرژی تولید نمی‌کنند، در ساعات مختلف نیاز به توان رزرو دارند. روش مورد نظر برای حداقل کردن هزینه عملیاتی پمپ‌ها پیشنهاد داده است که هر شش پمپ یک ذخیره‌ساز در تمامی ساعات شبانه‌روز روشن و در حداکثر توان خود، یعنی ۹۰ کیلووات، در حال کار باشند. در نتیجه توان مصرفی هر شش ذخیره‌ساز در همه ساعات شبانه‌روز یکسان و برابر با ۵۴۰ کیلووات بدست آمد. همچنین تلفات تولید نیروگاه‌های هیدروالکتریک نیز برابر با مقدار «832710.2» است. هزینه عملیاتی کل پمپ‌ها را می‌توان برابر با مقدار «761.1» و «36794.6» $C_{op.p}$ تومان محاسبه نمود.

نتایج حاصل از روش *ELM-GA* وجود توان رزرو را در هر ساعت و برای واحدهای درگیر تولید انرژی نشان می‌دهد. مطابق این نتایج، در هر شش پمپ یک ذخیره‌ساز در تمامی ساعات شبانه‌روز روشن بوده و توان مصرفی آن‌ها مطابق شکل ۹ خواهد بود. در این روش نیز، مانند روش *MILP*، پمپ‌ها در همه ساعات روشن بوده اما با ظرفیت کمتر کار می‌کنند. همچنین تلفات تولید نیروگاه‌های هیدروالکتریک نیز برابر با مقدار «860922» است که از مقدار به دست آمده در روش قبل بیشتر است زیرا جواب به دست آمده از روش قبل بر بهینه کل دلالت دارد.

هزینه عملیاتی کل پمپ‌ها را می‌توان برابر مقدار «264873» و «12789624.36» $C_{op.p}$ تومان محاسبه نمود که افزایش فاحش نسبت به روش *MILP* نشان می‌دهد.



شکل ۹. توان مصرفی پمپ‌های ذخیره‌ساز از روش *ELM-GA*
Fig 9. Power consumption of storage pumps using the ELM-GA method.

روش *MILP* برای حداقل کردن هزینه‌ها و تلفات تا جای ممکن سعی کرده تا عناصر درگیر در نیروگاه مجازی حداقل حضور ولی در حداکثر توان مورد نیاز استفاده شوند. علاوه بر این نشان داد برای رسیدن به اهداف تعریف شده، تقسیم بار بین واحدهای مشابه و تولید مقادیر انرژی مشابه از طریق

این واحدها بر سایر روش‌ها ارجحیت دارد. اما در روش *ELM-GA*، همه عناصر نیروگاه مجازی به انجام وظایف خود پرداختند و هیچ کدام هزینه نگهداری را، بدون داشتن آورده‌ای، به سیستم تحمیل نکردند. در نهایت، مشارکت بهینه واحدها در روش، مطابق شکل ۱۰ و ۱۱ خواهد بود:



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

Fig 10. Participation of units involved in the virtual power plant in the MILP method



شکل ۱۱. توان خروجی واحدهای درگیر در نیروگاه مجازی از روش *ELM-GA*.

Fig 11. Output power of units involved in the virtual power plant using the ELM-GA method

در شرایط کنونی و بدون حضور و استفاده از نیروگاه مجازی و مدیریت‌کننده سمت تقاضا، نیروگاه‌ها باید به‌تنهایی کار کرده و در هر ساعت، باتوجه به شرایط جوی، توان تولیدی حداکثر را محقق کنند. همچنین در شرایط واقعی، باتری و ماشین الکتریکی در زمانی که مازاد تولید وجود دارد؛ شارژ شده و در ساعات پیک مصرف تخلیه می‌شوند. اما نتایج حاصل از روش‌های پیشنهادی، تصمیمات دیگری را برای این دو عضو اتخاذ کردند. در این حالت، سود فروش انرژی به مقدار «3015700100-» می‌رسد. این رقم درحالی بدست می‌آید که سود روش برنامه‌ریزی خطی برابر با «1350-» و سود روش یادگیری ماشین برابر با «1678-» است. مقایسه اعداد نشان می‌دهد که استفاده از نیروگاه

مجازی در کاهش زیان مؤثر بوده و راه حل مناسب‌تری نسبت به بازار انحصاری می‌باشد. [۱۰] در پژوهش خود شبکه‌ای سنتی به همراه مدیریت‌کننده سمت تقاضا را در نظر گرفتند. آن‌ها تعداد دفعات تغییر وضعیت پمپ‌ها از روشن به خاموش و بالعکس را در حالت *MILP* برابر با 1108 و در حالت استفاده از الگوریتم *ELM-GA* برابر با 782 بار در یک شبانه‌روز بدست آوردند. همچنین نمودارهای ارائه شده در پژوهش یاد شده نشان می‌دهند که توان مصرفی پمپ‌ها در هر ساعت متفاوت بوده و نوسان را تجربه می‌کنند. باتوجه به نتایج، دفعات تغییر پمپ‌ها به وضعیت روشن و خاموش در هر دو حالت حل، از مقادیر به‌دست‌آمده در [۱۰] کمتر بوده و توان مصرفی پمپ‌ها نیز نوسان کمتری

جدول ۶. مقایسه توان‌های واقعی تولیدی با [۱۶] (کیلووات).

Fig 6. Comparing actual generated powers with [16] (kilowatts).

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	60.9	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	49.7	150.0
22:00–23:00	32.6	48.6	151.2
23:00–24:00	29.5	46.7	153.1

۴.۴. تحلیل حساسیت

کارایی الگوریتم ترکیبی *ELM-GA* ریشه در نقش کلیدی مؤلفه یادگیری ماشین (*ELM*) در بهبود فرآیند بهینه‌سازی دارد. در صورت حذف این بخش، الگوریتم به یک الگوریتم ژنتیک (*GA*) استاندارد تبدیل می‌شود که برای رسیدن به جواب باکیفیت، نیازمند بودجه محاسباتی بسیار بالایی (شامل جمعیت بزرگتر و تعداد نسل‌های بیشتر) و در نتیجه، زمان حل طولانی‌تری است. در ساختار ترکیبی، *ELM* به عنوان یک عملگر هوشمند، با یادگیری الگوهای موجود در جواب‌های برتر، جستجوی الگوریتم ژنتیک را به سمت مناطق امیدبخش‌تر فضای جواب هدایت می‌کند. این فرآیند، هم از همگرایی زودرس جلوگیری کرده و هم سرعت رسیدن به یک جواب همگرا تر و باکیفیت‌تر را به طور قابل توجهی تسریع می‌بخشد.

برای مقایسه سرعت و کیفیت حل دو روش یاد شده، بر اساس تعداد واحدهای حاضر در نیروگاه مجازی، مسائلی را با

را تجربه می‌کنند. در نتیجه هزینه‌های عملیاتی پمپ‌ها و هزینه ذخیره‌سازها در پژوهش حاضر نسبت به پژوهش یاد شده کاهش یافته که می‌تواند نشان‌دهنده تأثیر استفاده و بهره‌گیری از نیروگاه مجازی در کاهش هزینه‌ها باشد.

برای مقایسه عملکرد نیروگاه مجازی در حضور مدیریت‌کننده سمت تقاضا و عدم حضور آن، این پژوهش با [۱۶] مقایسه می‌شود. [۱۶] یک نیروگاه مجازی شامل شش توربین بادی، چهار پنل خورشیدی، یک واحد نیروگاه دیزلی و یک باتری را در نظر گرفته و توان خروجی هر واحد و هزینه‌های آن‌ها را محاسبه کردند. مجموع توان هر نوع نیروگاه مورد بررسی در پژوهش یاد شده، در جدول ۵ ارائه شده است:

جدول ۵. مجموع توان نامی هر نوع نیروگاه مورد بررسی [۱۶].

Table 5. Total rated power of each type of power plant studied in the study [16].

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

جهت مقایسه پژوهش حاضر با [۱۶]، واحدهای تولیدکننده انرژی باید متناسب شوند؛ بدین صورت که واحدهای هیدروالکتریک و ماشین الکتریکی را از پژوهش حاضر حذف کرده و مجموع توان نامی واحدهای باقی‌مانده را برابر با جدول ۵ در نظر گرفته و توان‌های واقعی بدست آمده در بخش‌های قبل را متناسب‌سازی کردیم. در این بخش وابستگی توان تولیدی به تقاضا را نادیده گرفتیم.

مجموع توان واقعی تولیدی توسط واحدهای دو پژوهش مورد بررسی در هر ساعت شبانه‌روز، در جدول ۶ ارائه شده‌اند. همان‌طور که در جدول مشخص است، توان تولیدی در نیروگاه مجازی با حضور مدیریت‌کننده سمت تقاضا بیشتر از حالت عدم حضور مدیریت‌کننده است؛ در نتیجه هزینه‌ها نیز در حضور مدیریت‌کننده سمت تقاضا بیشتر خواهد بود که می‌تواند ناشی از نیاز پمپ‌ها به مصرف انرژی علاوه بر تقاضای مؤثر شبکه باشد. باوجود افزایش هزینه‌ها در کوتاه‌مدت، نوسان انرژی تولیدی در حالتی که مدیریت‌کننده سمت تقاضا وجود دارد، کمتر از حالت دیگر است. به عبارت دیگر کاهش نوسان می‌تواند نشان‌دهنده 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 را به شبکه و نیروگاه موردنظر وارد آورده و هزینه‌ها، به‌خصوص هزینه نگهداری و تعمیرات را در بلندمدت کاهش می‌دهد.

داده‌های تصادفی در سه محدوده ابعادی کوچک (تا 20 واحد نیروگاهی)، متوسط (20 تا 40 واحد نیروگاهی) و بزرگ (40 تا 60 واحد نیروگاهی) در نظر گرفته شد. برای این تحلیل، واحدهای جدید به صورت تصادفی و با مشخصات فنی و اقتصادی مشابه با انواع واحدهای تعریف شده در مطالعه موردی اصلی (شامل واحدهای دیزلی، خورشیدی، بادی و...) تولید شدند. بازه زمانی 48 ساعت را برای رسیدن به پاسخ معین کردیم. در این مقایسه مقدار جمعیت در روش *ELM-GA* برابر 10 و تعداد تولید نسل را برابر 50 در نظر گرفتیم. نتایج در جداول 7، 8 و 9 ارائه شده است. همان‌طور که در جداول مشخص است، در مسائلی با ابعاد کوچک و متوسط، روش *MILP* علاوه بر دستیابی به بهینه کلی، زمان کمتری نیز در رسیدن به جواب صرف می‌کند. این در حالی است که در روش *ELM-GA* نه تنها زمان بیشتری صرف شده، بلکه مقدار نزدیک به بهینه به دست آمده است. اما با بالا رفتن ابعاد مسئله و رسیدن به 60 واحد، زمان روش

MILP به طرز چشمگیری بالا رفته؛ در حالی که در روش دیگر زمان بسیار کمتری صرف شده است. با توجه به نتایج سایر مسئله‌ها و نزدیک بودن جواب به دست آمده از روش *ELM-GA* به بهینه کلی، می‌توان در مسائلی با ابعاد بزرگ از این روش برای صرف زمان کمتر استفاده کرد و اطمینان داشت که جواب به دست آمده به بهینه کلی نزدیک است. از این ویژگی می‌توان برای توسعه زیرساخت‌های تولید انرژی متناسب با تغییر تقاضا و تعریف سیاست‌های مناسب استفاده کرد. بدین صورت که با استفاده از داده‌های پیشین و تاریخچه هواشناسی و مصرف انرژی در مکانی خاص، ماشین را آموزش داده و سپس به وسیله داده‌ها و پیش‌بینی‌های هواشناسی روزهای آتی، از ماشین خواست پیش‌بینی تقاضای انرژی در روزهای مورد نظر را ارائه کند. در نتیجه با صرف زمانی کم، نتایجی نزدیک به بهینه خواهیم داشت که می‌تواند مبنای تصمیم‌گیری و سیاست‌گذاری باشد.

جدول 7. مقایسه سرعت و کیفیت حل دو روش *MILP* و *ELM-GA* در مسائلی با ابعاد کوچک.

Table 7. Comparison of the speed and quality of solving the two methods *MILP* and *ELM-GA* in small-dimensional problems

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	-1022.6	-1340	31.0

جدول 8. مقایسه سرعت و کیفیت حل دو روش *MILP* و *ELM-GA* در مسائلی با ابعاد متوسط.

Table 8. Comparison of the speed and quality of solving the two methods *MILP* and *ELM-GA* in medium-dimensional problems.

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	-2125.05	-2341	10.2
36	2.54	173	-2125.1	-2397	12.8

جدول 9. مقایسه سرعت و کیفیت *MILP* و *ELM-GA* در ابعاد بزرگ.

Table 9. Comparison of speed and quality of *MILP* and *ELM-GA* in large dimensions.

Number of units	Solution time		Objective function (million)		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 این پژوهش، تشویق به گذر از بازار انحصاری با احداث نیروگاه مجازی و کاهش شکاف بین عرضه و تقاضا با استفاده از ذخیره‌سازها در سمت تقاضا بود. این هدف با مقایسه شبکه برق سنتی با نیروگاه مجازی در حضور و عدم حضور مدیریت‌کننده سمت تقاضا و بررسی سود و زیان ناشی آن دنبال شد. از اهداف دیگر این پژوهش می‌توان به استفاده از یادگیری ماشین برای افزایش سرعت حل مدل‌ها و پیش‌بینی جهت برنامه‌ریزی آینده اشاره کرد.

فراتر از نتایج فنی، یافته‌های این پژوهش، بینش‌های مدیریتی مهمی را برای سیاست‌گذاران و مدیران این حوزه فراهم می‌آورد. اولاً، توجیه‌پذیری اقتصادی چارچوب نیروگاه مجازی به‌عنوان یک جایگزین برتر برای شبکه سنتی، یک دلیل محکم برای سرمایه‌گذاری در تجمیع منابع انرژی پراکنده است. ثانیاً، نتایج نشان می‌دهد که

مدیریت سمت تقاضا، علی‌رغم هزینه‌های عملیاتی اولیه، یک سرمایه‌گذاری استراتژیک بلندمدت برای افزایش پایداری شبکه و کاهش هزینه‌های آتی نگهداری است. در نهایت، مقایسه روش‌های حل به مدیران نشان می‌دهد که برای تصمیم‌گیری‌های استراتژیک و آفلاین، دقت روش‌های دقیق مانند *MILP* ارجحیت دارد، درحالی‌که برای عملیات روزانه و آنلاین که سرعت حیاتی است، ابزارهای هوشمند و سریع (*ELM-GA*) کارایی بسیار بیشتری دارند.

مدل پیشنهادی شامل پیشینه‌سازی تابع سود و کمینه‌سازی تلفات نیروگاه هیدروالکتریک و هزینه 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 شد. در پژوهش‌های آینده می‌توان مواردی از جمله بررسی و مدل‌سازی بازار رقابت عمده‌فروشی، در نظر گرفتن خرابی‌های برنامه‌ریزی نشده، و سایر الگوریتم‌های یادگیری ماشین را بررسی کرد.

۶. مراجع

1. Awerbuch, S. and Preston, A., ۱۹۹۷. The Virtual Utility: Accounting, Technology & Competitive Aspects of the Emerging Industry. Springer: Berlin/Heidelberg. <https://books.google.com/books?hl=en&lr=&id=BXrBwAAQBAJ&oi=fnd&pg=PR13&dq=۱.%۰۹Awerbuch,+S.,+Preston,+A.,+۱۹۹۷.+The+Virtual+Utility:+Accounting,+Technology+%۲۶+Competitive+Aspects+of+the++++Emerging+Industry.+Springer:+Berlin/Heidelberg&ots=n۰ySfEIYFp&sig=۶۴S۷tKZufYrpka۹Zw۴gI۴۲۹REpM>
2. Borenstein, S. and Bushnell, J., ۲۰۱۵. The U.S. electricity industry after ۲۰ years of restructuring. *National Bureau of Economic Research*, 7(۱), pp. ۴۳۷-۴۶۳. <https://doi.org/۱۰.۱۱۴۶/annurev-economics-۰۸.۶۱۴-۱۱۵۶۳۰>
3. Narkhede, M., Chatterji, S. and Ghosh, S., ۲۰۱۳. Multi objective optimal dispatch in a virtual power plant using genetic algorithm. *International Conference on Renewable Energy and Sustainable Energy*. <https://doi.org/۱۰.۱۱۰۹/ICRESE.۲۰۱۳.۶۹۲۷۸۲۲>
4. Mao, T., Guo, X., Xie, P., Zhou, J., Zhou, B., Han, S., Wu, W. and Sun., L., ۲۰۲۰. Virtual power plant platforms and their applications in practice: a brief review. ۲۰۲۰ *IEEE Sustainable Power and Energy Conference (iSPEC)* pp. ۲۰۷۱-۲۰۷۶. *IEEE*. <https://doi.org/۱۰.۱۱۰۹/iSPEC۰۸۴۸,۲۰۲۰,۹۳۵۱۱۴۷>
5. Abdelaziz, Y. A., Hegazy, Y. G., Elkhattam, W. and Othman, M., ۲۰۱۳. Virtual power plant: The future of power delivery systems. *Second European Workshop on Renewable Energy Systems*. pp. ۱-۲. https://www.academia.edu/download/۷۲۷۶۲۸۶۹/VIRTUAL_POWER_PLANT_THE_FUTURE_OF_POWER_۲۰۲۱۱۰۱۵-۲۰۲۲۷-۱۰e۰k۲۱.pdf

٦. Rouzbahani, H. M., Karimipour, H. and Lei, L., ٢٠٢١. A review on virtual power plant for energy management. *Sustainable Energy Technologies and Assessments*, 47, pp.١٠١٣٧٠. <https://doi.org/١٠.١٠١٦/j.seta.٢٠٢١.١٠١٣٧٠>
٧. Warren, P., ٢٠١٤. A review of demand-side management policy in the UK. *Renewable and Sustainable Energy Reviews*, 29, pp.٩٤١-٩٥١. <https://doi.org/١٠.١٠١٦/j.rser.٢٠١٣.٠٩.٠٠٩>
٨. Park, S. and Son, S., ٢٠٢٠. Interaction-based virtual power plant operation methodology for distribution system operator's voltage management. *Applied Energy*, 271, pp.١١٥٢٢٢. <https://doi.org/١٠.١٠١٦/j.apenergy.٢٠٢٠.١١٥٢٢٢>
٩. Aguilar, J., Bordons, C. and Arce, A., ٢٠٢١. 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.١٠٧٣٠٤. <https://doi.org/١٠.١٠١٦/j.ijepes.٢٠٢١.١٠٧٣٠٤>
١٠. Nandkeolyar, S. and KumarRay, P., ٢٠٢٢. Multi objective demand side storage dispatch using hybrid extreme learning machine trained neural networks in a smart grid. *Journal of Energy Storage*, 51, pp.١٠٤٤٣٩. <https://doi.org/١٠.١٠١٦/j.est.٢٠٢٢.١٠٤٤٣٩>
١١. Kabirifar, M., Pourghaderi, N. and Moeini-Aghaie, M., ٢٠٢٢. Optimal operation strategy of virtual power plant considering EVs and ESSs. *Scheduling and Operation of Virtual Power Plants*, pp.٢٥٧-٢٩٧. <https://doi.org/١٠.١٠١٦/B٩٧٨-٠-٣٢-٣٨٥٢٦٧-٨,٠٠٠١٧-٢>
١٢. Ali, Y., ٢٠٢٣. A novel machine learning-based power trading algorithm (MLPTA) for demand side management (DSM). *2023 International Conference on Emerging Power Technologies (ICEPT)* pp.١-٥. IEEE. <https://doi.org/١٠.١١٠٩/ICEPT٥٨٨٥٩,٢٠٢٣,١٠.١٥٢٣٩٤>
١٣. Karimi, H., Jadid, S. and Hasanzadeh, S., ٢٠٢٣. 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.١٢٦-١٣٨. <https://doi.org/١٠.١٠١٦/j.spc.٢٠٢٢.١٢.٠٢٥>
١٤. Ahmadian, A., Ponnambalam, K., Almansoori, A. and Elkamel, A., ٢٠٢٣. Optimal management of a virtual power plant consisting of renewable energy resources and electric vehicles using mixed-integer linear programming and deep learning. *Energies*, 1٦(٢), pp.١٠٠٠. <https://doi.org/١٠.٣٣٩٠/en١٦.٢١.٠٠٠>
١٥. Singh, S., Subburaj, V., Sivakumar, K., Kumar, R., Muthuramam, M. S., Rastogi, R., Patil, V. R. and Rajaram, A., ٢٠٢٤. Optimum power forecasting technique for hybrid renewable energy systems using deep learning. *Electric Power Components and Systems*, pp.١-١٨. <https://doi.org/١٠.١٠٨٠/١٥٣٢٥٠.٠٨,٢٠٢٤,٢٣١٦٢٥١>
١٦. Zhaoxia, X., Jiakai, N., Guerrero, J. and Hongwei, F., ٢٠١٧. 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.٢٥٩٤-٢٥٩٩. IEEE. <https://doi.org/١٠.١١٠٩/IECON.٢٠١٧,٨٢١٦٤٣٦>
١٧. Ullah, Z., Arshad, and Hassanin, H., ٢٠١٧. 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(١٤), pp.٥٢٩٦. <https://doi.org/١٠.٣٣٩٠/en١٥١٤٥٢٩٦>
١٨. Fleischer, C., Waag, W., Bai, Z. and Sauer, D.U., ٢٠١٣. Adaptive on-line state-of-available-power prediction of lithium-ion batteries. *Journal of Power Electronics*, 1٣(٤), pp.٥١٦-٥٢٧. <https://doi.org/١٠.٦١١٣/JPE.٢٠١٣,١٣,٤,٥١٦>
١٩. Dehghani, B., Lotfi, M. and Sedighi, A., Development of machine learning algorithm for energy supply management in virtual power plant.

<https://ganj.irandoc.ac.ir/#/articles/۰e۴۶b۱۵۱۰۰۰۲۹e۱۰۳۲۰۰۱d۲۲۵۵۲۰۷۱۳۷>.
Persian]

[In