

兰州理工大学

科研成果汇总

学 号:	191081191002
研 究 生:	吴国栋
导 师:	包广清 教授
研究方向:	电力系统建模与优化运行优化
论文题目:	新能源高占比电力系统的多元储能协同配置与多时间尺度优化调度研究
学 科:	可再生能源发电与智能电网
学 院:	电气工程与信息工程学院
入学时间:	2019年 9 月

1.论文检索报告.....	1
2.Two-Stage, Three Layer Stochastic Model and Solution for Multiregionalism Based on Hybrid Game Theory.....	5
3.A Convolutional Neural Network-long Short-Term Memory-Attention Solar Photovoltaic Power Prediction-Correction Model Based on the Division of Twenty-Four Solar Terms.....	31
4.Reactive Power Dispatch Method for Wind Farms Based on Dynamic Weight Adjustment of Electrical Distance and Reactive Power Capacity.....	50
5.考虑可再生能源接入的主动配电网双层规划消纳优化方法	59
6.蝗虫优化算法与单一预测模型在干旱区光伏功率预测中的比较研究.....	71
7.基于双层调度模型和需求分析的新能源电网规划优化研究.....	79
8.基于时序模拟的新能源合理利用率分析.....	86
9.专利：一种基于新能源出力特性的新能源消纳能力测算方法.....	93
10.著作《新能源全合理利用率之路》	94

报告编号: 202505027

论文收录检索报告

数据来源:

"Science Citation Index Expanded (SCIE)"、中科院期刊分区、
JCR、" Engineering Village (EI) "

检索条件:

作者= Bao, Guangqing AND 地址= "Southwest Petroleum
University"

检索结果:

SCIE 收录论文 2 篇、EI 收录论文 2 篇

详细检索结果见附录。

注: 该报告检索论文均由被检索人提供并得到被检索人确认。

检索人员(不签字无效)



检索单位: 西南石油大学图书馆

检索时间: 2025 年 4 月 2 日



附录一： Science Citation Index Expanded (SCIE)收录 2 篇

第 1 条, 共 2 条

标题: Two-Stage, Three-Layer Stochastic Robust Model and Solution for Multi-Energy Access System Based on Hybrid Game Theory

作者: Wu, GD (Wu, Guodong); Li, XH (Li, Xiaohu); Wang, JH (Wang, Jianhui); Zhang, RX (Zhang, Ruixiao); Bao, GQ (Bao, Guangqing)

来源出版物: PROCESSES 卷: 12 期: 12 文献号: 2656 DOI: 10.3390/pr12122656 Published Date: 2024 DEC

Web of Science 核心合集中的 "被引频次": 0

被引频次合计: 0

入藏号: WOS:001384010900001

文献类型: Article

地址: [Wu, Guodong; Wang, Jianhui] Lanzhou Univ Technol, Coll Elect & Informat Engn, Lanzhou 730050, Peoples R China.

[Wu, Guodong; Li, Xiaohu] Grid Gansu Elect Power Co, Lanzhou 730030, Peoples R China.

[Zhang, Ruixiao] State Grid Gansu Elect Power Co, Elect Power Sci Res Inst, Lanzhou 730030, Peoples R China.

[Bao, Guangqing] SouthWest Petr Univ, Sch Elect & Informat Engn, Chengdu 610500, Peoples R China.

通讯作者地址: Wang, JH (通讯作者), Lanzhou Univ Technol, Coll Elect & Informat Engn, Lanzhou 730050, Peoples R China.

电子邮件地址: wuguodong0943@126.com; lixiaohu202411@126.com;

wangjianhui555@mail.dlut.edu.cn; changjuihsiao@foxmail.com; baogq03@163.com

Affiliations: Lanzhou University of Technology; State Grid Corporation of China; Southwest Petroleum University

eISSN: 2227-9717

开放获取: gold

输出日期: 2025-04-02

中科院期刊大类分区: 工程技术 4 区 (2023)

期刊影响因子: 2.8 (2023)

第 2 条, 共 2 条

标题: A Convolutional Neural Network-Long Short-Term Memory-Attention Solar Photovoltaic Power Prediction-Correction Model Based on the Division of Twenty-Four Solar Terms

作者: Wu, GD (Wu, Guodong); Hu, DG (Hu, Diangang); Zhang, YR (Zhang, Yongrui); Bao, GQ (Bao, Guangqing); He, T (He, Ting)

来源出版物: ENERGIES 卷: 17 期: 22 文献号: 5549 DOI: 10.3390/en17225549 Published Date: 2024 NOV

Web of Science 核心合集中的 "被引频次": 0

被引频次合计: 0



入藏号: WOS:001364717400001

文献类型: Article

地址: [Wu, Guodong] Lanzhou Univ Technol, Coll Elect & Informat Engr, Lanzhou 730050, Peoples R China.

[Wu, Guodong; Hu, Diangang; Zhang, Yongrui] Power Dispatch Ctr State Grid Gansu Elect Power Co, Lanzhou 730030, Peoples R China.

[Bao, Guangqing] SouthWest Petr Univ, Sch Elect & Informat Engr, Chengdu 610500, Peoples R China.

[He, Ting] Gansu Nat Energy Res Inst, Lanzhou 730046, Peoples R China.

通讯作者地址: Bao, GQ (通讯作者), SouthWest Petr Univ, Sch Elect & Informat Engr, Chengdu 610500, Peoples R China.

电子邮件地址: liulj_dky@gs.sgcc.com.cn; lvqc@gs.sgcc.com.cn; zhangrx_dky@gs.sgcc.com.cn; baogq@swpu.edu.cn; heting@gneri.com.cn

Affiliations: Lanzhou University of Technology; Southwest Petroleum University

eISSN: 1996-1073

开放获取: gold

输出日期: 2025-04-02

中科院期刊大类分区: 工程技术 4 区 (2023)

期刊影响因子: 3 (2023)

附录二: Engineering Village (EI) 收录2篇

1. A study of short-term wind power segmentation forecasting method considering weather on ramp segments (*Open Access*)

Accession number: 20244717375972

Authors: Yang, Chunxiang (1); Wu, Guodong (1, 2); Zhang, Yongrui (3); Bao, Guangqing (4); Wang, Jianhui (5)

Author affiliation: (1) Power Dispatch Center of State Grid Gansu Electric Power Company, Lanzhou, China; (2) Department of Electrical Engineering and Information Engineering, Lanzhou University of Technology, Lanzhou, China; (3) Electric Power Science Research Institute of State Grid Gansu Electric Power Company, Lanzhou, China; (4) School of Electronics and Information Engineering, Southwest Petroleum University, Chengdu, China; (5) School of Electrical Engineering, Northwest University for Nationalities, Lanzhou, China

Corresponding author: Yang, Chunxiang(2071763385@qq.com)

Source title: Frontiers in Energy Research

Abbreviated source title: Front. Energy Res.

Volume: 12

Issue date: 2024

Publication year: 2024

Article number: 1474969

Language: English

E-ISSN: 2296598X

Document type: Journal article (JA)



Publisher: Frontiers Media SA

DOI: 10.3389/fenrg.2024.1474969

Funding Details: Number: SGGSKY00WYJS2310221, Acronym: -, Sponsor: -;

Funding text: The authors declare that this study received funding from Electric Power Scientific Research Institute of State Grid Gansu Power Company. The funder had the following involvement in the study: the collection and analysis of the data, as well as the funder's decision to submit the article for publication. The author(s) declare that financial support was received for the research, authorship, and/or publication of this article. This work was supported in part by the Science and Technology Project of State Grid Gansu Electric Power Company Electric Power Science Research Institute under Grant (No. SGGSKY00WYJS2310221).

Compendex references: YES

Open Access type(s): All Open Access, Gold

Database: Compendex

Data Provider: Engineering Village

Compilation and indexing terms, Copyright 2025 Elsevier Inc.

2. Reactive power dispatch method for wind farms based on dynamic weight adjustment of electrical distance and reactive power capacity

Accession number: 20251218097131

Authors: Wu, Guodong (1, 2); Li, Xiaohu (2); Zhang, Ruixiao (2); Bao, Guangqing (3); Tan, Hongtao (3)

Author affiliation: (1) College of Electrical and Information Engineering, Lanzhou University of Technology, Lanzhou; 730050, China; (2) Power Dispatch Center of State Grid, Gansu Electric Power Company, Lanzhou; 730030, China; (3) School of Electronics and Information Engineering, Southwest Petroleum University, Chengdu; 610500, China

Corresponding author: Tan, Hongtao(13679261064@163.com)

Source title: Sustainable Energy Research

Abbreviated source title: Sustain. Energy. Research

Volume: 12

Issue: 1

Issue date: December 2025

Publication year: 2025

Article number: 12

Language: English

E-ISSN: 27319237

Document type: Journal article (JA)

Publisher: Springer Science and Business Media B.V.

DOI: 10.1186/s40807-025-00155-1

Funding text: This work is funded by State Grid Corporation of China project (No. SGGSKY00WYJS2310221).

Compendex references: YES

Database: Compendex

Data Provider: Engineering Village

Compilation and indexing terms, Copyright 2025 Elsevier Inc.



Article

Two-Stage, Three-Layer Stochastic Robust Model and Solution for Multi-Energy Access System Based on Hybrid Game Theory

Guodong Wu ^{1,2}, Xiaohu Li ², Jianhui Wang ^{1,*} , Ruixiao Zhang ³ and Guangqing Bao ⁴

¹ College of Electrical and Information Engineering, Lanzhou University of Technology, Lanzhou 730050, China; wuguodong0943@126.com

² Grid Gansu Electric Power Company, Lanzhou 730030, China; lixiaohu202411@126.com

³ Electric Power Science Research Institute of State Grid Gansu Electric Power Company, Lanzhou 730030, China; changjuihsiao@foxmail.com

⁴ School of Electronics and Information Engineering, Southwest Petroleum University, Chengdu 610500, China; baogq03@163.com

* Correspondence: wangjianhui555@mail.dlut.edu.cn

Abstract: This paper proposes a two-stage, three-layer stochastic robust model and its solution method for a multi-energy access system (MEAS) considering different weather scenarios which are described through scenario probabilities and output uncertainties. In the first stage, based on the principle of the master–slave game, the master–slave relationship between the grid dispatch department (GDD) and the MEAS is constructed and the master–slave game transaction mechanism is analyzed. The GDD establishes a stochastic pricing model that takes into account the uncertainty of wind power scenario probabilities. In the second stage, considering the impacts of wind power and photovoltaic scenario probability uncertainties and output uncertainties, a max–max–min three-layer structured stochastic robust model for the MEAS is established and its cooperation model is constructed based on the Nash bargaining principle. A variable alternating iteration algorithm combining Karush–Kuhn–Tucker conditions (KKT) is proposed to solve the stochastic robust model of the MEAS. The alternating direction method of multipliers (ADMM) is used to solve the cooperation model of the MEAS and a particle swarm algorithm (PSO) is employed to solve the non-convex two-stage model. Finally, the effectiveness of the proposed model and method is verified through case studies.



Citation: Wu, G.; Li, X.; Wang, J.; Zhang, R.; Bao, G. Two-Stage, Three-Layer Stochastic Robust Model and Solution for Multi-Energy Access System Based on Hybrid Game Theory. *Processes* **2024**, *12*, 2656. <https://doi.org/10.3390/pr12122656>

Academic Editor: Massimo Caruso

Received: 30 October 2024

Revised: 13 November 2024

Accepted: 20 November 2024

Published: 25 November 2024



Copyright: © 2024 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

Keywords: weather scenarios; hybrid game; stochastic robust; variable alternating iteration; particle swarm algorithm

1. Introduction

With the proposal of carbon neutrality targets, the distribution grid will integrate a large amount of renewable energy in the future, thereby reducing the use of fossil fuels. In order to fully integrate renewable energy, multi-energy access systems (MEASs) have emerged [1]. MEASs are capable of optimizing their internal operational status under specified electricity price backgrounds, achieving a dynamic balance with the distribution grid's energy interaction [2]. However, intermittent renewable energy poses challenges to the energy planning of MEASs [3]. Additionally, there will be more distributed MEASs connecting to the distribution grid in the future, which increases the difficulty of unified management for MEASs [4]. Therefore, addressing how to manage MEASs with uncertainty in energy and how to unify the management of multiple distributed MEASs are urgent challenges that need to be solved.

In recent years, scholars both domestically and internationally have conducted extensive research on the unified management of microgrids (MEASs). The general approach involves appointing a unified energy manager at the higher level of the MEAS, such as a grid dispatch department (GDD) [5]. The GDD is primarily responsible for coordinating

energy interactions between the distribution grid and the MEAS, while also establishing optimal electricity prices for the MEAS to achieve overall optimal benefits for both the GDD and the MEAS. From the perspective of game theory, the relationship between the GDD and MEAS can be understood as a leader–follower game where the GDD acts as the upper-level leader, setting electricity prices for the MEAS, while the MEAS can be seen as the lower-level follower, planning energy usage based on these prices. The GDD–MEAS relationship can achieve game equilibrium solutions [6]. For example, [6] deals with energy trading among MEASs through leader–follower games and establishes a multi-agent optimization scheduling model with multiple microgrid systems as leaders and load aggregators as followers. Another study [7] builds upon leader–follower games to establish an optimization configuration model for multi-microgrid systems with multiple microgrid operators as leaders and distribution grids as followers.

With the advancement of market trading mechanisms, some MEASs that are geographically proximate or have similar energy forms will, under the guidance of decision-making information, form cooperative alliances through point-to-point transactions among MEASs. This is referred to as the cooperative operation mode. In this cooperative operation, the GDD permits MEASs to flexibly select transactions with other MEASs to enhance their own benefits. Meanwhile, compared to MEASs' individual participation in market transactions, the formation of cooperative alliances also boosts the market competitiveness of MEASs [8]. One study [9] established a multi-MEAS cooperative optimization model by minimizing the electricity transaction costs between MEASs and market operators to optimize the centralized trading process and minimizing the electricity transaction costs among MEASs to optimize the decentralized trading process. Eventually, the Nash bargaining method was adopted to distribute the cooperative surplus value among multiple MEASs. From the perspective of game theory, this GDD–MEAS operation mode is actually a leader–follower–cooperative game model and the game model has expanded from a two-layer to a three-layer structure, with the intermediate layer being the follower cooperation layer. Another study [10] established a three-layer optimization model for the distribution network and multiple MEASs based on the leader–follower–cooperative game; studies [11,12] constructed a three-layer leader–follower–cooperative game model with the GDD as the leader and the collaborative operation of cold, heat, and electricity multi-energy coupled shared energy storage–prosumer.

At present, the main solution idea for the leader–follower–cooperative game model is the two-stage solution method; that is, the leader–follower problem is solved in the first stage and the cooperative problem in the second stage. Currently, methods for solving leader–follower game equilibrium solutions mainly include numerical methods based on Karush–Kuhn–Tucker (KKT) conditions [13–15], column constraint generation (C&CG) methods [16], heuristic intelligent algorithms [17–19], and the alternating direction method of multipliers (ADMM) [20]. Due to its decoupling characteristics and stable convergence, the ADMM commonly uses the second-stage distributed solving cooperative model [21]. The KKT numerical method is applicable to the scene where the second-stage problem is a two-level model, and can transform a two-level model into a single-level model, but this method is only applicable to the scene where the underlying model is a convex problem, so the underlying non-convex model needs to be simulated/convex in advance [22]. C&CG combined with KKT can solve the scenario where the second-stage problem is a three-level model. Generally, KKT is first used to convert the lowest two levels into a single level, so that the original problem can be simplified to a classical two-level problem, provided that the two-level model is convex [23]. Heuristic intelligent algorithms can overlook the non-convexity of the lower-level problem and are thus widely applied in solving leader–follower game models [24].

However, the above models of the master–slave game are mostly deterministic models, while there often exist uncertainty factors in MEASs, such as the uncertainty of output from renewable energy sources like wind turbines (WTs) and photovoltaics (PVs). The uncertainty factors in MEASs will affect the management of GDDs for MEASs [25]. For ex-

ample, the paper [26] studies the cooperative Stackelberg game energy management scheme considering price discrimination and risk assessment. The upper layer uses a stochastic programming method with a conditional risk value to establish a retailer stochastic pricing model, while the lower layer is based on a Nash bargaining game follower–cooperation model. The experiment shows that the stochastic pricing information will affect the direct trading price and trading volume of the followers at the same time. To solve this problem, scholars have proposed uncertainty handling methods such as stochastic programming [27,28] and robust optimization [29–31]. Stochastic optimization uses historical experience to generate random probability scenarios and then seeks the scheduling scheme with the lowest cost expectation. For example, reference [27] used stochastic optimization to study the impact of WT output uncertainty on MEAS energy planning. Reference [28] modeled the randomness of WTs based on probability distribution functions to optimize the operation of distribution networks. Robust optimization describes uncertain variables using various uncertainty sets to find the optimal solution under the worst-case scenario. Reference [29] described WT output fluctuations using box uncertainty sets and constructed a two-stage robust optimization scheduling model. Reference [30] described the uncertainty of user participation using box uncertainty sets. However, both of these methods have a certain one-sidedness and limitations: scenario-based stochastic optimization is suitable for situations where probability distribution functions are relatively easy to obtain, but it may lead to a huge computational burden, while robust optimization is suitable for situations where the distribution of uncertain parameters is difficult to determine or there is little historical data, and it has good robustness, but it has conservatism issues [31,32].

To address the conservatism issue, researchers have proposed some improved models based on stochastic and robust methods. For example, to consider the probability uncertainty of multiple uncertain parameters, the idea of stochastic optimization is incorporated into robust optimization to propose a four-level stochastic robust model with predictive probabilities [33,34]. Reference [35] used stochastic optimization and robust handling of uncertainty to establish a max–max–max–min microgrid robust model, and the results showed that the conservatism of this model is moderate. Reference [36] studied the hybrid game optimization model of a micro-energy network and consumer, considering the uncertainty of WTs and consumer response, and adopted robust optimization, the chance constraint method, KKT condition, McCormick envelope method, and ADMM method to solve the model, which effectively coordinated the scheduling of the micro-energy network and consumer and ensured the fairness of the consumer cooperation alliance. However, these models also have some problems, as stochastic optimization still needs to simulate its probability function based on a large amount of historical data. In addition, the maximization in the second and third layers of the four-level model is coupled, making it more difficult to solve the model. Therefore, it is necessary to develop robust models adapted to uncertain factors and study corresponding solution algorithms.

In summary, this paper establishes a two-stage, three-level stochastic robust model considering the probability and output uncertainty of WT and PV scenarios. The model is for a two-stage problem based on mixed games, where the first stage is a stochastic pricing model for the GDD and the second stage is a three-level structured MEAS stochastic robust cooperative model. Considering the difficulty of decoupling in the three-level stochastic robust model, a variable alternating iteration algorithm (AIV-KKT) combined with KKT is proposed. Considering the nonlinearity and non-convexity of the two-stage model, a particle swarm algorithm is used for solving.

2. Transaction Mechanism Analysis

Figure 1 depicts the GDD–MEAS transaction framework. In this framework, the MEAS consists of electric chillers (EC), absorption chillers (AC), combined heat and power systems (CHP), gas boilers (GB), heat storage (HS), and electricity storage (ES), forming a multi-energy supply system for cooling, heating, and electricity. In the first stage, the GDD acts as the leader and personalized electricity pricing is formulated based on the electricity

demand information from the MEASs, aiming to manage the MEASs effectively. The specific process is as follows: firstly, the GDD aggregates the electricity demand information from various MEASs, which is robust information considering both scenario and output uncertainties, thus resulting in a conservative estimate. Based on this information, the GDD sets a conservative pricing for electricity transactions. Subsequently, when an MEAS needs to purchase electricity, the GDD procures an equivalent amount from the electricity market at the grid price and resells it to the MEAS at the corresponding purchasing price; conversely, when an MEAS needs to sell electricity, the GDD purchases it from the MEAS at the corresponding selling price and resells it to the electricity market at the grid price. The GDD determines the purchasing and selling prices for each MEAS by maximizing the price difference.




Figure 1. A master-slave framework for trading.

In the second stage, each MEAS acts as a follower, formulating electricity purchase and sales plans based on the feedback from the GDD and arranging internal energy distribution reasonably. Typically, the selling price of electricity to the GDD is lower than the purchasing price from the GDD. Therefore, multiple MEASs can form cooperative alliances to reduce the overall electricity purchase from the GDD through internal electricity sharing, thereby saving electricity costs and improving economic benefits. Under the guidance of purchasing and selling prices, MEASs prioritize cooperation, which involves decentralized direct transactions. After completing direct transactions, MEASs report surplus or deficit electricity information to the GDD, which then determines the centralized trading electricity for each MEAS. After centralized trading, the GDD organizes Nash negotiations based on the basic information of each MEAS and allocates the cooperative surplus among multiple MEASs uniformly. In the proposed MEAS model, stochastic optimization and robust methods are utilized to handle uncertainties in WT and PV scenario probabilities and outputs. The uncertainty space of scenario probabilities is discretized based on a small amount of historical data to generate a typical scenario probability distribution, while the uncertainty space of WT output adopts a box-set form.

3. Two-Stage Stochastic Model

The objective of the two-stage stochastic model based on mixed games is to maximize operational profits.

$$U = U^{\text{DSO}} + \sum_{j=1}^N u_j^{\text{m,hz}} \quad (1)$$

where U represents the objective function of the model; U^{DSO} represents the operational profit of GDD; and $U_j^{\text{m,hz}}$ represents the operational profit under MEAS j . The maximizing model U^{DSO} is referred to as the stochastic pricing model for GDD, while the maximizing model $U_j^{\text{m,hz}}$ is referred to as the MEAS cooperation model.

3.1. GDD's Stochastic Pricing Model

3.1.1. Utility Function

As the leader, the GDD is obligated to manage the MEASs. The GDD determines the transaction prices between the GDD and each MEAS based on the spot electricity price and the grid electricity price. Generally, each MEAS's selling price is lower than its buying price to encourage each MEAS to arrange internal energy, further reducing external dependence. Meanwhile, the GDD aims to maximize price difference benefits. Therefore, the GDD's stochastic pricing model is

$$U^{\text{DSO}} = \max_x \sum_{s=1}^M \sum_{t=1}^T \sum_{j=1}^N \sigma_{j,s} \left(\frac{\beta_t^f p_{j,t,s}^{\text{m,S}} - \beta_t^c p_{j,t,s}^{\text{m,B}} + \beta_{j,t,s}^{\text{m,B}} p_{j,t,s}^{\text{m,B}} - \beta_{j,t,s}^{\text{m,S}} p_{j,t,s}^{\text{m,S}}}{\beta_{j,t,s}^{\text{m,B}} p_{j,t,s}^{\text{m,B}} - \beta_{j,t,s}^{\text{m,S}} p_{j,t,s}^{\text{m,S}}} \right) \quad (2)$$

where $x = (\beta_{j,t,s}^{\text{m,B}}, \beta_{j,t,s}^{\text{m,S}}, \sigma_{j,s})$ represents the set of decision variables. Among them, $\beta_{j,t,s}^{\text{m,B}}$ and $\beta_{j,t,s}^{\text{m,S}}$ denote the prices at which the j -th MEAS buys electricity from the GDD and sells electricity to the GDD at time t ; namely, the purchase price and the selling price set by the GDD for the MEAS; $p_{j,t,s}^{\text{m,B}}$ and $p_{j,t,s}^{\text{m,S}}$ represent the amount of electricity purchased and sold by the j -th MEAS to the GDD at time t under scenario s , respectively; $\sigma_{j,s}$ represents the probability distribution of scenario s for the j -th MEAS; β_t^f and β_t^c represent the on-grid electricity price and off-grid electricity price at time t , respectively; M denotes the number of scenarios; N denotes the total number of MEASs; and T denotes the scheduling period.

3.1.2. Strategy Space

$$\beta_t^f \leq \beta_{j,t,s}^{\text{m,S}} \leq \beta_{j,t,s}^{\text{m,B}} \leq \beta_t^c \quad (3)$$

Equation (2) represents the strategy space Ω^D of the GDD's random pricing model. It constrains the pricing space of the GDD, where the purchasing price $\beta_{j,t,s}^{\text{m,B}}$ set by the GDD is not greater than the off-grid electricity price β_t^c , and the selling price $\beta_{j,t,s}^{\text{m,S}}$ is not less than the on-grid electricity price β_t^f . In order to maximize its own interests, the MEAS will choose to trade with the GDD.

3.2. Multi-MEAS Random-Robust Cooperation Model

3.2.1. Utility Function

The objective function of the MEAS is to minimize its costs, which is in the form of a max–max–min three-level random model. The first level involves finding the worst-case probability distribution of the WTs, the second level is to determine the worst-case output of the WTs, and the third level is to devise the optimal operating strategy for the MEAS to minimize its operational costs, including energy storage operational costs C_j^{cn} , purchasing and selling electricity costs C_j^{m} , and cooperation costs C_{ji}^{hz} .

$$\begin{cases} U_j^{\text{m,hz}} = \max_{\sigma_s} \max_{P_{j,t,s}^{\{\cdot\}} \cdot} \min_{y_j} (C_j^{\text{cn}} + C_j^{\text{m}} + C_{ji}^{\text{hz}}) \\ y_j = \begin{pmatrix} p_{ji,t,s}^{\text{phz}}, \beta_{ji,t,s}^{\text{phz}}, p_{j,t,s}^{\text{m,S}}, p_{j,t,s}^{\text{m,B}}, p_{j,t,s}^{\text{desc}}, p_{j,t,s}^{\text{descd}}, \\ p_{j,t,s}^{\text{phsc}}, p_{j,t,s}^{\text{phsdc}}, g_{j,t,s}^{\text{chp}}, p_{j,t,s}^{\text{pec}}, g_{j,t,s}^{\text{gb}}, h_{j,t,s}^{\text{ac}}, \\ b_{j,t,s}^{\text{esc}}, b_{j,t,s}^{\text{escd}}, b_{j,t,s}^{\text{hsc}}, b_{j,t,s}^{\text{hscd}} \end{pmatrix} \end{cases} \quad (4)$$

where σ_s represents the probability distribution of the s -th class; $P_{j,t,s}^{\{\cdot\}}$ represents the WT and PV power of the j -th MEAS at time t under scenario s ;

$y_j = \left(\begin{matrix} p_{ji,t,s}^{hz}, \beta_{ji,t,s}^{hz}, p_{j,t,s}^{m,S}, p_{j,t,s}^{m,B}, p_{j,t,s}^{esc}, p_{j,t,s}^{esdc}, p_{j,t,s}^{hsc}, p_{j,t,s}^{hscd} \\ g_{j,t,s}^{chp}, p_{j,t,s}^{ec}, g_{j,t,s}^{gb}, h_{j,t,s}^{ac}, b_{j,t,s}^{esc}, b_{j,t,s}^{esdc}, b_{j,t,s}^{hsc}, b_{j,t,s}^{hscd} \end{matrix} \right)$ is the set of operational decision variables for the j -th MEAS, where $P_{ji,t,s}^{hz}$ represents the direct trading electric power between the j -th MEAS and the i -th MEAS at time t in scenario s ; $\beta_{ji,t,s}^{hz}$ is the direct trading price between the j -th and i -th MEASs at time t ; $p_{j,t,s}^{esc}$ and $p_{j,t,s}^{esdc}$ respectively represent the charging and discharging power of the j -th MEAS's ES in scenario s at time t ; $b_{j,t,s}^{esc}$ and $b_{j,t,s}^{esdc}$ represent the state variables of the ES of the j -th MEAS at time t under scenario s , and $b_{j,t,s}^{esc} = 1$ indicates that the ES is charging, while $b_{j,t,s}^{esdc} = 1$ indicates that the ES is discharging. $p_{j,t,s}^{hsc}$ and $p_{j,t,s}^{hscd}$ represent the charging and discharging power of the j -th MEAS's HS at time t in scenario s ; $b_{j,t,s}^{hsc}$ and $b_{j,t,s}^{hscd}$ respectively represent the state variables of the j -th MEAS's HS in scenario s at time t , and $b_{j,t,s}^{hsc} = 1$ indicates that the HS is currently charging, while $b_{j,t,s}^{hscd} = 1$ indicates that the HS is discharging. $g_{j,t,s}^{chp}$ represents the gas power of the CHP of the j -th MEAS at time t in scenario s ; $p_{j,t,s}^{ec}$ represents the EC of the j -th MEAS at time t in scenario s ; $g_{j,t,s}^{gb}$ represents the gas power generation of the j -th MEAS in scenario s at time t ; and $h_{j,t,s}^{ac}$ represents the heating power of the j -th MEAS's AC in scenario s at time t .

$$C_j^{cn} = \beta_j^e \sum_{t=1}^T \sum_{s=1}^S \sigma_s (p_{j,t,s}^{esc} + p_{j,t,s}^{esdc}) + \beta_j^h \sum_{t=1}^T \sum_{s=1}^S \sigma_s (p_{j,t,s}^{hsc} + p_{j,t,s}^{hscd}) \quad (5)$$

$$C_j^m = \sum_{t=1}^T \sum_{s=1}^S \sigma_s (\beta_{j,t,s}^{m,B} p_{j,t,s}^{m,B} - \beta_{j,t,s}^{m,S} p_{j,t,s}^{m,S}) \quad (6)$$

$$C_{ji}^{hz} = \sum_{i=1, j \neq i}^N \sum_{t=1}^T \sum_{s=1}^S \sigma_s \beta_{ji,t,s}^{hz} p_{ji,t,s}^{hz} \quad (7)$$

where σ_s represents the probability distribution of scenario s ; β_j^e represents the unit price of charging and discharging power for the j -th ES of the MEAS.

3.2.2. Strategy Space

(1) Uncertainty space of WT and PV scenario probabilities

The probability values of scenarios, denoted as σ_s , theoretically can be within any range. However, to ensure the economic and feasible nature of scheduling schemes, it is necessary to constrain the probabilities of the most adverse WT and PV output scenarios within reasonable bounds to ensure their fluctuations are within acceptable limits. In the group M_C of WT or PV output scenarios, the scenario reduction method is employed to select a subset S as the basis scenario, and the probability values of this subset, denoted as M , are taken as the initial scenario probabilities σ_s^0 . The probability values in actual scenarios cannot be consistent with the initial scenario probabilities, and uncertainty still exists. In order to solve for the worst-case scenario and probability distribution, a comprehensive norm constraint is applied to the probabilities of each scenario, with the initial scenario probability values as the center:

$$\Omega_\sigma = \left\{ \sigma_s \mid \sigma_s \geq 0, \sum_{s=1}^M \sigma_s = 1, \sum_{s=1}^M |\sigma_s - \sigma_s^0| \leq \theta_1, \max_{1 \leq s \leq M} |\sigma_s - \sigma_s^0| \leq \theta_\infty \right\} \quad (8)$$

where Ω_σ represents the probability uncertainty space for WT and PV classes; θ_1 and θ_∞ are the allowable deviation values for actual scenario probabilities under the 1-norm

condition and ∞ -norm condition, respectively. According to reference [31], the following can be derived:

$$\begin{cases} \theta_1 = \frac{M}{2M_C} \ln \frac{2M}{1-\alpha_1} \\ \theta_\infty = \frac{1}{2M_C} \ln \frac{2M}{1-\alpha_\infty} \end{cases} \quad (9)$$

where α_1 and α_∞ represent the confidence levels of the 1-norm condition and the ∞ -norm condition, respectively. Equation (8) indicates that as the historical data volume S_C increases, the allowable deviation values θ_1 and θ_∞ of the actual scenario probabilities under the 1-norm condition and the ∞ -norm condition become smaller. The probability distributions of each scenario also tend to converge towards the true situation. Consequently, the uncertainty of WT and PV output considered in the scheduling scheme decreases, and its conservatism is also lower.

(2) Uncertainty sets of WT and PV output

The uncertainty sets of WT and PV output are represented as

$$D^j = \left[\begin{array}{l} P_j^{\{\cdot\}} \in \mathbb{R}^{T \times S} : (P_{j,t,s}^{\{\cdot\}} - P_{j,t,s}^{\{\cdot\},f}) / \Delta_{j,t,s}^{\{\cdot\}} = \xi_{j,t,s}^{\{\cdot\}} \\ \sum_{t=1}^T \xi_{j,t,s}^{\{\cdot\}} \leq \Gamma_{j,s}^{\{\cdot\}}, 0 \leq \xi_{j,t,s}^{\{\cdot\}} \leq 1, \\ P_{j,t,s}^{\{\cdot\},f} - \Delta_{j,t,s}^{\{\cdot\}} \leq P_{j,t,s}^{\{\cdot\}} \leq P_{j,t,s}^{\{\cdot\},f} + \Delta_{j,t,s}^{\{\cdot\}} \\ \{\cdot\} = \{ES, HS\} \end{array} \right] \quad (10)$$

where D^j represents the uncertain space of WT and PV; $P_j^{\{\cdot\}}$ is in the vector form of variable $P_{j,t,s}^{\{\cdot\}}$; $P_{j,t,s}^{\{\cdot\},f}$ represents the predicted power of WT and PV of the j -th MEAS at time t ; $\Delta_{j,t,s}^{\{\cdot\}}$ represents the maximum fluctuation amplitude of the WT and PV of the j -th MEAS at time t ; $\xi_{j,t,s}^{\{\cdot\}}$ represents the fluctuation ratio of WT and PV of the j -th microgrid at time t ; and $\Gamma_{j,s}^{\{\cdot\}}$ represents the uncertainty margin of WT and PV of the j -th microgrid, used to adjust the conservatism of the uncertainty set.

(3) Electricity trading constraints

$$0 \leq P_{j,t,s}^{m,S} \leq P_{j,\max}^m \quad (11)$$

$$0 \leq P_{j,t,s}^{m,B} \leq P_{j,\max}^m \quad (12)$$

$$P_{j,t,s}^m = P_{j,t,s}^{m,S} - P_{j,t,s}^{m,B} \quad (13)$$

$$0 \leq P_{ji,t,s}^{phz} \leq P_{j,\max}^{phz} \quad (14)$$

where $P_{j,\max}^m$ represents the maximum electricity trading volume between the j -th MEAS and GDD; $P_{j,t,s}^m$ represents the total electricity trading volume between the j -th MEAS and GDD at time t under scenarios; and $P_{j,\max}^{phz}$ represents the maximum electricity trading volume between the j -th MEAS and other MEASs.

(4) Power balance constraints

Power balance constraints primarily involve the balance of electrical power exchange between MEASs and the balance of supply and demand within each MEAS:

$$P_{ij,t,s}^{phz} = P_{ji,t,s}^{phz} \quad (15)$$

$$P_{j,t,s}^{m,B} + P_{ji,t,s}^{phz} + P_{j,t,s}^w + P_{j,t,s}^{pv} + \alpha_e^{chp} g_{j,t,s}^{chp} + P_{j,t,s}^{pesc} = P_{j,t}^L + P_{j,t,s}^{pesc} + P_{j,t,s}^{m,S} + P_{j,t,s}^{pec} \quad (16)$$

$$\alpha_h^{chp} g_{j,t,s}^{chp} + \alpha_h^{gb} g_{j,t,s}^{gb} + h_{j,t,s}^{hsdc} = h_{j,t}^L + h_{j,t,s}^{ac} + h_{j,t,s}^{hsc} \quad (17)$$

$$\alpha_c^{ec} P_{j,t,s}^{ec} + \alpha_c^{ac} h_{j,t,s}^{ac} = c_{j,t}^L \quad (18)$$

$$g_{j,t,s}^{chp} + g_{j,t,s}^{gb} = g_{j,t,s}^{buy} \quad (19)$$

where, $P_{ij,t,s}^{\text{hz}}$ represents the direct trading electric power between the i -th and j -th MEAS at time t under scenario s ; α_e^{chp} , α_h^{chp} , α_h^{gb} , α_c^{ec} , α_c^{ac} represent the energy conversion efficiency of CHP, GB, EC, AC; $P_{j,t}^{\text{L}}$, $h_{j,t}^{\text{L}}$, $c_{j,t}^{\text{L}}$ represent the fixed loads of the j -th MEAS at time t ; $g_{j,t,s}^{\text{buy}}$ represents the gas source power of the j -th MEAS at time t under scenario s .

(5) Price constraints

Due to the purchase price of electricity set by GDD for MEASs being greater than the selling price, assuming multiple MEASs form cooperation at the lower level, the participating MEASs will engage in electricity power exchange at a lower price among themselves. This is to facilitate energy sharing among the MEASs.

$$\beta_{i,t}^{\text{m,S}} \leq \beta_{ji,t,s}^{\text{hz}} \leq \beta_{j,t}^{\text{m,B}} \quad (20)$$

$$\beta_{ji,t}^{\text{hz}} = \beta_{ij,t}^{\text{hz}} \quad (21)$$

(6) Equipment models and constraints.

Constraints for GB, CHP, ES, HS, EC, AC, and GS are detailed in Appendix A (A1)–(A7).

The above Equations (8)–(21) and Equations (A1)–(A7) collectively form the strategy space $\Omega^{\text{m,hz}}$ A of the MEAS stochastic model.

3.3. Dual-Layer Model

Building upon Sections 3.1 and 3.2, we establish a dual-layer model for GDD and multiple MEASs based on the master–slave game, as follows:

$$\begin{aligned} (\tilde{\beta}_{i,t,s}^{\text{m,S}}, \tilde{\beta}_{i,t,s}^{\text{m,B}}, \tilde{\beta}_{j,t,s}^{\text{m,S}}, \tilde{\beta}_{j,t,s}^{\text{m,B}}) &= \arg \left\{ U^{\text{DSO}} \left(\begin{array}{c} \tilde{p}_{i,t,s}^{\text{m,S}}, \tilde{p}_{i,t,s}^{\text{m,B}}, \tilde{\sigma}_{i,s}, \tilde{p}_{j,t,s}^{\text{m,S}} \\ \tilde{p}_{j,t,s}^{\text{m,B}}, \tilde{\sigma}_{j,s} \end{array} \right) \right. \\ &\quad \text{s.t. } (\tilde{\beta}_{i,t,s}^{\text{m,S}}, \tilde{\beta}_{i,t,s}^{\text{m,B}}, \tilde{\beta}_{j,t,s}^{\text{m,S}}, \tilde{\beta}_{j,t,s}^{\text{m,B}}) \in \Omega^{\text{D}} \\ (\tilde{p}_{i,t,s}^{\text{m,S}}, \tilde{p}_{i,t,s}^{\text{m,B}}, \tilde{\sigma}_{i,s}, \tilde{p}_{ij,t,s}^{\text{hz}}, \tilde{\beta}_{ij,t,s}^{\text{hz}}) &= \arg \left\{ U_i^{\text{m,hz}} \left(\begin{array}{c} \tilde{\beta}_{i,t,s}^{\text{m,S}}, \tilde{\beta}_{i,t,s}^{\text{m,B}} \\ \tilde{p}_{ij,t,s}^{\text{hz}}, \tilde{\beta}_{ji,t,s}^{\text{hz}} \end{array} \right) \right. \\ &\quad \text{s.t. } (\tilde{p}_{i,t,s}^{\text{m,S}}, \tilde{p}_{i,t,s}^{\text{m,B}}, \tilde{p}_{ij,t,s}^{\text{hz}}, \tilde{\beta}_{ij,t,s}^{\text{hz}}) \in \Omega_i^{\text{m,hz}} \\ &\quad \dots, \\ (\tilde{p}_{j,t,s}^{\text{m,S}}, \tilde{p}_{j,t,s}^{\text{m,B}}, \tilde{\sigma}_{j,s}, \tilde{p}_{ji,t,s}^{\text{hz}}, \tilde{\beta}_{ji,t,s}^{\text{hz}}) &= \arg \left\{ U_j^{\text{m,hz}} \left(\begin{array}{c} \tilde{\beta}_{j,t,s}^{\text{m,S}}, \tilde{\beta}_{j,t,s}^{\text{m,B}} \\ \tilde{p}_{ij,t,s}^{\text{hz}}, \tilde{\beta}_{ji,t,s}^{\text{hz}} \end{array} \right) \right. \\ &\quad \text{s.t. } (\tilde{p}_{j,t,s}^{\text{m,S}}, \tilde{p}_{j,t,s}^{\text{m,B}}, \tilde{p}_{ji,t,s}^{\text{hz}}, \tilde{\beta}_{ji,t,s}^{\text{hz}}) \in \Omega_j^{\text{m,hz}} \end{aligned} \quad (22)$$

where $\tilde{p}_{i,t,s}^{\text{m,S}}, \tilde{p}_{i,t,s}^{\text{m,B}}, \tilde{p}_{j,t,s}^{\text{m,S}}, \tilde{p}_{j,t,s}^{\text{m,B}}$ represents the power vectors transmitted by consumers i and j to the GDD, respectively, $\tilde{\sigma}_{i,s}, \tilde{\sigma}_{j,s}$ represents the probability distribution values transmitted by consumers i and j to GDD, and $\tilde{\beta}_{i,t,s}^{\text{m,S}}, \tilde{\beta}_{i,t,s}^{\text{m,B}}, \tilde{\beta}_{j,t,s}^{\text{m,S}}, \tilde{\beta}_{j,t,s}^{\text{m,B}}$ represents the price variables transmitted by the GDD to consumers i and j . These variables can be classified as master–slave variables; $\tilde{p}_{ij,t,s}^{\text{hz}}$ and $\tilde{p}_{ji,t,s}^{\text{hz}}$ is a pair of power coupling variable vectors between producer–consumer i and producer–consumer j , while $\tilde{\beta}_{ij,t,s}^{\text{hz}}$ and $\tilde{\beta}_{ji,t,s}^{\text{hz}}$ are a pair of price coupling variable vectors between producer–consumer i and producer–consumer j , classified as cooperative coupling vectors. The proposed model is a max–max–max–min two-stage, four-layer structure. The first stage is the first-layer max, which is the dynamic pricing model of the GDD, determining the purchase–sale electricity prices for the second stage. The second stage consists of the last three layers of max–max–min, representing a stochastic–robust model of the MEAS under producer–consumer cooperation. It relies on the purchase–sale electricity prices determined in the first stage to determine the optimal energy allocation and cooperative prices for producer–consumers. When ignoring the probability uncertainty of WTs, the model can be simplified into a max–max–min two-stage, three-layer robust model; when ignoring the output uncertainty of WTs, the model can be simplified into a max–max–min two-stage, three-layer stochastic model; and when

simultaneously ignoring the probability-output uncertainty of the WT, the model can be simplified into a max–min two-stage two-layer deterministic model.

In Equation (22), the GDD and MEAS formulate strategies with the objectives of maximizing revenue and minimizing operational costs, respectively. The GDD's revenue is dependent on the set electricity prices and the trading volume of the MEAS: a larger price differential between buying and selling electricity results in a higher trading volume for the MEAS, thereby increasing the GDD's revenue. However, the MEAS's response to electricity prices also affects the GDD's revenue: higher buying prices lead to a lower purchasing volume for the MEAS, while lower selling prices lead to a reduced selling volume, resulting in a decrease in the trading volume between the MEAS and GDD. Thus, there exists a game of interests between the GDD and MEAS. To maximize its own revenue, the GDD needs to consider the MEAS's response to prices and seek a Nash equilibrium solution through game theory as the optimal pricing strategy.

Considering the equilibrium solution and its proof in principal–agent games, when there exists an equilibrium solution in principal–agent two-tier models, the following conditions must be satisfied [37]: (1) The strategy sets Ω^D , $\Omega_i^{m,hz}$, and $\Omega_j^{m,hz}$ are all non-empty bounded subsets of their respective Euclidean spaces; (2) $U_i^{m,hz}$ and $U_j^{m,hz}$ concern quasi-concave functions with respect to the variables $\Omega_i^{m,hz}$ and $\Omega_j^{m,hz}$; and (3) U^{DSO} is a continuous function concerning Ω^D , $\Omega_i^{m,hz}$, and $\Omega_j^{m,hz}$.

From Equation (2), it is clear that condition 3 is satisfied. Considering Equations (3), (8), (10)–(21), and (A1)–(A7), we can conclude that strategy sets Ω^D , $\Omega_i^{m,hz}$, and $\Omega_j^{m,hz}$ are all non-empty quasiconvex sets, thus satisfying condition 1. Furthermore, Equations (5)–(7) indicate that the cost indicators of the MEAS stochastic–robust model are all linear functions, implying that $U_i^{m,hz}$ and $U_j^{m,hz}$ are quasiconcave functions, fulfilling condition 2. Therefore, in Equation (22), assuming $A = (\tilde{\beta}_{i,t,s}^{m,S}, \tilde{\beta}_{i,t,s}^{m,B}, \tilde{\beta}_{j,t,s}^{m,S}, \tilde{\beta}_{j,t,s}^{m,B}, \tilde{p}_{i,t,s}^{m,S}, \tilde{p}_{i,t,s}^{m,B}, \tilde{p}_{j,t,s}^{m,S}, \tilde{p}_{j,t,s}^{m,B}, \tilde{\sigma}_{i,s}, \tilde{\sigma}_{j,s})$ is a strategy set for the principal–agent game's two-layer model, then according to the definition of the equilibrium solution in principal–agent games, it is considered an equilibrium solution when it satisfies the following conditions:

$$\left\{ \begin{array}{l} U^D(A) \geq U^D \left(\begin{array}{l} \beta_{i,t,s}^{m,S}, \beta_{i,t,s}^{m,B}, \beta_{j,t,s}^{m,S}, \beta_{j,t,s}^{m,B} \\ \tilde{p}_{i,t,s}^{m,S}, \tilde{p}_{i,t,s}^{m,B}, \tilde{p}_{j,t,s}^{m,S}, \tilde{p}_{j,t,s}^{m,B}, \tilde{\sigma}_{i,s}, \tilde{\sigma}_{j,s} \end{array} \right) \\ U_i^m(\tilde{\beta}_{i,t,s}^{m,S}, \tilde{\beta}_{i,t,s}^{m,B}, \tilde{p}_{i,t,s}^{m,S}, \tilde{p}_{i,t,s}^{m,B}, \tilde{p}_{ij,t,s}^{m,hz}, \tilde{\sigma}_{i,s}) \leq \\ U_i^m(\tilde{\beta}_{i,t,s}^{m,S}, \tilde{\beta}_{i,t,s}^{m,B}, p_{i,t,s}^{m,S}, p_{i,t,s}^{m,B}, \tilde{p}_{ij,t,s}^{m,hz}, \sigma_{i,s}) \\ U_j^m(\tilde{\beta}_{j,t,s}^{m,S}, \tilde{\beta}_{j,t,s}^{m,B}, \tilde{p}_{j,t,s}^{m,S}, \tilde{p}_{j,t,s}^{m,B}, \tilde{p}_{ji,t,s}^{m,hz}, \tilde{\sigma}_{j,s}) \leq \\ U_j^m(\tilde{\beta}_{j,t,s}^{m,S}, \tilde{\beta}_{j,t,s}^{m,B}, p_{j,t,s}^{m,S}, p_{j,t,s}^{m,B}, \tilde{p}_{ji,t,s}^{m,hz}, \sigma_{j,s}) \end{array} \right. \quad (23)$$

4. Model Solving

4.1. Solution of Two-Layer Model

The two-layer model based on the principal–agent game is solved using the Particle Swarm Optimization (PSO) algorithm [38,39]. The schematic diagram of variable exchange in the model is shown in Figure 2. The specific steps are as follows:

- (1) Initialize system parameters, including the on-grid electricity price, off-grid electricity price, MEAS parameters, and relevant parameters of the PSO algorithm;
- (2) Generate initial sample points $\beta_{j,t,s,q}^{m,S}$ and $\beta_{j,t,s,q}^{m,B}$ based on Latin Hypercube Sampling (LHS), with a total of Q samples;
- (3) The MEAS calculates its collaborative model based on $\beta_{j,t,s,q}^{m,S}(k)$ and $\beta_{j,t,s,q}^{m,B}(k)$ (where k is the iteration count), obtaining the optimal purchase and sale electricity plans $p_{j,t,s,q}^{m,S}(k)$ and $p_{j,t,s,q}^{m,B}(k)$, and provides feedback to the GDD;

- (4) Solve the GDD stochastic pricing model based on Equation (1), and compute the objective function $U_q^D(k)$;
- (5) Update individual historical best prices $\beta_{j,t,s,q}^{m,S*}(k)$ and $\beta_{j,t,s,q}^{m,B*}(k)$, as well as individual historical best profits U^{D*} ;
- (6) Perform a selection operation: if the condition $U_q^D(k) > U^{D*}$ is met, designate $\beta_{j,t,s,q}^{m,S}(k)$ and $\beta_{j,t,s,q}^{m,B}(k)$ as the group's historical best prices and select them as the internal electricity prices for the next iteration. Otherwise, designate $\beta_{j,t,s,q}^{m,S*}(k)$ and $\beta_{j,t,s,q}^{m,B*}(k)$ as the internal electricity prices for the next iteration and update the group's historical best revenue to U^{D*} ;
- (7) Let $k = k + 1$. If $k \leq K$ (where K is the maximum number of iterations), return to step 2). Otherwise, output the optimal result.




Figure 2. Variable exchange process of the dual-layer model.

4.2. Solving the Cooperation Model of Multiple MEAS

In the two-tier model, the second stage involves solving the cooperation prices and power exchange between the MEASs. The cooperation coupling vectors in Equation (22) cancel each other out, making direct solution difficult. Therefore, the MEAS cooperation model can be characterized as a Nash bargaining model and transformed into two sub-problems: maximizing cooperation benefits (P1) and distributing cooperation profits (P2), to avoid the non-convex problem of the Nash bargaining model. The detailed transformation process is described in Appendix B.

A Nash bargaining model is adopted to construct the producer–consumer cooperation model.

$$\begin{aligned}
 U^{m,hz} &= \max \prod_{j=1}^N (U_j^{m,hz} - U_j^{m,0}) \\
 U_j^{m,hz} &= \max_{\sigma_s} \max_{P_{j,s,t}^{\{ \cdot \}}} \min_{y_j} (C_j^{cn} + C_j^m + C_{ji}^{hz}) \\
 \text{s.t. } U_j^{m,hz} &\geq U_j^{m,0}, \Omega_j^{m,hz}
 \end{aligned} \tag{24}$$

where $U_j^{m,0}$ represents the profit obtained by the j -th MEAS that did not participate in the cooperation.

P1:

$$U_{p1} = \max \sum_{j=1}^N \underbrace{[\max_{\sigma_s} \max_{P_{j,t,s}^{\{\cdot\}} \beta_{ji,t}^{hz} \notin y_j} \min (C_j^{\text{en}} + C_j^{\text{m}})]}_{W_j^{\text{m,hz}}} \quad (25)$$

s.t. $\Omega_j^{\text{m,hz}} \notin \{(7), (20) - (21)\}$

where $W_j^{\text{m,hz}}$ represents the cost under cooperation, excluding P2P revenue. Since the transaction electricity price, total sold electricity power, and total purchased electricity power are all the same between producers and consumers, the transaction costs $\sum_{i=1, j \neq i}^N C_{ji}^{\text{hz}} + \sum_{j=1, i \neq j}^N C_{ij}^{\text{hz}} = 0$ related to electricity power within producers and consumers can be omitted in Equations (7), (20), and (21). The transaction electricity price in Equations (20) and (21) will be solved in P2.

P2:

$$U_{p2} = \min \sum_{\beta_{ji,t,s}^{hz}}^N \ln(W_j^{\text{m,hz}*} + C_{ji}^{\text{hz}*} - U_j^{\text{m},0})$$

$$C_{ji}^{\text{hz}*} = \sum_{i=1, j \neq i}^N \sum_{t=1}^T \sum_{s=1}^S \sigma_s \beta_{ji,t,s}^{hz} P_{ji,t,s}^{\text{hz}*} \quad (26)$$

s.t. $W_j^{\text{m,hz}*} + C_{ji}^{\text{hz}*} \geq U_j^{\text{m},0}$
(7), (20) – (21)

where variables with superscript * denote the optimal solution for P1.

The distributed solving of P1 and P2 is achieved using ADMM, the solving principle of which is detailed in Appendix C. Consensus variables need to be introduced to decouple Equations (15) and (21), so that only information about cooperative plans needs to be provided without specific network topologies and operational modes, in order to protect their privacy, as shown in Equation (27):

$$\begin{aligned} \sigma_{ij,t,s}^{\text{p1}} &= P_{ij,t,s}^{\text{hz}}, \sigma_{ji,t,s}^{\text{p1}} = P_{ji,t,s}^{\text{hz}} \\ \sigma_{ij,t,s}^{\text{p2}} &= \beta_{ij,t,s}^{\text{hz}}, \sigma_{ji,t,s}^{\text{p2}} = \beta_{ji,t,s}^{\text{hz}} \end{aligned} \quad (27)$$

4.3. Solving the MEAS Random–Robust Model

Equation (25) is solved through ADMM in a distributed manner, decomposed into j three-layered MEAS random–robust models, ensuring the optimality of the external electrical energy allocation for MEAS under the most adverse renewable energy scenarios and worst output conditions. Due to the problem's nonlinear coupling nature, it cannot be directly solved. Therefore, the AIV algorithm is introduced to perform variable alternating iterative solving. Firstly, independent optimization variables are identified, then by fixing different independent optimization variables, the original optimization problem is decoupled into multiple simplified sub-problems, and finally, multiple sub-problems are alternately solved.

The random–robust model of the MEAS can be abbreviated as

$$\begin{aligned} &\max_{\sigma \in \Omega_{\sigma} P_j^{\{\cdot\}} \in D_j} \max_{Y_j^{\text{m}} \in \Omega_j^{\text{m,hz}}(x^*, \sigma, P_j^{\{\cdot\}})} \min_{a^T Y_j^{\text{m}}} \\ &\text{s.t. } A Y_j^{\text{m}} \leq B, C Y_j^{\text{m}} \leq f(P_j^{\{\cdot\}}), \\ &\quad E \sigma \leq h, I P_j^{\{\cdot\}} \leq J, \end{aligned} \quad (28)$$

where σ represents the vector form of σ^s ; Y_j^{m} represents the vector form of variables in $\beta_{ji,t}^{\text{hz}} \notin y_j$; x^* denotes the optimum value of the upper-level GDD; f denotes a function related to uncertainty; and a, A, B, C, E, h, I , and J are matrices with constant coefficients.

The first set of constraints includes Equations (11)–(15), (17)–(19), and (A1)–(A7). The second set of constraints is represented by Equation (16). The third set of constraints is represented by Equation (8). The fourth set of constraints is represented by Equation (10).

In Equation (28), σ and $P_j^{\{\cdot\}}$ are two sets of independent optimization variables, while Y_j^m belongs to $\Omega_j^{m,hz}(\sigma, P_j^{\{\cdot\}})$ and is a non-independent variable. Fixing σ and $P_j^{\{\cdot\}}$ separately decouples the original problem into two sub-problems: one with σ fixed and the other with $P_j^{\{\cdot\}}$ fixed.

(a) σ Fixed Problem

$$\begin{aligned} & \max_{P_j^{\{\cdot\}} \in D_j} \min_{Y_j^m \in \Omega_j^{m,hz}(x^*, \sigma^*, P_j^{\{\cdot\}})} a^T Y_j^m \\ & \text{s.t. } AY_j^m \leq B, CY_j^m \leq f(P_j^{\{\cdot\}}), \\ & E\sigma^* \leq h, IP_j^{\{\cdot\}} \leq J, \end{aligned} \quad (29)$$

where σ^* is a constant obtained after fixing σ .

By utilizing KKT conditions [38], the fixed problem σ is consolidated into a single-level model:

$$\begin{aligned} & \max_{P_j^{\{\cdot\}}, Y_j^m, \lambda} a^T Y_j^m \\ & \text{s.t. } AY_j^m \leq B, CY_j^m \leq f(P_j^{\{\cdot\}}), IP_j^{\{\cdot\}} \leq J, \\ & \lambda_1^T A + a^T = 0, \lambda_2^T C + f'(P_j^{\{\cdot\}}) + a^T = 0, \lambda_3^T I = 0, \\ & \lambda_1^T [AY_j^m - B] = 0, \lambda_2^T [CY_j^m - f(P_j^{\{\cdot\}})] = 0, \\ & \lambda_3^T [IP_j^{\{\cdot\}} - J] = 0, \lambda_1 \geq 0, \lambda_2 \geq 0, \lambda_3 \geq 0 \end{aligned} \quad (30)$$

Note that the complementary slackness constraints of Equation (30) can be linearized using the BIG-M method [39]:

$$\begin{cases} \lambda_1^T \leq M(1 - \vartheta) \\ AY_j^m - B \geq -M\vartheta \end{cases} \quad (31)$$

where M is a large positive number and ϑ is a binary variable.

Then, the optimal solution $P_j^{\{\cdot\}*}$ and the objective function value U^1 are obtained by solving Equation (30).

(b) $P_j^{\{\cdot\}}$ Fixed problem

$$\begin{aligned} & \max_{\sigma \in \Omega_\sigma} \min_{Y_j^m \in \Omega_j^{m,hz}(x^*, \sigma, P_j^{\{\cdot\}*})} a^T Y_j^m \\ & \text{s.t. } AY_j^m \leq B, CY_j^m \leq f(P_j^{\{\cdot\}*}), E\sigma \leq h \end{aligned} \quad (32)$$

Although the objective function includes nonlinear terms composed of σ and Y_j^m (as in Equations (8) and (A1)), the fixed problem $P_j^{\{\cdot\}}$ can be decomposed into two independent steps without the need for strong duality/KKT transformations like those used in fixed problem σ , because there are no direct coupling constraints between σ and Y_j^m . Therefore, the fixed problem $P_j^{\{\cdot\}}$ can be decoupled into the following $S + 1$ linear programming models:

First, the S linear programming models are solved:

$$\begin{aligned} y_s^* &= \min_{Y_j^m \in \Omega_j^{m,hz}(x^*, \sigma_s, P_j^{\{\cdot\}*})} a^T Y_j^m, s = 1, \dots, S \\ & \text{s.t. } AY_j^m \leq B, CY_j^m \leq f(P_j^{\{\cdot\}*}) \end{aligned} \quad (33)$$

where y_s^* is the optimal value for each s . Then, y_s^* is substituted into the following model to obtain the optimal value σ_s and the objective function value U^2 .

$$\max_{\sigma \in \Omega_\sigma} y_s^* \quad (34)$$

Convergence can be achieved when the objective function values of the two fixed problems satisfy a small error ζ_{RO} :

$$|U^1 - U^2| \leq \zeta \quad (35)$$

In conclusion, the solution process diagram of the proposed double-layer, four-stage stochastic-robust optimization model is shown in Appendix D Figure A1.

5. Case Study Simulation

5.1. Case Description

The double-layer model is tested with one GDD and three MEASs as subjects. The MEAS model is derived from a comprehensive energy service demonstration project in Dongguan, which currently has 6 PVs, 6 energy storage units, 2 charging stations (20 charging piles), 3 flexible loads, and 2 MEASs formed by any combination of the above elements, along with one intelligent distribution room. It also has management capabilities for energy routers and combined cooling, heating, and power units, achieving full coverage of the main elements on the demand side. By setting different renewable energy output scenarios, we can expand this project into more MEASs. In this paper, we expand this project into 3 MEASs of equal size, with MEAS1 adding WT, MEAS2 replacing PV with WT, and MEAS3 remaining unchanged. Their parameters are listed in Appendix D, Table A1. The grid electricity price and the grid tariff are listed in Appendix D, Figure A2. The load curve of MEASs is shown in Figure 3.




Figure 3. Load curve of MEAS.

Using the Monte Carlo simulation method, 365 WT scenes are randomly generated. Considering the trade-off between computational efficiency and accuracy, scene reduction techniques are employed to obtain 10 representative initial scenes, as detailed in Appendix D, Figure A3.

The underlying model utilizes MATLAB 2017 (Natick, Massachusetts, USA) calling the Cplex solver, solving on a personal computer with a 3.7GHz 6-core CPU. The convergence accuracy of AIV is set to 0.01. The original residuals of P1 and P2 are both 0.1, with maximum iteration counts of 50 and 100, respectively, and a penalty factor of 0.01. The uncertainty margins for WT and PV are set to 24 and 12, respectively. The scheduling interval is 1 h, with a maximum scheduling period of 24 h. With the initial settings of α_1 and α_∞ as 0.9, according to Equation (9), we can determine that θ_1 and θ_∞ are 0.073 and 0.0073, respectively.

5.2. The Impact of Uncertainty in Scenario Probability

Using WT analysis, the uncertainty in the spatial parameters of scenario probability includes confidence levels α_1 and α_∞ for the 1-norm and ∞ -norm conditions, which jointly affect the permissible deviation values θ_1 and θ_∞ of scenario probability, thus influencing the scheduling of the MEASs and the purchase and sale electricity prices of the GDD.

5.2.1. Analysis of the Impact of Confidence Levels on MEAS Scheduling Situation

Setting α_1 and α_∞ to 0.8, 0.9, and 0.98, according to the calculation in Equation (9), the allowable deviation values θ_1 and θ_∞ for the probabilities of actual scenarios under the 1-norm condition and ∞ -norm condition are shown in Table 1. It can be observed that as the confidence level increases, the probabilities of θ_1 and θ_∞ increase from 0.063 and 0.0063 to 0.094 and 0.0094, respectively, indicating a growing tolerance for deviations from the actual scenario probabilities. Combining this with the decrease in P_j^w from 19.47 MW to 19.37 MW, it is evident that as the confidence level increases, the output of WT becomes increasingly conservative. The root cause is as follows: it can be inferred that as the confidence level increases, the allowable deviation of scenario probabilities also increases, leading to a more adverse and extreme scenario probability distribution for the WTs. Specifically, scenarios with high outputs receive lower probability values, while scenarios with low outputs receive even lower probability values, resulting in lower WT outputs and greater scheduling conservatism for Monte Carlo simulation. Therefore, considering the uncertainty of scenario probability distributions can provide a wider range of scheduling options for the Monte Carlo simulation, which aligns with the scheduling requirements of real-world engineering.

Table 1. Allowable deviation values for actual scenario probabilities.

Variable	θ_1	θ_∞	P_j^w
Fixed scenario probability	-	-	19.47
$\alpha_1 = \alpha_\infty = 0.8$	0.063	0.0063	19.42
$\alpha_1 = \alpha_\infty = 0.9$	0.073	0.0073	19.4
$\alpha_1 = \alpha_\infty = 0.98$	0.094	0.0094	19.37

5.2.2. Analysis of the Impact of Confidence Level on Purchase and Sale Electricity

Figure 4 compares the effects on purchase and sale electricity prices of deterministic WT scenarios with a probability of 0.1 and uncertain WT scenarios with confidence levels of 0.8, 0.9, and 0.98 respectively. Positive values represent sale electricity prices, while negative values indicate purchase electricity prices. In pursuit of its own interests, the GDD tends to offer higher purchase prices and lower sale prices to MEASs. Comparing the purchase and sale electricity prices of each MEAS, it can be observed that as the confidence level increases, the GDD tends to set higher purchase prices and lower sale prices. However,

as the confidence level increases towards saturation, the differentiation in pricing becomes smaller, such as the purchase and sale electricity prices at confidence levels of 0.9 and 0.98 showing no significant difference. This is because, as the confidence level increases, more adverse WT output scenarios occur, leading to a more conservative dispatch strategy by the MEASs. With the dual drive of maximizing its own interests and increasing MEAS conservatism, the GDD therefore raises purchase prices and lowers sale prices.




Figure 4. Comparison of electricity purchase and sale prices at different confidence levels.

Figure 5 presents a comparison of the purchased and sold electricity volumes at different confidence levels. Positive values indicate the electricity sold by the MEAS to the GDD, while negative values indicate the electricity purchased by the MEAS from the GDD. With Table 2, it can be observed that compared to uncertain scenarios, in deterministic scenarios, the MEAS sells more electricity to the GDD, at 7.37 MW, and buys more electricity from the GDD, at 16.85 MW. Moreover, as the confidence level increases, the amount of electricity bought and sold by the MEAS to the GDD decreases, while the difference between the bought and sold amounts increases. This is attributed to the following: (1) the GDD raising the purchase price and lowering the selling price, driving a continuous reduction in the purchased and sold electricity volumes; (2) the uncertainty in scenarios increasing the uncertainty that the MEAS needs to consider regarding WT, leading to the MEAS needing to buy more electricity and sell less electricity to address the worst-case scenario probability distribution, hence the continuous increase in the buy–sell difference. However, as the confidence level saturates, the differences in purchased and sold electricity volumes at different confidence levels become smaller.




Figure 5. Electricity purchased and sold at different confidence levels.

Table 2. Total electricity purchases and sales at different confidence levels.

Scenario	Electricity Sales (MW)	Electricity Purchased (MW)	Purchase–Sale Gap (MW)
Fixed scenario probability	7.37	16.85	9.48
$\alpha_1 = \alpha_\infty = 0.8$	6.83	16.42	9.59
$\alpha_1 = \alpha_\infty = 0.9$	6.77	16.41	9.64
$\alpha_1 = \alpha_\infty = 0.98$	6.70	16.36	9.66

5.3. Dispatch Results Analysis

Table 3 provides a detailed breakdown of the dispatch results at different confidence levels, including various costs for the MEAS, costs and revenues for the GDD, and the total cost for the GDD–MEAS, where negative values indicate revenue. It can be observed that with increasing confidence levels, the MEAS’s revenue from selling electricity decreases, while the cost of purchasing electricity increases, as a result of the dual driving forces of purchase and selling prices and transaction volumes. Additionally, the operational costs of MEAS’s energy storage also increase continuously, indicating that the MEAS has increased the scheduling intensity of energy storage under continuously adverse WT scenarios and outputs. However, the operational costs of the MEAS decrease continuously, indicating that the number of transitions between the trading status between the GDD–MEAS and the charging and discharging states of energy storage is decreasing.

Table 3. Detailed dispatch cost statistics.

Confidence Level	Cost Item/JPY	MEAS1	MEAS2	MEAS3	Total Cost of Each of the MEAS/JPY	GDD Costs/JPY	GDD's Net Gain/JPY
Fixed scenario probability	O&M costs	71.36	61.72	73.29	206.36	-	
	Cooperation costs	−395.98	−313.26	−709.24	0.00	-	
	Purchased–sold power costs	−107.49	−1040.21	11,321.17	10,173.47	−10,173.47	215.90
	GDD–electric grid turnover	-	-	-	-	9957.57	
0.80	O&M costs	67.50	69.43	73.29	210.22	-	
	Cooperation costs	−393.30	−323.31	−716.61	0.00	-	
	Purchased–sold power costs	−83.78	−1034.43	11,396.35	10,278.15	−10,278.15	243.43
	GDD–electric grid turnover	-	-	-	-	10,034.72	
0.90	O&M costs	63.65	69.43	69.43	202.51	-	
	Cooperation costs	−405.66	−319.11	−724.77	1859.45	-	
	Purchased–sold power costs	−48.19	−1004.34	11,728.08	10,675.55	−10,675.55	253.18
	GDD–electric grid turnover	-	-	-	-	10,422.37	
0.98	O&M costs	65.57	61.72	69.43	196.72	-	
	Cooperation costs	−404.22	−322.88	−727.11	0.00	-	
	Purchased–sold power costs	−55.95	−1042.24	11,883.36	10,785.17	−10,785.17	260.58
	GDD–electric grid turnover	-	-	-	-	10,524.59	

Comparing the various cost items of the GDD at different confidence levels, the cooperation cost is the product of the cooperation volume (Figure A4) and the cooperation price (Figure A5). From the perspective of the GDD, the amount of money exchanged in the MEAS–GDD transactions represents the revenue for the GDD, while the amount of money exchanged in the GDD–grid transactions represents the cost for the GDD. It can be observed that with increasing confidence levels, both the costs and revenues of the GDD increase continuously, indicating that the amount of electricity traded between the GDD and the grid is continuously increasing. Additionally, combining with Table 3, it can be inferred that the sum of the GDD's costs and revenues continuously increases, indicating that the growth rate of the GDD's revenue is higher than its cost growth rate. This further suggests that the GDD has set higher purchase prices and lower selling prices to expand its revenue.

5.4. Model and Algorithm Comparative Analysis

Table 4 compares the effects of four models on the cost and solving time of the GDD–MEAS, namely the stochastic optimization model (with deterministic scenario probabilities, ignoring output uncertainty), the three-layer stochastic model considering scenario probability uncertainty (Model 1), the three-layer robust model considering output uncertainty (Model 2), and the three-layer stochastic robust model considering both scenario probability

and output uncertainty (Model 3). Among these models, the cost of stochastic optimization is JPY 11,628.18, demonstrating good economic efficiency. However, the stochastic optimization algorithm requires precise probability distribution functions, and many scenarios lead to long solving times of 64.91 s, limiting its applicability. Compared to Model 3, the cost of this model increases by JPY 856.15. This is mainly because the stochastic robust model sacrifices some economic efficiency to achieve conservatism by overcoming scenario probability and output uncertainty.

Table 4. Comparison of different uncertainty treatments.

Uncertainty Optimization	Solution Duration/s	Costs/JPY	Iterations/k	Iterations/r
stochastic optimization	64.91	11,628.18	23	12
Model 1	42.86	12,232.79	22	3
Model 2	43.62	13,038.99	22	3
Model 3	53.85	12,484.33	22	5

Meanwhile, Model 3 balances economic efficiency and conservatism compared to Models 1 and 2. For instance, Model 3 exhibits better economic efficiency than Model 2. This is because the inclusion of scenario probability uncertainty in Model 3 directly influences the GDD, which formulates purchase and sale electricity prices and quantities under the worst-case scenario. Under dual stimuli, the GDD's revenue growth rate exceeds its cost growth rate, resulting in a more economical total cost for the GDD–MEAS. However, Model 3 is more conservative than Model 1, as the “output uncertainty” in Model 3 does not directly influence the GDD but indirectly affects the impact of WT output uncertainty through the electricity trading volume between the GDD and MEAS. As a result, the GDD's revenue growth rate cannot cover its cost growth rate, resulting in a larger total cost for the GDD–MEAS, reflecting the conservatism of this approach.

However, Model 3 has a longer solving time, but it is still suitable for solving practical engineering problems. The difference in iteration times among models mainly lies in the solving of stochastic optimization, with the sub-problem iteration times of stochastic optimization being the highest at 12 times, while the iteration times of each robust model are relatively lower. Ultimately, this is because the stochastic optimization algorithm needs to select the economically optimal scenarios from many deterministic scenarios, while robust models only need to optimize in the uncertain space.

6. Conclusions

This paper establishes a two-stage, three-layer stochastic–robust optimization model for the MEAS–GDD relationship considering the probabilities of WT and PV scenarios and output uncertainty. A stochastic pricing model for the GDD considering the uncertainties of WT and PV scenario probabilities is developed, along with a three-layer stochastic–robust model for the MEASs considering the probabilities of WT and PV scenarios and output uncertainty. Additionally, an AIV–KKT algorithm is proposed based on KKT to solve the three-layer MEAS stochastic–robust model. The Simulation results indicate the following:

The confidence level and historical data volume both affect the economic efficiency and conservatism of the optimization results. A higher confidence level leads to higher conservatism and poorer economic efficiency of the model. The confidence level affects the trading situation of the GDD–MEAS. With a higher confidence level, the MEAS purchases more electricity and sells less. Both the GDD's revenue and MEAS's costs increase. Therefore, in practical engineering, the MEAS should carefully select confidence level parameters to ensure both the MEAS and GDD's economic efficiency while meeting the conservatism requirements of their actual needs. Compared to traditional stochastic optimization and three-layer robust models, the proposed two-stage, three-layer stochastic–robust model

avoids overly conservative scenarios while also considering economic feasibility to a certain extent.

Author Contributions: Conceptualization, G.W. and X.L.; methodology, G.W. and X.L.; software, J.W.; validation, R.Z.; formal analysis, J.W.; investigation, G.W. and G.B.; resources, R.Z.; data curation, G.W., X.L. and R.Z.; writing—original draft, G.W. and J.W.; writing—review and editing, J.W. and G.B.; supervision, G.B.; project administration, G.B.; funding acquisition, G.W. and X.L. All authors have read and agreed to the published version of the manuscript.

Funding: This work was supported in part by the Science and Technology Project of State Grid Gansu Electric Power Company Electric Power Science Research Institute under Grant (No. SG-GSKY00WYJS2310221).

Data Availability Statement: The data presented in this study are available on request from the corresponding author. (The data are not publicly available due to privacy or ethical restrictions.)

Conflicts of Interest: Authors Guodong Wu, Xiaohu Li were employed by Grid Gansu Electric Power Company, Ruixiao Zhang was employed by Electric Power Science Research Institute of State Grid Gansu Electric Power Company. The remaining authors declare that the research was conducted in the absence of any commercial or financial relationships that could be construed as a potential conflict of interest.

Appendix A

$$\begin{cases} S_{j,1,s}^e = S_j^{e,ini}, S_{j,T,s}^e = S_j^{e,exp} \\ S_{j,t,s}^e = S_{j,t-1,s}^e + (\eta_e^{esc} p_{j,t,s}^{esc} - p_{j,t,s}^{esdc} / \eta_e^{esdc}) \\ 0 \leq p_{j,t,s}^{esc} \leq p_{j,max}^{esc} u_{j,t,s}^{esc}, 0 \leq p_{j,t,s}^{esdc} \leq p_{j,max}^{esdc} u_{j,t,s}^{esdc} \\ u_{j,t,s}^{esc} + u_{j,t,s}^{esdc} \leq 1, S_{j,min}^e \leq S_{j,t,s}^e \leq S_{j,max}^e \end{cases} \quad (A1)$$

$$\begin{cases} 0 \leq \alpha_e^{chp} g_{j,t,s}^{chp} \leq P_{j,max}^{chp} \\ 0 \leq \alpha_h^{chp} g_{j,t,s}^{chp} \leq H_{j,max}^{chp} \end{cases} \quad (A2)$$

$$0 \leq \alpha_h^{gb} g_{j,t,s}^{gb} \leq h_{j,max}^{gb} \quad (A3)$$

$$0 \leq \alpha_c^{ec} p_{j,t,s}^{ec} \leq C_{j,max}^{ec} \quad (A4)$$

$$0 \leq \alpha_c^{ac} h_{j,t,s}^{ac} \leq C_{j,max}^{ac} \quad (A5)$$

$$\begin{cases} S_{j,1,s}^h = S_j^{h,ini}, S_{j,T,s}^h = S_j^{h,exp} \\ S_{j,t,s}^h = S_{j,t-1,s}^h + (\eta_h^{hsc} e_{j,t,s}^{hsc} - e_{j,t,s}^{hsc} / \eta_h^{hsc}) \\ 0 \leq h_{j,t,s}^{hsc} \leq h_{j,max}^{hsc} u_{j,t,s}^{hsc}, 0 \leq e_{j,t,s}^{hsc} \leq h_{j,max}^{hsc} u_{j,t,s}^{hsc} \\ u_{j,t,s}^{hsc} + u_{j,t,s}^{hsc} \leq 1, S_{j,min}^h \leq S_{j,t,s}^h \leq S_{j,max}^h \end{cases} \quad (A6)$$

$$0 \leq g_{j,t}^{buy} \leq g_{j,max}^{buy} \quad (A7)$$

In the equation, $S_{j,t,s}^e$ represents the stored electric charge of ES for the j -th MEAS at time t under scenario s ; η_e^{esc} and η_e^{esdc} are the charging and discharging coefficients for the ES; $S_{j,min}^e$ and $S_{j,max}^e$ represent the state of charge constraints for the ES of the j -th MEAS; $S_{j,1,s}^e$ and $S_{j,T,s}^e$ denote the initial and final state of charge for the ES of the j -th MEAS; $p_{j,max}^{esc}$ and $p_{j,max}^{esdc}$ represent the charge–discharge power limits of ES for the j -th MEAS; $u_{j,t,s}^{esc}$ and $u_{j,t,s}^{esdc}$ respectively represent the state variables of the ES for the j -th MEAS at time t under scenario s , $u_{j,t,s}^{esc} = 1$ indicates that the ES is charging, while $u_{j,t,s}^{esdc} = 1$ indicates that

the ES is discharging; and $S_j^{e,ini}$ and $S_j^{e,exp}$ represent the initial and final state of charge limits for the j -th ES unit of the MEAS. α_e^{chp} represents the electric efficiency of the CHP system; α_h^{chp} represents the thermal efficiency; and $P_{j,max}^{chp}$ and $H_{j,max}^{chp}$ represent the electric and thermal power constraints of the j -th MEAS. α_h^{gb} represents the GB thermal efficiency; $h_{j,max}^{gb}$ represents the thermal power limit of the j -th MEAS. α_c^{ec} represents the EC cooling efficiency; $C_{j,max}^{ec}$ represents the cooling power limit of the j -th MEAS. α_c^{ac} represents the AC cooling efficiency; $C_{j,max}^{ac}$ represents the AC cooling power limit of the j -th MEAS. $S_{j,t,s}^h$ represents the state of charge of the HS of the j -th MEAS at time t under scenario s ; η_h^{hsc} and η_h^{hscd} represent the charging and discharging coefficients of the HS. $S_{j,min}^h$ and $S_{j,max}^h$ represent the charge limits for the j -th MEAS's HS; $S_{j,1,s}^h$ and $S_{j,T,s}^h$ represent the initial and final charge levels for the j -th MEAS's HS; $h_{j,max}^{hsc}$ and $h_{j,max}^{hscd}$ represent the limits on charging and discharging power for the j -th MEAS's HS; $u_{j,t,s}^{hsc}$ and $u_{j,t,s}^{hscd}$ represent the HS state variables of the j -th MEAS at time t under scenario s , where $u_{j,t,s}^{hsc} = 1$ indicates that HS is charging and $u_{j,t,s}^{hscd} = 1$ indicates that HS is discharging; and $S_j^{h,ini}$ and $S_j^{h,exp}$ represent the initial and final state-of-charge limits of the j -th MEAS's HS. Here, $g_{j,max}^{buy}$ is the purchased gas power limit of the j -th MEAS.

Appendix B

Equivalence Transformation of Equation (24) into P1 and P2 Problems

According to reference [40], Equation (24) can be equivalently transformed into

$$\begin{cases} U_j^{m,hz} = \max \sum_{j=1}^N (U_j^{m,hz} - U_j^{m,0}) \\ U_j^{m,hz} = \max_{\sigma_s} \max_{P_{j,s,t}^{(\cdot)}} \min_{y_j} (C_j^{en} + C_j^m + C_{ji}^{hz}) \\ \text{s.t. } U_j^{m,hz} \geq U_j^{m,0}, \Omega_j^{m,hz} \end{cases} \quad (A8)$$

Since the interaction benefits $C_{ji}^{hz} = \sum_{i=1, j \neq i}^N \sum_{t=1}^T \sigma_s \beta_{ji,t}^{hz} P_{ji,t,s}^{hz}$ between each MEAS can cancel each other out when accumulated, eliminating the variable $\beta_{ji,t}^{hz}$ and its constraints, we obtain

$$\begin{cases} U_j^{m,hz} = \max \sum_{j=1}^N \left[\max_{\sigma_s} \max_{P_{j,s,t}^{(\cdot)}} \min_{\beta_{ji,t}^{hz} \notin y_j} (C_j^{en} + C_j^m) - U_j^{m,0} \right] \\ \text{s.t. } U_j^{m,hz} \geq U_j^{m,0}, \{(7), (20) - (21)\} \notin \Omega_j^{m,hz} \end{cases} \quad (A9)$$

In Equation (A9), $U_j^{m,0}$ represents the optimal cost without cooperation, which can be considered a fixed value, thus eliminating the constraints involving $U_j^{m,0}$. Therefore, solving Equation (A9) is equivalent to solving Equation (A10):

$$\begin{cases} U_j^{m,hz} = \max \sum_{j=1}^N \left[\max_{\sigma_s} \max_{P_{j,s,t}^{(\cdot)}} \min_{\beta_{ji,t}^{hz} \notin y_j} (C_j^{en} + C_j^m) \right] \\ \text{s.t. } \{(7), (20) - (21)\} \notin \Omega_j^{m,hz} \end{cases} \quad (A10)$$

Equation (A10) represents the subproblem (P1) aimed at maximizing cooperative benefits, which consists of j producer–consumer RO models. Distributed solving using ADMM can be employed for this problem, with each producer–consumer RO model solved using the methods described in Section 3.3. Subsequently, solving P1 yields values C_j^{en*} ,

C_j^{m*} , and $P_{ji,t,s}^{hz*}$, which are substituted into Equation (A8). The constraints involving the solution to P1 are automatically eliminated, resulting in

$$\begin{cases} U_j^{m,hz} = \max \prod_{j=1}^N \left(W_j^{m,hz*} + C_{ji}^{hz*} - U_j^{m,0} \right) \\ C_{ji}^{hz*} = \sum_{i=1, j \neq i}^N \sum_{t=1}^T \sigma_s \beta_{ji,t}^{hz} P_{ji,t,s}^{hz*} \\ \text{s.t. } W_j^{m,hz*} + C_{ji}^{hz*} \geq U_j^{m,0} \\ (7), (20) - (21) \end{cases} \quad (\text{A11})$$

In the equation, $W_j^{m,hz*} = C_j^{en*} + C_j^{m*}$ represents the cost under cooperation, excluding P2P revenue.

Equation (A11) can be further equivalently transformed into the following equation.

$$\begin{cases} U_{p2} = \min - \sum_{j=1}^N \ln \left(W_j^{m,hz*} + C_{ji}^{hz*} - U_j^{m,0} \right) \\ C_{ji}^{hz*} = \sum_{i=1, j \neq i}^N \sum_{t=1}^T \sigma_s \beta_{ji,t}^{hz} P_{ji,t,s}^{hz*} \\ \text{s.t. } W_j^{m,hz*} + C_{ji}^{hz*} \geq U_j^{m,0} \\ (7), (20) - (21) \end{cases} \quad (\text{A12})$$

Equation (A12) represents the sub-problem P2 of cooperative revenue distribution, which can be decomposed into j sub-problems and solved using ADMM in a distributed manner. After substituting the results of solving sub-problem P1, the cooperative price $\beta_{ji,t,s}^{hz}$ corresponding to the producer–consumer relationship can be obtained. Therefore, Equation (24) can be decomposed into two sub-problems, namely maximizing cooperative benefits P1 and cooperative revenue distribution P2, and solved successively, thus concluding the proof.

Appendix C

The process of solving P1 using ADMM can be iterated based on Equation (A13).

$$\begin{cases} P_{j,s,r+1}^{hz} = \max_{\sigma_s} \max_{P_{j,s,t}^{hz}} \min_{\beta_{ji,t}^{hz} \notin y_j} \left[\left(C_j^{en} + C_j^m \right) + \lambda_{j,s,r}^{p1} \left(P_{j,s,r+1}^{hz} - \sigma_{j,s,r}^{p1} \right)^T + \sum_{t=1}^T \left(\rho \left\| P_{j,s,r+1}^{hz} - \sigma_{j,s,r}^{p1} \right\|_2^2 \right) \right] \\ \sigma_{j,s,r}^{p1} = \frac{1}{N-1} \sum_{j=1}^{N-1} \left(P_{j,s,r+1}^{hz} \right) \\ \lambda_{j,s,r+1}^{p1} = \lambda_{j,s,r}^{p1} + \rho \left(P_{j,s,r+1}^{hz} - \sigma_{j,s,r+1}^{p1} \right) \\ \max \sum_{t=1}^T \left\| P_{j,s,r+1}^{hz} - \sigma_{j,s,r+1}^{p1} \right\|_2^2 \leq \epsilon_{pri}, \max \sum_{t=1}^T \left\| \sigma_{j,s,r+1}^{p1} - \sigma_{j,s,r}^{p1} \right\|_2^2 \leq \epsilon_{dul} \end{cases} \quad (\text{A13})$$

In the equation, $\lambda_{j,s,r}^{p1} = \left[\lambda_{j1,s,k}^{p1}, \lambda_{j2,s,k}^{p1}, \dots, \lambda_{ji,s,k}^{p1}, \dots, \lambda_{jN,s,k}^{p1} \right]$ represents the dual vector for the j -th iteration of the k -th step of the MEAS, with $\lambda_{ji,s,r}^{p1} = \left[\lambda_{ji,1,s,r}^{p1}, \lambda_{ji,2,s,r}^{p1}, \dots, \lambda_{ji,T,s,r}^{p1} \right]^T$; $P_{j,s,r}^{hz} = \left[P_{j1,s,r}^{hz}, P_{j2,s,r}^{hz}, \dots, P_{ji,s,r}^{hz}, \dots, P_{jN,s,r}^{hz} \right]$ is the coupling variable vector for the j -th MEAS iteration at the k -th iteration, $P_{ji,s,r}^{hz} = \left[P_{ji,1,s,r}^{hz}, P_{ji,2,s,r}^{hz}, \dots, P_{ji,T,s,r}^{hz} \right]^T$; $\sigma_{j,s,r}^{p1} = \left[\sigma_{j1,s,r}^{p1}, \sigma_{j2,s,r}^{p1}, \dots, \sigma_{ji,s,r}^{p1}, \dots, \sigma_{jN,s,r}^{p1} \right]$ is the consensus variable vector for the j -th MEAS at the k -th iteration, where $\sigma_{ji,s,r}^{p1} = \left[\sigma_{ji,1,s,r}^{p1}, \sigma_{ji,2,s,r}^{p1}, \dots, \sigma_{ji,T,s,r}^{p1} \right]^T$; and ρ represents the penalty coefficient.

The process of solving P2 with ADMM involves iterative loops based on Equation (A14):

$$\begin{cases} \beta_{j,s,r+1}^{\text{hz}} = \min_{\beta_{ji,t}^{\text{hz}}} \left[-\ln \left(\left(W_j^{\text{m,hz*}} + C_{ji}^{\text{hz*}} - U_j^{\text{m},0} \right) + \lambda_{j,s,r}^{\text{p2}} \left(\beta_{j,s,r+1}^{\text{hz}} - \sigma_{j,s,r}^{\text{p2}} \right)^T + \sum_{t=1}^T \rho \left\| \beta_{j,s,r+1}^{\text{hz}} - \sigma_{j,s,r}^{\text{p2}} \right\|_2^2 \right) \right] \\ \sigma_{j,s,r}^{\text{p2}} = \frac{1}{N-1} \sum_{j=1}^{N-1} \left(\beta_{j,s,r+1}^{\text{hz}} \right) \\ \lambda_{j,s,r+1}^{\text{p2}} = \lambda_{j,s,r}^{\text{p2}} + \rho \left(\beta_{j,s,r+1}^{\text{hz}} - \sigma_{j,s,r}^{\text{p2}} \right) \\ \max \sum_{t=1}^T \left\| \beta_{j,s,r+1}^{\text{hz}} - \sigma_{j,s,r}^{\text{p2}} \right\|_2^2 \leq \varepsilon_{\text{pri}}^{\text{p2}}, \max \sum_{t=1}^T \left\| \sigma_{j,s,r+1}^{\text{p2}} - \sigma_{j,s,r}^{\text{p2}} \right\|_2^2 \leq \varepsilon_{\text{dul}}^{\text{p2}} \end{cases} \quad (\text{A14})$$

In the equation, $\lambda_{j,s,r}^{\text{p2}} = [\lambda_{j1,s,r}^{\text{p2}}, \lambda_{j2,s,r}^{\text{p2}}, \dots, \lambda_{ji,s,r}^{\text{p2}}, \dots, \lambda_{jN,s,r}^{\text{p2}}]$ represents the dual vector for the k -th iteration of consumer j , where $\lambda_{ji,s,r}^{\text{p2}} = [\lambda_{ji,1,s,r}^{\text{p2}}, \lambda_{ji,2,s,r}^{\text{p2}}, \dots, \lambda_{ji,T,s,r}^{\text{p2}}]^T$; $\beta_{j,s,r}^{\text{hz}} = [\beta_{j1,s,r}^{\text{hz}}, \beta_{j2,s,r}^{\text{hz}}, \dots, \beta_{ji,s,r}^{\text{hz}}, \dots, \beta_{jN,s,r}^{\text{hz}}]$ is the coupling variable vector for consumer-producer j in the k -th iteration, $\beta_{ji,s,r}^{\text{hz}} = [\beta_{ji,1,s,r}^{\text{hz}}, \beta_{ji,2,s,r}^{\text{hz}}, \dots, \beta_{ji,T,s,r}^{\text{hz}}]^T$; $\sigma_{j,s,r}^{\text{p2}} = [\sigma_{j1,s,r}^{\text{p2}}, \sigma_{j2,s,r}^{\text{p2}}, \dots, \sigma_{ji,s,r}^{\text{p2}}, \dots, \sigma_{jN,s,r}^{\text{p2}}]$ is the consensus variable vector for consumer-producer j in the k -th iteration, where $\sigma_{ji,s,r}^{\text{p2}} = [\sigma_{ji,1,s,r}^{\text{p2}}, \sigma_{ji,2,s,r}^{\text{p2}}, \dots, \sigma_{ji,T,s,r}^{\text{p2}}]^T$; and ρ represents the penalty coefficient.

Appendix D






Figure A1. Solution procedure of the bilayer robust model.

Table A1. System Parameters.

Parameters	Parameter Values	Parameters	Parameter Values
$e_{j,\max}^{\text{buy}}, \delta_{j,\max}^{\text{buy}}$	2500,4000	$\alpha_e^{\text{chp}}, \alpha_h^{\text{chp}}$	0.33,0.47
$e_{j,\max}^{\text{chp}}, h_{j,\max}^{\text{chp}}$	1000,1400	α_h^{gb}	0.9
$h_{j,\max}^{\text{gb}}$	1000	α_c^{ec}	3.5
$c_{n,\max}^{\text{ec}}, c_{n,\max}^{\text{ac}}$	1750,1000	α_c^{ac}	1.2
$e_{n,\max}^{\text{esc}}, e_{n,\max}^{\text{esdc}}$	250	$\lambda_e, \alpha_e^{\text{es}}$	0.2,0.98
$S_{n,\min}^e, S_{n,\max}^e$	100,900	$\eta_e^{\text{esc}}, \eta_e^{\text{esdc}}$	0.96
$h_{n,\max}^{\text{hsc}}, h_{n,\max}^{\text{hsdc}}$	200	$\lambda_h, \alpha_h^{\text{hs}}$	0.6,0.96
$S_{n,\min}^h, S_{n,\max}^h$	100,800	$\eta_h^{\text{hsc}}, \eta_h^{\text{hsdc}}$	0.95
$p_t^{\text{g,buy}}, a_e^{\text{buy}}$	0.31,0.04	$a_h^{\text{chp}}, a_e^{\text{chp}}$	0.013,0.02
$b_e^{\text{ec}}, b_h^{\text{ac}}$	0.01,0.016	$b_g^{\text{chp}}, b_g^{\text{gb}}$	0.025,0.012
$b_e^{\text{pv}}, b_e^{\text{wt}}$	0.024,0.02	$b_e^{\text{es}}, b_h^{\text{hs}}$	0.002
$e_{n,\min}^{\text{ex}}, e_{n,\max}^{\text{ex}}$	800,800	$a_h^{\text{gb}}, b_{\text{buy}}$	0.013

**Figure A2.** Feed-in tariffs and grid tariffs.**Figure A3.** Ten typical scenarios for WT.




Figure A4. Cooperation volume of MEASs.




Figure A5. Cooperation price of MEASs.

References

- Canale, L.; Di Fazio, A.R.; Russo, M.; Frattolillo, A.; Dell'Isola, M. An Overview on Functional Integration of Hybrid Renewable Energy Systems in Multi-Energy Buildings. *Energies* **2021**, *14*, 1078. [CrossRef]
- Li, H.; Liu, H.; Ma, J.; Wang, J. Robust stochastic optimal dispatching of integrated electricity-gas-heat system considering generation-network-load uncertainties. *Int. J. Electr. Power Energy Syst.* **2024**, *157*, 109868. [CrossRef]
- Liu, X.; Yue, Y.; Huang, X.; Xu, W.; Lu, X. A Review of Wind Energy Output Simulation for New Power System Planning. *Front. Energy Res.* **2022**, *10*, 942450. [CrossRef]
- Bagherzadeh, L.; Kamwa, I.; Alharthi, Y.Z. Hybrid strategy of flexibility regulation and economic energy management in the power system including renewable energy hubs based on coordination of transmission and distribution system operators. *Energy Rep.* **2024**, *12*, 1025–1043. [CrossRef]
- Zhou, X.; Wang, N.; Li, Z.; Zhao, P.; Cong, L. Day-ahead load optimal distribution of thermal power coupled electric energy storage frequency regulation system considering the effect of overtemperature. *E3S Web Conf.* **2023**, *375*, 03005. [CrossRef]
- Ma, L.; Xie, L.; Ye, J.; Bian, Y. Two-stage dispatching strategy for park-level integrated energy systems based on a master-slave-cooperative hybrid game model. *Renew. Energy* **2024**, *232*, 120971. [CrossRef]
- Zhang, M.; Wang, B.; Wei, J. The Robust Optimization of Low-Carbon Economic Dispatching for Regional Integrated Energy Systems Considering Wind and Solar Uncertainty. *Electronics* **2024**, *13*, 3480. [CrossRef]
- Tao, W.; Ai, Q.; Li, X. Research status and prospects of cooperative scheduling and market trading in virtual power plants. *China South. Power Grid Technol.* **2024**, 1–15. Available online: <https://www.cnki.com.cn/Article/CJFDTotal-NFDW20240313004.htm> (accessed on 29 October 2024).
- Wang, S.; Sun, G.; Wu, C.; Hu, G.; Zhou, Y.; Chen, S.; Wei, Z. A two-stage robust optimization model for prolific consumers based on central-decentralized trading mechanisms. *Power Autom. Equip.* **2022**, *42*, 175–182. [CrossRef]

10. Chen, L.; Zhu, Z.; Wang, K.; Guo, B.; Shuai, W. Optimal operation of distribution networks and multi-integrated energy micronetworks based on hybrid game. *Power Grid Technol.* **2023**, *47*, 2229–2243. [\[CrossRef\]](#)
11. Lin, M.; Liu, J.; Tang, Z.; Zeng, P.; Jiang, B.; Ma, G. Multi-agent hybrid game coordination optimization of microgrids considering multi-energy coupled shared energy storage. *Power Syst. Autom.* **2024**, *48*, 132–141.
12. Yang, D.; Wang, Y.; Yang, S.; Jiang, C.; Liu, X. Multi-microgrid and shared Energy storage two-layer energy trading strategy based on hybrid game. *High Volt. Technol.* **2024**, *50*, 1392–1402. [\[CrossRef\]](#)
13. Seok, H.; Kim, S.-P. A Stackelberg-Cournot model to harmonize participants' interests in a smart grid. *Comput. Ind. Eng.* **2024**, *187*, 109772. [\[CrossRef\]](#)
14. Yu, M.; Hong, S.H. A Real-Time Demand-Response Algorithm for Smart Grids: A Stackelberg Game Approach. *IEEE Trans. Smart Grid* **2016**, *7*, 879–888. [\[CrossRef\]](#)
15. Liu, N.; Yu, X.; Wang, C.; Wang, J. Energy Sharing Management for Microgrids With PV Prosumers: A Stackelberg Game Approach. *IEEE Trans. Ind. Inform.* **2017**, *13*, 1088–1098. [\[CrossRef\]](#)
16. Yang, H.; Liu, F.; Yang, H.; Zhang, X.; Liu, L. A two-stage robust configuration optimization model and solution algorithm for new flexibility resources considering uncertainty response characterization. *Front. Energy Res.* **2024**, *12*, 1381857. [\[CrossRef\]](#)
17. Belgana, A.; Rimal, B.P.; Maier, M. Open Energy Market Strategies in Microgrids: A Stackelberg Game Approach Based on a Hybrid Multiobjective Evolutionary Algorithm. *IEEE Trans. Smart Grid* **2014**, *6*, 1243–1252. [\[CrossRef\]](#)
18. Ma, L.; Liu, N.; Zhang, J.; Tushar, W.; Yuen, C. Energy Management for Joint Operation of CHP and PV Prosumers Inside a Grid-Connected Microgrid: A Game Theoretic Approach. *IEEE Trans. Ind. Inform.* **2016**, *12*, 1930–1942. [\[CrossRef\]](#)
19. Shui, J.; Peng, D.; Zeng, H.; Song, Y.; Yu, Z.; Yuan, X.; Shen, C. Optimal scheduling of multiple entities in virtual power plant based on the master-slave game. *Appl. Energy* **2024**, *376*, 124286. [\[CrossRef\]](#)
20. He, C.; Wu, L.; Liu, T.; Shahidehpour, M. Robust Co-Optimization Scheduling of Electricity and Natural Gas Systems via ADMM. *IEEE Trans. Sustain. Energy* **2017**, *8*, 658–670. [\[CrossRef\]](#)
21. Chen, J.; Zhang, W.; Zhang, Y.; Bao, G. Day-Ahead Scheduling of Distribution Level Integrated Electricity and Natural Gas System Based on Fast-ADMM With Restart Algorithm. *IEEE Access* **2018**, *6*, 17557–17569. [\[CrossRef\]](#)
22. Li, J.; Tong, X.; Chen, H.; Pan, P.; Xu, G.; Liu, W. Two-layer optimization Method for low-carbon economic operation of integrated energy systems with multiple types of energy storage. *J. Power Eng.* **2024**, *44*, 498–508. [\[CrossRef\]](#)
23. Zhou, H.; Wu, R.; Ma, Y.; Liu, S. Data-driven Robust scheduling optimization for electric-gas energy systems considering wind power uncertainty. *Power Grid Technol.* **2020**, *44*, 3752–3761. [\[CrossRef\]](#)
24. Wang, J.; Bao, G.; Zhang, H. A double-four-tier stochastic robust optimal scheduling model and its solution. *Power Grid Technol.* **2024**, *48*, 1622–1634. [\[CrossRef\]](#)
25. Yang, C.; Zhu, Y.; Zhou, J.; Zhao, J.; Bu, R.; Feng, G. Dynamic flexibility optimization of integrated energy system based on two-timescale model predictive control. *Energy* **2023**, *276*, 127501. [\[CrossRef\]](#)
26. Li, G.; Li, Q.; Liu, Y.; Liu, H.; Song, W.; Ding, R. A cooperative Stackelberg game based energy management considering price discrimination and risk assessment. *Int. J. Electr. Power Energy Syst.* **2022**, *135*, 107461. [\[CrossRef\]](#)
27. Tang, Y.; Xun, Q.; Liserre, M.; Yang, H. Energy management of electric-hydrogen hybrid energy storage systems in photovoltaic microgrids. *Int. J. Hydrogen Energy* **2024**, *80*, 1–10. [\[CrossRef\]](#)
28. Lei, Y.; Wang, D.; Jia, H.; Li, J.; Chen, J.; Li, J.; Yang, Z. Multi-stage stochastic planning of regional integrated energy system based on scenario tree path optimization under long-term multiple uncertainties. *Appl. Energy* **2021**, *300*, 117224. [\[CrossRef\]](#)
29. Zhou, C.; Jia, H.; Jin, X.; Mu, Y.; Yu, X.; Xu, X.; Li, B.; Sun, W. Two-stage robust optimization for space heating loads of buildings in integrated community energy systems. *Appl. Energy* **2022**, *331*, 120451. [\[CrossRef\]](#)
30. Chen, Y.; Niu, Y.; Qu, C.; Du, M.; Wang, J. Data-driven-based distributionally robust optimization approach for a virtual power plant considering the responsiveness of electric vehicles and Ladder-type carbon trading. *Int. J. Electr. Power Energy Syst.* **2024**, *157*, 109893. [\[CrossRef\]](#)
31. Lai, J.; Xie, Y.; Zeng, H.; Zhou, S.; Luo, Y.; Song, J. A review of uncertain optimal scheduling research and its application to new power systems. *High Volt. Technol.* **2022**, *48*, 3447–3464. [\[CrossRef\]](#)
32. Xiong, C.; Xu, L.; Ma, L.; Hu, P.; Ye, Z.; Sun, J. Research on large-scale clean energy optimal scheduling method based on multi-source data-driven. *Front. Energy Res.* **2024**, *11*, 1230818. [\[CrossRef\]](#)
33. Chao, N.; You, F. Data-driven stochastic robust optimization: General computational framework and algorithm leveraging machine learning for optimization under uncertainty in the big data era. *Comput. Chem. Eng.* **2018**, *111*, 115–133.
34. Wu, L.; Li, Z.; Xu, Y.; Zheng, X. Stochastic-weighted robust optimization based bi-layer operation of a multi-energy home considering practical thermal loads and battery degradation. *IEEE Trans. Sustain. Energy* **2021**, *13*, 668–682.
35. Lyu, X.; Liu, T.; Liu, X.; He, C.; Nan, L.; Zeng, H. Low-carbon robust economic dispatch of park-level integrated energy system considering price-based demand response and vehicle-to-grid. *Energy* **2023**, *263*, 125739. [\[CrossRef\]](#)
36. Wang, Z.; Jia, Y.; Han, X.; Chen, J.; Li, Y.; Zhang, S. Two-layer hybrid game optimization of micro-energy networks considering producer response and uncertainty. *Power Grid Technol.* **2024**, *48*, 2754–2764. [\[CrossRef\]](#)
37. Chen, T.; Cao, Y.; Qing, X.; Zhang, J.; Sun, Y.; Amaratunga, G.A. Multi-energy microgrid robust energy management with a novel decision-making strategy. *Energy* **2022**, *239*, 121840. [\[CrossRef\]](#)
38. Li, P.; Wu, D.; Li, Y.; Liu, H.; Wang, N.; Zhou, X. Optimized scheduling strategy for multi-microgrid integrated energy system based on integrated demand response and master-slave game. *Chin. J. Electr. Eng.* **2024**, *41*, 1307–1321.

39. Zhang, Q.; Xie, Z.; Lu, M.; Ji, S.; Liu, D.; Xiao, Z. Optimization of Hydropower Unit Startup Process Based on the Improved Multi-Objective Particle Swarm Optimization Algorithm. *Energies* **2024**, *17*, 4473. [[CrossRef](#)]
40. Hu, W.; Zhang, Y.; Liu, L.; Zhang, P.; Qin, J.; Nie, B. Study on Multi-Objective Optimization of Construction Project Based on Improved Genetic Algorithm and Particle Swarm Optimization. *Processes* **2024**, *12*, 1737. [[CrossRef](#)]

Disclaimer/Publisher's Note: The statements, opinions and data contained in all publications are solely those of the individual author(s) and contributor(s) and not of MDPI and/or the editor(s). MDPI and/or the editor(s) disclaim responsibility for any injury to people or property resulting from any ideas, methods, instructions or products referred to in the content.

Article

A Convolutional Neural Network–Long Short-Term Memory–Attention Solar Photovoltaic Power Prediction–Correction Model Based on the Division of Twenty-Four Solar Terms

Guodong Wu ^{1,2}, Diangang Hu ², Yongrui Zhang ², Guangqing Bao ^{3,*} and Ting He ⁴

¹ College of Electrical and Information Engineering, Lanzhou University of Technology, Lanzhou 730050, China; liulj_dky@gs.sgcc.com.cn

² Power Dispatch Center of State Grid Gansu Electric Power Company, Lanzhou 730030, China; lvqc@gs.sgcc.com.cn (D.H.); zhangrx_dky@gs.sgcc.com.cn (Y.Z.)

³ School of Electronics and Information Engineering, Southwest Petroleum University, Chengdu 610500, China

⁴ Gansu Natural Energy Research Institute, Lanzhou 730046, China; heting@gneri.com.cn

* Correspondence: baogq@swpu.edu.cn

Abstract: The prevalence of extreme weather events gives rise to a significant degree of prediction bias in the forecasting of photovoltaic (PV) power. In order to enhance the precision of forecasting outcomes, this study examines the interrelationships between China's 24 conventional solar terms and extreme meteorological events. Additionally, it proposes a methodology for estimating the short-term generation of PV power based on the division of solar term time series. Firstly, given that the meteorological data from the same festival is more representative of the climate state at the current prediction moment, the sample data are grouped according to the 24 festival time nodes. Secondly, a convolutional neural network–long short-term memory (CNN–LSTM) PV power prediction model based on an Attention mechanism is proposed. This model extracts temporal change information from nonlinear sample data through LSTM, and a CNN link is added at the front end of LSTM to address the issue of LSTM being unable to obtain the spatial linkage of multiple features. Additionally, an Attention mechanism is incorporated at the back end of the CNN to obtain the feature information of crucial time steps, further reducing the multi-step prediction error. Concurrently, a PV power error prediction model is constructed to rectify the outcomes of the aforementioned prediction model. The examination of the measured data from PV power stations and the comparison and analysis with other prediction models demonstrate that the model presented in this paper can effectively enhance the accuracy of PV power predictions.

Keywords: forecasting; solar PV power; extreme weather; attention mechanism; CNN (convolutional neural network); LSTM (long short-term memory)



Citation: Wu, G.; Hu, D.; Zhang, Y.; Bao, G.; He, T. A Convolutional Neural Network–Long Short-Term Memory–Attention Solar Photovoltaic Power Prediction–Correction Model Based on the Division of Twenty-Four Solar Terms. *Energies* **2024**, *17*, 5549. <https://doi.org/10.3390/en17225549>

Academic Editor: Anastassios M. Stamatielos

Received: 20 September 2024

Revised: 20 October 2024

Accepted: 29 October 2024

Published: 6 November 2024



Copyright: © 2024 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

1. Introduction

Solar photovoltaic (PV) power represents a promising form of clean energy with diverse potential applications, and it has emerged as a prominent area of focus in the field of energy transformation, undergoing rapid development. As evidenced by the annual report released by the International Energy Agency, the global installed capacity of PV power generation exhibited an average annual growth rate of 28% from 2019 to 2023. Notably, the global installed capacity of PV power generation in the previous year surpassed that of hydropower. In most countries, solar energy has become the most cost-effective energy source. Over the next decade, the solar PV industry will continue to experience high growth rates.

In contrast to conventional thermal power generation, the efficacy of PV power generation is inherently constrained by environmental variables such as meteorological fluctua-

tions and seasonal variations. In recent years, global climate change has manifested in a number of ways, including extreme temperatures, persistent high and low temperatures, dust, typhoons, heavy rain, haze, and other meteorological disasters. These phenomena have caused the destruction of PV facilities and resulted in short-term, high-frequency fluctuations in the power grid. These fluctuations have posed significant challenges to the operation, scheduling, planning, and design of the power grid, as well as to disaster prevention and mitigation efforts. For example, in February 2021, a cold weather event swept through Texas in the United States, resulting in a 68% decline in PV power generation [1]. In 2019, typhoons and heavy rains in southern China resulted in operational challenges for some PV power plants. During April and May in 2021, China experienced a widespread occurrence of sand-dust storm in the provinces of Hebei and Inner Mongolia. This resulted in a notable decline in the efficiency of PV power generation, with a reduction of 20% to 60% in output [2]. In light of the inherent unpredictability of natural phenomena, it is imperative to enhance the precision of PV output forecasting in order to guarantee the security and reliability of optimization scheduling and control decisions for PV power systems with high penetration rates.

Although solar PV power prediction solutions have reached a mature stage of development, challenges remain, particularly in the context of transient weather conditions [3]. The primary challenges can be attributed to three fundamental factors: the inherent inaccuracies inherent in numerical weather forecasting (NWP) models, the anomalous nature of operational data, and the suboptimal performance of prediction models. The majority of existing studies concentrate on the input, model, and output aspects. Techniques such as principal component analysis (PCA) and wavelet decomposition effectively extract data features [4–7]; however, they often underperform in extreme weather due to their linear nature, which fails to capture significant nonlinear changes. Hybrid models and machine learning methodologies have demonstrated enhanced prediction accuracy under typical conditions. However, they have been less successful in addressing the challenges posed by extreme weather variability. For example, while combination forecasting methodologies may enhance accuracy, they may not adequately account for sensitive meteorological factors during severe weather, which could result in prediction errors. Moreover, error correction modules and optimization algorithms [8–10], including particle swarm and genetic algorithms, have demonstrated potential in refining model parameters. However, these techniques also exhibit limitations in adapting to rapidly changing conditions. Furthermore, the partitioning of solar PV power prediction into discrete subsystems based on weather types has been demonstrated to enhance accuracy. However, this approach may become ineffectual when key characteristic variables, such as total, direct, and scattered radiation, undergo significant shifts during inclement weather [11]. As PV capacity continues to grow, it is becoming increasingly important to address the implications of transitional weather patterns on grid-connected operations.

Extreme weather events are classified as low-probability occurrences, leading to challenges related to sample scarcity, which have been tackled in various studies. These studies have successfully employed small sample learning approaches by integrating transfer learning methods with interval prediction, thereby addressing the issue of insufficient sample data for power generation predictions in new PV plants. Although a variety of data sampling strategies have been employed to address category imbalance [12], these methods frequently prove ineffective in fully alleviating the impact of sample scarcity on model performance. Generative adversarial networks (GANs), in particular, offer significant advantages in data generation, effectively reducing the cost of power measurement, and have been successfully applied in power system modeling [13]. In [14], a solution for sparse PV power data on days with precipitation is proposed. This solution employs a Wasserstein generative adversarial network (GAN) with gradient penalty to enhance the quality of data collected during such conditions. These methodologies offer promising avenues for addressing the challenges posed by limited sample sizes. Nevertheless, the predominant utilization of small sample techniques in PV power forecasting frequently disregards the

time-varying characteristics of the data, which represents a substantial limitation. Given the significant impact of weather conditions on PV generation, temporal dynamics play a pivotal role in accurate prediction models.

The aforementioned study demonstrates that the current methodology for predicting PV power encounters two significant challenges. Primarily, the model is not tailored to the specific characteristics of PV data. Instead, it employs methodologies from other fields, with inadequate consideration of the nonlinear and nonsmooth attributes inherent to PV series. Secondly, there is a dearth of research on multidimensional and high-precision PV prediction. These approaches rely solely on historical power data, failing to leverage the full spectrum of influencing factors, including meteorological conditions and geographic variables.

In order to address the issues mentioned above, it is necessary to consider the intrinsic correlation between seasonal and climate changes and their impact on PV power generation. This research aims to develop a novel PV power prediction model that integrates convolutional neural networks (CNNs), long short-term memory (LSTM) networks, and Attention mechanisms. This model not only leverages the benefits of small sample learning but also incorporates time-varying characteristics, thereby enhancing prediction accuracy under extreme weather conditions. To address the intrinsic correlation between seasonal and climate changes and their impact on PV generation, this study proposes a methodology based on the time division of China's 24 solar terms [15]. Initially, the relationship between PV prediction results and extreme weather processes is analyzed using operational data from a PV power plant in Guazhou City, western China. This analysis identifies prediction error characteristics and their sensitive meteorological factors. Subsequently, sample data are grouped according to the solar term time nodes, utilizing meteorological data within the same term to represent the prevailing climate state. This approach effectively mitigates the challenges posed by limited meteorological data and reduces the impact of climate change on predictive accuracy. The proposed CNN-LSTM model employs LSTM to extract temporal variation from nonlinear sample data, while a CNN component at the LSTM's input captures multi-feature correlations. An Attention mechanism is integrated at the output stage to enhance the influence of critical time steps and minimize multi-step prediction errors. Additionally, an error correction step is incorporated, constructing a PV power prediction error model based on historical operational and solar term data. This correction aims to refine the final prediction outputs, providing valuable insights for improving PV power forecasting. The methodologies developed in this research can also be adapted for wind power prediction, demonstrating their broader applicability and significance in the renewable energy sector.

2. Correlation Analysis of Sample Characteristics

Spearman's correlation coefficient, a linear correlation index commonly utilized in statistical analysis, ranges from -1 to 1 , with 1 signifying a perfect positive correlation, -1 indicating a perfect negative correlation, and 0 representing no correlation, and the larger the absolute value, the more robust the correlation [16]. The value in question is calculated from Equation (1).

$$\rho_s = 1 - \frac{6 \sum d_i^2}{n(n^2 - 1)} \quad (1)$$

where ρ_s is the correlation coefficient, d_i is the i th difference between the ranks of the data pairs, and n is the total sample size.

In accordance with the disparate prediction timescales, PV power prediction can be classified into the following categories: ultra-short-term prediction, short-term prediction, medium-term prediction, and long-term prediction [17]. For the sake of argument, let us suppose that meteorological factors exert no influence on fluctuations in PV power and that only the direct method is employed to extrapolate power. In the context of ultra-short-term prediction, the aforementioned approach is indeed acceptable. However, when considering the realm of short-, medium-, and long-term prediction, the results exhibit a considerable degree of deviation. Consequently, there is a notable absence of

practical engineering applications in the domains of power system control, dispatching, and planning. It is thus imperative to consider the impact of meteorological variables on PV power generation in a comprehensive manner. In NWP, the selection of appropriate predictor variables is of paramount importance. The incorporation of an excessive number of variables will result in the generation of a model that is overly redundant. In the event that the accuracy of the predictor variables is insufficient, the capacity of the predictor to accurately predict the PV power will be compromised. Accordingly, this study employs the Spearman correlation coefficient to identify the initial four meteorological variables with the highest correlation with PV power, which are then utilized as the meteorological parameters of the PV prediction model.

The sample data for correlation analysis were selected from the data of NWP weather factors and corresponding PV power of a PV power station in Guazhou City, Northwest China, in 2022. The data were employed to calculate the Spearman correlation coefficients between the sequences of each weather factor and the sequences of PV power, with the objective of obtaining the column graphs depicted in Figure 1. The weather factors that have a significant impact on PV power and are positively correlated are total radiation, direct radiation, scattered radiation, and temperature. The correlation coefficient values for these factors are 96.44%, 95.45%, 62.18%, and 47%, respectively. Among the factors affecting PV prediction results, total radiation is the most sensitive meteorological feature. If extreme weather causes data bias, it will have an unfavorable impact on the prediction results.




Figure 1. Input feature correlation histogram.

3. Grouping of Sample Data Based on 24 Solar Terms

3.1. Overview of 24 Sections

The 24 solar terms represent an integral component of the traditional Chinese calendar, reflecting the cyclical patterns of seasonal and climatic change observed in nature. In November 2016, the UNESCO Representative List of the Intangible Cultural Heritage of Humanity was expanded to include this traditional Chinese practice. The nomenclature of each solar term is directly reflective of the shifts in seasonal patterns, meteorological phenomena, and associated climatic changes. To illustrate, the initial spring equinox marks the Beginning of Spring, the Summer Solstice represents the midpoint of summer, and the Winter Solstice signifies the culmination of winter. The 24 solar terms, an early system

of knowledge based on the cyclical rotation of the seven stars of the Big Dipper and the annual movement of the sun, reflects the position of the Earth in its orbit and the correlation between the seasons and the climate. These are closely related to the seasons, climate, and physical phenomena of a year, and are universal. The current 24 solar terms are determined according to the position of the sun on the ecliptic; that is, the sun's apparent path on the celestial sphere during the year is divided into 24 equal parts of 15° each. Each part constitutes a node, resulting in 24 nodes, as illustrated in Figure 2. The existence of the angle of intersection of the yellow and red angles causes annual changes in the movement of the sun's point of direct sunlight back and forth between the earth's Tropic of Capricorn and Tropic of Cancer, which in turn causes changes in the height of the sun at noon and changes in the length of the day and night [18]. For example, the Summer Solstice marks the point where the sun crosses the Tropic of Cancer directly, resulting in the longest days of the year. The height of the sun and the length of the day exert a direct influence on PV power generation. As the duration of daylight increases, the hours of sunlight and the amount of radiation received by the PV panels also rise.




Figure 2. Division diagram of the 24 solar terms.

3.2. Data Grouping

Firstly, the data pertaining to the twenty-four solar terms for the year 2022, in addition to the operational data of the PV plant, are selected, and the date of the solar termination node is extracted. The empirical results indicate that meteorological conditions are more similar near the nodes, with notable examples including the longest day on the Summer Solstice, which also has the longest sunshine time. Indeed, the sunshine situation is nearly identical to that of the Summer Solstice in the time intervals of 2–3 days before and 2–3 days after the Summer Solstice. In accordance with the theory of similar days, the meteorological characteristics and PV operation data for the entire year are divided into 24 groups based on the seasons, with the time nodes of the aforementioned twenty-four seasons serving as the basis for this division. The training and test sets are divided in a crossover manner to enhance the prediction accuracy. Table 1 illustrates the grouping of the data training and test samples for some seasons.

Table 1. Grouping of sample data for selected festivals.

Solar Terms	Period	Training Samples	Test Samples
Slight cold	1.5 23:04:39–1.20 16:29:19 1.12 0:00–1.17 23:45	1.2 0:00–1.7 23:45	1.8 0:00–1.11 23:45
Spring begins	2.4 04:50:36–2.19 00:42:49 2.12 0:00–2.16 23:45	2.2 0:00–2.7 23:45	2.8 0:00–2.11 23:45
Vernal Equinox	3.20 23:33:15–4.5 03:20:02 3.28 0:00–4.2 23:45	3.18 0:00–3.23 23:45	3.24 0:00–3.27 23:45
Grain rain	4.20 10:24:07–5.5 20:25:45 4.28 0:00–5.2 23:45	4.18 0:00–4.23 23:45	4.24 0:00–4.27 23:45
Grain buds	5.21 09:22:25–6.6 00:25:36 5.29 0:00–6.3 23:45	5.19 0:00–5.24 23:45	5.25 0:00–5.28 23:45
Summer solstice	6.21 17:13:40–7.7 10:37:49 6.29 0:00–7.4 23:45	6.19 0:00–6.24 23:45	6.25 0:00–6.28 23:45
Slight heat	7.7 10:37:49–7.23 04:06:49 7.15 0:00–7.20 23:45	7.5 0:00–7.10 23:45	7.11 0:00–7.14 23:45
Stopping the heat	8.7 20:28:57–8.23 11:15:58 8.15 0:00–8.20 23:45	8.5 0:00–8.10 23:45	8.11 0:00–8.14 23:45
White dews	9.7 23:32:07–9.23 09:03:30 9.15 0:00–9.20 23:45	9.5 0:00–9.10 23:45	9.11 0:00–9.14 23:45
Cold dews	10.8 15:22:16–10.23 18:35:30 10.16 0:00–10.20 23:45	10.6 0:00–10.11 23:45	10.12 0:00–10.15 23:45
Winter begins	11.7 18:45:18–11.22 16:20:17 10.15 0:00–10.20 23:45	11.5 0:00–10.10 23:45	11.11 0:00–11.14 23:45
Heavy snow	12.7 11:46:04–12.22 05:47:00 12.15 0:00–12.20 23:45	12.5 0:00–12.10 23:45	12.11 0:00–12.14 23:45

3.3. Data Processing

Initially, the missing values and outliers are addressed. The missing values are then processed using the forward-filling method. The outliers are evaluated using the standard deviation method, after which they are subjected to processing via the substitution method. In order to prevent the information contained within the test set from being inadvertently transferred to the model, the data set is divided and placed before the normalized data. Subsequently, the maximum–minimum normalization method is employed for data processing to accelerate the model training process. Following normalization, each data point is scaled to the [0, 1] interval, as illustrated in Equation (2).

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (2)$$

where x is the variable that needs to be normalized, x' is the normalized data, and $x_{\max}$ and $x_{\min}$ are the maximum and minimum values of the input variables, respectively.

4. Impact of Extreme Weather on Forecast Results

While the present NWP system is highly accurate, it is prone to significant forecast biases in extreme or transient weather processes [19]. For instance, the forecast information for solar irradiance, air temperature, precipitation, sand and dust, and other variables in the forecast grid area exhibits a considerable degree of fallout range, with forecast timing of key meteorological elements being either premature or delayed and with amplitudes of the elements being either high or low. It can be reasonably deduced that these forecast biases will result in a corresponding bias in the PV power series, specifically in timing and amplitude.

The PV power plant under consideration in this study is situated in an area that receives more than 3260 h of sunshine per year, with an average of 73% of the sky being illuminated and the total radiation exceeding 6350 MJ/m². This region is classified as a land area with an abundance of solar energy resources [20]. The region displays three discrete geomorphological patterns of mountainous terrain, namely the Gobi, corridor flood plains, and sparse vegetation. These patterns are distinguished by a high prevalence of desertification, drought, scarce precipitation, and a pronounced temperature contrast between diurnal and nocturnal periods. The aforementioned climatic context gives rise to the frequent occurrence of meteorological disasters, including sand and dust storms and

cold waves. As grid-connected PV capacity continues to expand, it is imperative to consider the impact of extreme weather on the accuracy of PV power predictions. As illustrated in the correlation analysis presented at the outset, the correlation between the total radiation factor and the PV power is the most significant. This is followed by an examination of the change rule of the total radiation and its relationship with the deviation of the power prediction under conditions of extreme cold and sandy weather. This analysis provides a foundation for the development of an exact PV power prediction model. A high-precision PV power prediction model will be employed to establish a foundation for further analysis.

4.1. Cold Weather

A cold wave is defined as a wide range of cold solid air activity processes characterized by significant cooling and windiness. Additionally, these events are often accompanied by rain, snow, or frost precipitation. A cold wave is defined as a meteorological event characterized by a daily minimum temperature drop exceeding $8\text{ }^{\circ}\text{C}$ and a lowest temperature below $5\text{ }^{\circ}\text{C}$, persisting for a minimum of 48 h [21]. It can be observed that an increase in temperature results in a corresponding decrease in the impact of the cold snap on PV. In a sustained low-temperature environment, PV modules are susceptible to icing, which can impair power generation efficiency. The scale of PV off-grid deployment can significantly impact regional or even provincial voltage and frequency regulation.

Typically, the lowest temperatures are observed in January during the Lesser Cold period. In January 2021, the average temperature at PV power plants was $-9.7\text{ }^{\circ}\text{C}$, with the lowest temperature reaching $-20.9\text{ }^{\circ}\text{C}$. In January 2022, the average temperature was $-5.9\text{ }^{\circ}\text{C}$, with a minimum temperature of $-16.8\text{ }^{\circ}\text{C}$. As illustrated in Figure 3, the total radiation observed in 2021 and 2022 reached approximately 60% of the yearly maximum, reflecting the overall low temperature during the Lesser Cold period, particularly in 2021. This was due to a series of freezing weather events, which resulted in ice accumulation on the PV panels, thereby reducing the total radiation to a level that was considerably below the average for the entire year.




Figure 3. Time sequence diagram of total radiation during the Lesser Cold period.

4.2. Dusty Conditions

Dusty weather is defined as a meteorological phenomenon in which strong winds transport considerable quantities of dust and sand from the ground, resulting in the turbidity of the atmosphere and a notable reduction in horizontal visibility. The presence of dust in the atmosphere, particularly in high-humidity conditions, has a dual impact

on the efficiency of PV power generation. Firstly, it reduces the transmittance of solar radiation, leading to a more excellent diffuse reflection of solar radiation irradiated onto the surface of PV modules. Secondly, the presence of dust increases the likelihood of surface contamination, reducing the efficiency of PV power generation by approximately 30% [22]. The mineral composition of dust includes a significant proportion of calcium and magnesium oxides, which can facilitate the formation of calcium and magnesium scale on the surface of PV modules. PV cells have been observed to exhibit elevated temperatures and other problematic behaviors.

Due to the gradual increase in temperature within the PV power station area, the ground can only undergo warming before and after the Lesser Fullness of Grain. The abnormally dry and sparse surface conditions result in low resistance to wind erosion, facilitating the formation of dust and sand storms. This region experiences a significant sand and dust weather increase during May, coinciding with the Lesser Fullness of Grain. As illustrated in Figure 4, while the mean value of total radiation is more excellent during the Lesser Fullness of Grain period than during the Lesser Cold period, several intense dust weather events in 2022 resulted in a rapid decline in total radiation.




Figure 4. Time sequence diagram of total radiation during Lesser Fullness of Grain.

4.3. Analysis of Forecast Deviations

Based on the classical CNN prediction model, the following comparison is made between the predicted and actual measured values of PV power generation and its relationship with the change in total solar radiance under cold wave and dusty weather conditions in 2021 and 2022, respectively. To simplify the analysis, the Mean Absolute Percentage Error (MAPE) is chosen here as the assessment index [23]:

$$\text{MAPE} = \frac{1}{n} \sum_{t=1}^n \left| \frac{A_t - F_t}{A_t} \right| \times 100\% \quad (3)$$

where A_t is the actual measurement at time point t , F_t is the predicted value at time point t , and n is the total number of sampling points.

The selected cold weather occurred on 9 January 2021 and 11 January 2022, during the Lesser Cold period; as seen in Figure 5a,b, respectively, the total irradiance is positively proportional to the measured PV power, and the predicted power shows a positive deviation from the measured power. Among them, as shown in Figure 5a, on 9 January 2021, the weather was cloudy and cold, the total solar irradiance was less than 20%, the prediction

results showed a significant deviation, and the MAPE reached 45.49%. In Figure 5a, the peak of total solar radiation on 11 January 2022 is less than 50% and changes frequently, leading to a significant deviation in the prediction results, with an MAPE of 27.14%.




Figure 5. Comparisons of total radiation, short-term prediction, and measured power under cold wave weather conditions: (a) comparison results on 9 January 2021; (b) comparison results on 11 January 2022.

For the analysis of the prediction deviation of sandy weather, 29 May 2021 and 26 May 2022, which occurred during the Lesser Fullness of Grain period, were selected, and the short-term predicted power, actual power, and total radiation comparison curves are shown in Figure 6a,b. In Figure 6a, the total solar radiation fluctuates in the morning and evening hours of 29 May 2021, due to sandy weather, and the predicted MAPE value is 24.67%. In Figure 6b, there is a dust storm on 26 May 2022, which leads to a sudden drop in the total solar radiation and the MAPE value even reaches 95.12%, and there is a huge deviation in the prediction results; therefore, the output of PV power plants will

drop rapidly, and it will have a significant impact on the voltage of the local area and the frequency adjustment of the whole province.




Figure 6. Comparison of total radiation, short-term prediction, and measured power under sandstorm weather conditions: (a) comparison results on 29 May 2021; (b) comparison results on 26 May 2022.

In the following, the absolute deviation rates of the overall PV power in 2021 and 2022 are compared with those of the overall PV power in the Lesser Cold and Lesser Fullness of Grain periods, respectively. As shown in Table 2, during the Lesser Cold period, the forecast deviation rate decreases slightly from January 1 to 6, increases significantly from January 7 to 12, and decreases from January 13 to 18, 2022, but there is still a trend of increasing forecast deviation. During the Lesser Fullness of Grain period, as shown in Table 3, the forecast deviation decreased slightly from May 19 to 24, increased sharply from May 25 to 30, and remained basically stable from May 31 to June 5, 2022, relative to the previous year. Due to the more frequent turnaround weather at the end of May 2022, although it lasted for a shorter period of time, the strong dusty weather made the forecast

sample data jump a lot, increasing the prediction bias, which corresponded exactly to the time of the dust storm.

Table 2. MAPE comparison in Lesser Cold period.

MAPE	1–6 January	7–12 January	13–18 January
2021	10.03%	16.47%	15.19%
2022	8.56%	21.34%	16.50%

Table 3. MAPE comparison in Lesser Fullness of Grain period.

MAPE	19–24 May	25–30 May	31 May–5 June
2021	24.72%	27.46%	27.67%
2022	18.59%	41.18%	27.43%

The following is a comparison of the MAPE of the PV short-term power forecasts for a single day and time period. As shown in Figure 7, the sample data are selected from the PV short-term predicted power versus measured power values from 9:00 to 18:00 on 11 January 2021 and 2022. It can be seen that the MAPE value of the power prediction for the year 2022 significantly decreases in comparison with the previous year at 9–12:00 and 15–16:00, and there is a significant increase at 13–14:00 and 17–18:00, which corresponds perfectly with the occurrence of the extreme cold turnaround weather on that day that caused the temperature drop. The timing of icing corresponds precisely.




Figure 7. Comparison of daily PV power prediction MAPE by time period.

The above example of total radiance analyzes the fact that the representative weather extremes occurring in different seasons greatly impact the PV power prediction bias. Although the NWP has high accuracy with the past few example days, the NWP often suffers from prediction bias under extreme or even transient weather conditions, which is mainly manifested in the forecasts of crucial weather elements of the NWP, such as radiance, precipitation, temperature, and so on. This bias is mainly manifested in the forecasts of key meteorological elements of NWP, such as radiance, precipitation, air temperature, etc. In the forecast grid area, there are cases in which the fallout range of the information is too large or too small, the forecast time sequence of key meteorological elements is over or lagging, and the amplitude of the elements is too high or too low.

5. CNN-LSTM-Attention PV Power Prediction Models

5.1. Forecasting Process

Based on analyzing the relationship between historical PV output data and meteorological factors, a short-term PV power prediction–correction prediction model driven by PV output data is established, and the specific prediction process is shown in Figure 8.




Figure 8. Flow chart for PV power prediction.

Step 1: Collect the NWP data of the region where the PV plant is located, the twenty-four solar terms information of the selected year, and the operation data of the PV plant, and carry out data cleaning and normalization, including inspection and screening, elimination of erroneous data, interpolation and correction, etc., to extract the nodal dates of the solar terms of the specified year.

Step 2: According to the time nodes of the twenty-four solar terms, the preprocessed NWP data of PV power plants and the measured output power data of PV power plants are divided to establish 24 sets of data samples corresponding to the solar terms; the same set of training samples is derived from the data of the same solar term, and the selected data are only related to the solar terms but not to the year, which can be derived from the same solar terms in the same year as well as from the same solar terms in different years.

Step 3: Based on the 24 sets of training samples corresponding to the 24 solar terms, the CNN-LSTM-Attention prediction model is built for the 24 corresponding solar terms. The prediction model and parameters are determined according to the solar term of the desired prediction time point or the solar term corresponding to the input NWP data, and the PV power prediction results are obtained.

Step 4: To further improve the prediction accuracy, the PV power error correction link is also introduced to correct the prediction results of the above sections. Specifically based on the previous year's annual sample data, the CNN-LSTM-Attention model is utilized to obtain the initial prediction results of PV power and then subtracted from the measured PV power data to obtain the prediction deviation information of Formula (4), which is combined with the meteorological data of the corresponding festival weather to update the parameters of the prediction model in time, to make the final prediction model of the various festivals able to adapt to the variable operating points in the operation area of PV units.

$$\text{power}_{\text{error}} = \text{power} - \text{power}_{\text{forecast}} \quad (4)$$

Step 5: The initial prediction of PV power and the error prediction are summed correspondingly to obtain the final wind speed prediction.

5.2. Predictive Modeling

Based on the Attention mechanism and neural network, the CNN-LSTM-Attention prediction model is constructed, which employs a convolutional neural network to capture the local patterns and features of the sample data and efficiently extracts the critical information in the time series; the LSTM network is introduced to process the data and capture the long-term dependency relationships, which improves the accuracy of the prediction; and, finally, the Attention mechanism provides the model with the ability to focus on crucial information, further improving the prediction accuracy. The overall structure is shown in Figure 9.




Figure 9. Structure of CNN-LSTM-Attention prediction model.

The first layer is the input layer, which defines the data dimensions, including time step, feature dimension, and batch size. The time step is defined as r , the number of features is n , and the batch size defaults to 1. A sample is $r \times n$ of the real matrices.

The second layer is a convolutional neural network layer. It applies the convolutional layer to the input time series to extract features, capturing the local patterns in the input data while preserving these patterns' spatial invariance. This reduces computational complexity and better utilizes local information. In this model, 2D convolutions are employed. The sample data are first converted into a 2D matrix required by the convolutional operation, followed by convolution and pooling. The numbers of convolutional kernels in the first and second layers are 8 and 16, respectively. The size of the convolutional kernels are all 3×3 and the pooling operation size is 2. $x_{i:i-t+1}$ represents the real matrix at the i^{th} time step up to the $(i - t + 1)^{th}$ time step, which is a $r \times n$ matrix. W_i is the weight matrix, which is an $s \times n$ real matrix, and b_i is a bias term. f is the activation function. After processing s time steps, a feature o_i is obtained by performing a one-dimensional feature extraction. The formula is as follows:

$$o_i = f(W_i \times x_{i:i+s-1} + b_i) \quad (5)$$

The feature map is unfolded in reverse and dimensionally reduced into a real-valued vector that preserves the spatial relationships between different feature values and input into the LSTM layer.

The third layer is the LSTM layer, designed to process the time-series data of nonlinear PV power generation. The number of hidden units is 20. The LSTM unit consists of a forget gate, an input gate, and an output gate. The forget gate primarily controls the information from the previous internal state that needs to be discarded, the input gate determines the information that should be retained at the current time step, and the output gate selects the information that needs to be transmitted externally at the current time step. The memory structure of the LSTM helps to mitigate issues such as the excessive influence of weights during training and the vanishing gradient problem.

The fourth layer is the SE (Squeeze-and-Excitation) Attention mechanism layer, which applies an Attention mechanism to the output of the LSTM. This mechanism allocates

Attention weights to each time step, enhancing the influence of essential time steps within the LSTM and further improving prediction accuracy. The output of the LSTM is used as the input to the Attention mechanism layer, where each output vector is assigned a weight. The calculation formula is as follows:

$$S_i = \tanh(W_i H_i + b_i) \quad (6)$$

where S_i is the score for each output and H_i is the output of the LSTM network.

The fifth layer is the fully connected layer. The number of nodes in the fully connected layer is 50. The prediction results are transformed into probability distributions by a function, and then the weighted average sum of the output vectors is obtained using the weights obtained from the training. The calculation formula is as follows:

$$a_i = \text{softmax}(S_i) \quad (7)$$

$$C_i = \sum_{i=1}^k a_i H_i \quad (8)$$

where a_i is the weight coefficient, C_i is the result of the weighted sum of the vectors, and softmax is the activation function.

The sixth layer is the output layer, which defines the prediction time steps and outputs the final prediction results.

In this paper, the Adam optimizer trains the model on the neural network. The model is trained with 200 iterations, the initial learning rate is 0.001, and the learning rate decreases by 0.5 each time.

5.3. Evaluation Indicators

In prediction tasks, evaluating the predictive performance of the model is crucial. In addition to the previously mentioned MAPE, standard error evaluation metrics such as Root Mean Square Error (RMSE), Mean Absolute Error (MAE), Mean Bias Error (MBE), and the correlation coefficient R^2 are used to analyze the model's predictive effectiveness quantitatively.

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{t=1}^n (A_t - F_t)^2} \quad (9)$$

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |A_t - F_t| \quad (10)$$

$$R^2 = \frac{\sum_{t=1}^n [(A_t - \bar{A})(F_t - \bar{F})]}{\sqrt{\sum_{t=1}^n (F_t - \bar{F})^2 \sum_{t=1}^n (F_t - \bar{F})^2}} \quad (11)$$

where A_t is the measured data at the t^{th} time point; F_t is the predicted data at the t^{th} time point; $\bar{A}$ is the average of the measured results; $\bar{F}$ is the average of the predicted results; n is the total number of sampling points.

6. Case Studies

6.1. Data Preparation

The original data used a two-year data set from 1 January 2021 to 30 January 2022, with a sampling interval of 15 min and data characterization that included total, direct, and scattered radiation, temperatures, and their corresponding measured PV outputs.

According to the twenty-four solar term time series, the NWP data of PV power plants and the measured output power data of PV power plants are divided. In order to make each group of meteorological changes and solar irradiation time closer, 24 groups of data corresponding to them are established in accordance with the division of the festival time point two days in advance. The training set and the test set are divided by a crossover

approach to improve the prediction accuracy further. Table 3 shows examples of data training samples and test samples for some of the solar terms. To prevent the information of the test set from leaking to the model, the division of the data set is placed before the normalized data. In order to speed up the model training, the maximum–minimum normalization method is used to process the data set.

6.2. Comparative Analysis

In order to verify the superiority of the CNN-LSTM-Attention model proposed in this paper, it is used to predict the PV power generation in 2022 during the Lesser Cold period as an example, and it is used to compare the experiments with the support vector classification (SVC) and artificial neural network (ANN) models and perform the ablation experiments with the LSTM, CNN-LSTM, and LSTM-Attention. As shown in Figure 10, the CNN-LSTM-Attention model exhibits suboptimal performance when applied to non-stationary time series, particularly in the context of PV power time series prediction. The incorporation of a power error correction link enables the extraction of historical error characteristics through error prediction, facilitating the updating of prediction model parameters to enhance the precision of the prediction link. Figure 11 shows the predictions for the comparison and ablation experiments compared to the empirical performance data. The RMSE, MAE, and R^2 values of multi-step prediction results for each model are shown in Tables 4 and 5.




Figure 10. The influence of power error correction on prediction results.

Table 4. Comparison results of model error indicators in competitive analysis.

Prediction Model	MAE	RMSE	MAPE	R^2
SVM	0.5015	0.8447	45.19%	0.7184
TCN	0.2618	0.4716	16.33%	0.9310
RNN	0.3033	0.4356	23.70%	0.9249
Transformer	0.1540	0.2458	13.06%	0.9761
CNN-LSTM-Attention	0.1012	0.1938	7.18%	0.9853




Figure 11. PV power prediction result comparison between the proposed method and novel models: (a) comparison of predicted results from contrasting experiments; (b) comparison of predicted results from ablation experiments.

Table 5. Comparison results of model error indicators in ablation analysis.

Prediction Model	MAE	RMSE	MAPE	R ²
LSTM	0.2326	0.3612	23.52%	0.9484
CNN-LSTM	0.1684	0.2712	12.86%	0.9709
LSTM-Attention	0.1661	0.2539	11.40%	0.9745
CNN-LSTM-Attention	0.1012	0.1938	7.18%	0.9853

(1) Comparative experimental analysis

As seen in Table 4, the CNN-LSTM-Attention model demonstrates the lowest prediction error, achieving significant reductions in metrics compared to other models. Specifically, it exhibits a decrease in MAE, RMSE, and MAPE by 79.8%, 77.1%, and 84.1% relative to SVM, respectively. When compared to RNN, these metrics are reduced by 66.6%, 55.5%, and 69.7%. Similarly, the CNN-LSTM-Attention model shows reductions of 61.3%, 58.9%, and 56.0% compared to temporal convolutional network (TCN), and 34.3%, 21.2%, and 45.0% in relation to the Transformer model.

(2) Analysis of ablation experiments

As demonstrated in Table 5, the CNN-LSTM-Attention model exhibits superior predictive performance, as evidenced by lower MAE, RMSE, and MAPE values compared to LSTM, CNN-LSTM, and LSTM-Attention models. The MAE and RMSE of the CNN-LSTM model are reduced by 27.6% and 24.9%, respectively, compared to the single LSTM model. This suggests that employing CNN as a front end to the LSTM unit to extract multiple feature spatial linkages reduces the prediction error. The MAE and RMSE of the LSTM-Attention model are reduced by 28.6% and 29.7%, respectively, compared with the single LSTM, indicating that introducing the Attention mechanism can also reduce the prediction error. The CNN-LSTM-Attention model combines the advantages of CNN-LSTM and LSTM-Attention, and its MAE and RMSE are reduced compared to the single LSTM by 56.5% and 46.3%, a reduction from CNN-LSTM of 39.9% and 28.5% and a reduction from LSTM-Attention of 39.1% and 23.7%. Meanwhile, the CNN-LSTM-Attention model predicts the results with the highest R^2 value, which indicates that the CNN-LSTM-Attention model that introduces the CNN and Attention structures simultaneously can further reduce the prediction error and be more robust.

7. Conclusions

The intermittent, fluctuating, and stochastic nature of extreme weather phenomena presents a significant challenge to predicting the PV power generation work rate, rendering it more complex than load prediction. This paper employs an actual PV power plant in the western region of China as a case study to examine data grouping, the prediction process, and bias correction. The CNN-LSTM short-term PV output prediction and correction model, which employs an Attention mechanism, has been developed to address the shortcomings of existing prediction methods. The proposed model offers several advantages when compared to other existing approaches:

- (1) The correlation between the changes in the 24 traditional Chinese solar terms and extreme weather, as indicated by meteorological data within the same solar term, is a reliable indicator of the prevailing climate at the present moment. Furthermore, the fine grouping of sample data according to the time nodes of the 24 solar terms will enhance the predictive accuracy of the model.
- (2) The proposal of a CNN-LSTM PV power prediction–correction algorithm based on the Attention mechanism addresses the limitations of traditional time-series prediction methods, which are unable to adapt to nonlinear data and cannot consider temporal aspects of data. Furthermore, this approach effectively reduces the PV power multi-step prediction error.

This paper presents a study of two representative scenarios, which, while illustrative, cannot be considered exhaustive in their coverage of all potential weather impacts on PV output. Consequently, the next step will be to examine the classification of weather scenarios according to the type of error to develop a more rigorous and detailed delineation method. Due to the constraints of the temporal resolution of PV output data acquisition, the prediction–correction model presented in this paper has been designed offline. The predictive performance at the boundaries between different types of festivals remains suboptimal, which will be the focus of subsequent research.

Author Contributions: Conceptualization, G.W.; methodology, D.H.; software, Y.Z.; validation, G.W.; formal analysis, G.W.; investigation, D.H.; resources, D.H.; data curation, Y.Z.; writing—original draft preparation, G.W.; writing—review and editing, T.H.; supervision, project administration, funding acquisition, G.B. All authors have read and agreed to the published version of the manuscript.

Funding: This research was funded by the National Natural Science Foundation of China, grant number 51767018, the State Grid Gansu Electric Power Company, grant number SGGSKY00WYJS2310221, and the APC was funded by the State Grid Corporation of China Project, Natural Science Foundation of Gansu Province (22JR11RA216, 23JRR1664).

Data Availability Statement: No data were analyzed and hence data sharing is not applicable to this article.

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

References

1. Jun, G.Z.; Wang, J.R.; Cui, C.; Zhang, P.; Si, Y.B.; Fan, X.W.; Qin, W. Impact of extreme weather events on new energy power generation and power grid operation. *Smart Power* **2022**, *50*, 77–83.
2. Wang, N.; Chen, J.; Zhang, Y.Y.; Xu, Y.M.; Cui, J.W. Multi-source remote sensing analysis of the first dusty weather in northern China in 2021. *China Environ. Sci.* **2022**, *42*, 2002–2014.
3. Zhu, X.; Li, S.; Fan, J. An Overall Linearized Modeling Method and Associated Delay Time Model for the PV System. *Energies* **2023**, *16*, 4202. [\[CrossRef\]](#)
4. Zhang, C.; Tao, Z.H.; Xiong, J.L.; Qian, S.J. Research and application of a novel weight-based evolutionary ensemble model using principal component analysis for wind power prediction. *Renew. Energy* **2024**, *232*, 121085. [\[CrossRef\]](#)
5. An, S.; Shi, H.; Hu, Q.H.; Li, X.Q. Fuzzy rough regression with application to wind speed prediction. *Inf. Sci.* **2014**, *282*, 388–400. [\[CrossRef\]](#)
6. Harsh, S.D.; Dipankar, D.; Josep, M.G. On wavelet transform based convolutional neural network and twin support vector regression for wind power ramp event prediction. *Sustain. Comput. Inform. Syst.* **2022**, *36*, 100795.
7. Wu, J.X.; Li, S.T.; Vasquez, C.J.; Josep, M.G. A bi-level mode decomposition framework for multi-step wind power forecasting using deep neural network. *Energy Convers. Manag.* **2024**, *23*, 100650. [\[CrossRef\]](#)
8. Long, H.Y.; He, Y.L.; Xiang, W.; Guan, Z.Q.; Tan, H.; Yu, J.B. Research on Short-term Wind Speed Prediction Based on Adaptive Hybrid Neural Network with Error Correction. *IAENG Int. J. Comput. Sci.* **2023**, *50*, 4.
9. Xiang, G.W.; Lan, T.; Liu, L.P. Medium and Long Term Wind Power Generation Forecasting Method Based on Multi-model Fusion. *J. Phys. Conf. Ser.* **2024**, *2774*, 012004. [\[CrossRef\]](#)
10. Wang, G.F.; Gao, D.F.; Jiang, Y.; Wang, Z. A prediction model based on an adaptive genetic algorithm and optimized Elman neural network for PV power. *J. Phys. Conf. Ser.* **2023**, *2474*, 012033. [\[CrossRef\]](#)
11. Long, H.; Geng, R.H.; Sheng, W.X.; Hui, H. Small-Sample Solar Power Interval Prediction Based on Instance-Based Transfer Learning. *IEEE Trans. Ind. Appl.* **2023**, *59*, 5283–5292. [\[CrossRef\]](#)
12. Fujimoto, Y.; Takahashi, Y.; Hayashi, Y. Alerting to rare large-scale ramp events in wind power generation. *IEEE Trans. Sustain. Energy* **2019**, *10*, 55–65. [\[CrossRef\]](#)
13. Yilmaz, B. A scenario framework for electricity grid using Generative Adversarial Networks. *Sustain. Energy Grids Netw.* **2023**, *36*, 101157. [\[CrossRef\]](#)
14. Liu, W.C.; Mao, Z.Z. Prediction of rainy-day photovoltaic power generation based on Generative Adversarial Networks and enhanced Sparrow Search Algorithm. *Comput. Electr. Eng.* **2024**, *119*, 109529.
15. Baidu Online Encyclopedia. Available online: https://www.cma.gov.cn/en2014/20150311/20170119/201701/t20170119_388239.html (accessed on 12 November 2023).
16. Shi, Z.; Xiao, J.; Jiang, J.; Zhang, Y.; Zhou, Y. Identifying Reliability High-Correlated Gates of Logic Circuits With Pearson Correlation Coefficient. *IEEE Trans. Circuits Syst. II Express Briefs* **2024**, *71*, 2319–2323. [\[CrossRef\]](#)
17. Ma, M.; Tang, X.; Lv, Q.; Shen, J.; Zhu, B.; Wang, J.; Yong, B. Multi-features fusion for short-term photovoltaic power prediction. *Intell. Conver. Netw.* **2022**, *3*, 311–324. [\[CrossRef\]](#)
18. The Angle of Intersection of the Yellow and Red Zones of the Earth's Orbit Plane. Available online: <https://baike.baidu.com/item/%E9%BB%84%E8%B5%A4%E4%BA%A4%E8%A7%92/979385?fr=aladdin> (accessed on 1 January 2022).
19. Liu, Z.; Li, X.; Zhao, H. Short-Term Wind Power Forecasting Based on Feature Analysis and Error Correction. *Energies* **2023**, *16*, 4249. [\[CrossRef\]](#)
20. GB/T 37526-2019; Assessment Method for Solar Energy Resource. China National Standardization Administration: Beijing, China, 2019.
21. GB/T 20480-2017; Classification of Sand and Dust Weather. China National Standardization Administration Committee: Beijing, China, 2017.

22. Ren, X.Y.; Zhang, F.; Yan, J.S.; Liu, Y.Q. A Novel Convolutional Neural Net Architecture Based on Incorporating Meteorological Variable Inputs into Ultra-Short-Term Photovoltaic Power Forecasting. *Sustainability* **2024**, *16*, 2786. [[CrossRef](#)]
23. Tiwari, S.; Sabzehgar, R.; Rasouli, M. Short Term Solar Irradiance Forecast Using Numerical Weather Prediction (NWP) with Gradient Boost Regression. In Proceedings of the 2018 9th IEEE International Symposium on Power Electronics for Distributed Generation Systems (PEDG), Charlotte, NC, USA, 25–28 June 2018; pp. 1–8. [[CrossRef](#)]

Disclaimer/Publisher’s Note: The statements, opinions and data contained in all publications are solely those of the individual author(s) and contributor(s) and not of MDPI and/or the editor(s). MDPI and/or the editor(s) disclaim responsibility for any injury to people or property resulting from any ideas, methods, instructions or products referred to in the content.

RESEARCH

Open Access



Reactive power dispatch method for wind farms based on dynamic weight adjustment of electrical distance and reactive power capacity

Guodong Wu^{1,2}, Xiaohu Li², Ruixiao Zhang², Guangqing Bao³ and Hongtao Tan^{3*}

Abstract

To meet the requirements of real-time reactive power dispatch in wind farms, the method based on equal ratio of reactive power capacity is widely used, because it does not need power flow modeling and iterative solution. However, this method may cause the wind turbines (WT) with a long electrical distance to allocate too much reactive power, resulting in the terminal voltage exceeding the limit. Therefore, this paper proposes a reactive power allocation method based on dynamic weight adjustment of inverter capacity and electrical distance. First, the impact of WT power output on the voltage of each node in the system at different electrical distances was analyzed. Then, establish a reactive power dispatch model that takes the remaining capacity of the converter and electrical distance factors into account, and the weight coefficient between the two is dynamically adjusted based on voltage deviation by combining the idea of disturbance observation, achieve rapid distribution of reactive power commands without relying on detailed power flow modeling of the system. Finally, a 5 MW*25 wind farm case is used to verify the proposed method. The results show that the proposed method can effectively reduce the voltage deviation by more than 30% under the same reactive power scheduling instruction, and can improve the reactive power utilization of the wind farm.

Keywords Wind farm, Reactive power dispatch, Electrical distance, Converter capacity

Introduction

Driven by the goal of ‘peak carbon emissions and carbon neutrality’, China’s wind power industry has developed rapidly. As of now, the cumulative installed capacity of wind power in China has reached 460 million kW. However, due to the randomness and volatility of wind

power output, the voltage stability of the power system is threatened, and the demand for reactive power in the power grid is urgent (Liu & Cheng, 2021; Shabbir et al., 2022; Tan et al., 2023). Therefore, from the perspective of power grid operation, while injecting active power into the power system, wind farms also need to accept reactive power dispatch and participate in system reactive power voltage control (Asadollah et al., 2020; Dong et al., 2021; Tan et al., 2022).

Wind turbines (WTs) are connected to the power grid through inverters and have reactive power regulation capabilities, utilizing the reactive power capacity of the WT itself to achieve on-site reactive power compensation or accept reactive power dispatch has high economic efficiency (Peng et al., 2024; Tan et al., 2021; Wang et al.,

*Correspondence:

Hongtao Tan
13679261064@163.com

¹ College of Electrical and Information Engineering, Lanzhou University of Technology, Lanzhou 730050, People’s Republic of China

² Power Dispatch Center of State Grid, Gansu Electric Power Company, Lanzhou 730030, People’s Republic of China

³ School of Electronics and Information Engineering, Southwest Petroleum University, Chengdu 610500, People’s Republic of China

2022). However, due to the different operating states and electrical distances of the WTs in the wind farm, the impact trend of the output of different WTs on the system node voltage is different. Therefore, it is difficult to allocate the superior dispatch instructions to each WT (Guo et al., 2018a).

To achieve the allocation of reactive power dispatch instructions for wind farms, Ref. (Chondrogiannis et al., 2007; Sakamuri et al., 2016) adopt PI control of reactive power exchange values at point of common coupling (PCC), and allocate reactive power demand proportionally to each WT. In Ref. (Zhang et al., 2016), the reactive power output characteristics of doubly fed induction generator were considered, and the allocation of reactive power was achieved by prioritizing stator reactive power output and supplementing it with grid side inverters when insufficient. Ref. (Moursi et al., 2008) considers the active output of the WT, calculates the remaining reactive capacity of the inverter, and then issues reactive power instructions based on the proportional allocation of reactive capacity. In ref. (Guo et al., 2018b; Hung et al., 2019), a wind farm power flow model was established to optimize the distribution of WT reactive power command values with the goal of satisfying scheduling instructions and minimizing system active power loss and voltage deviation. Ref. (Zhao et al., 2016) takes both node voltage and system loss as optimization objectives, prioritizes the utilization of reactive power capacity of the WT, and uses reactive power compensation equipment to supplement when insufficient.

In summary, the reactive power dispatch methods of wind farms are mainly divided into two categories.

- (1) *Fixed rules*, such as proportional distribution of reactive power capacity, which does not need complicated calculation process and has low dependence on system parameters.
- (2) *Based on power flow optimization*, which needs detailed system parameter modeling and iterative solution, and has poor real-time performance, which is difficult to meet the demand of ms level power scheduling.

To meet the real-time reactive power scheduling requirements of the system, the first method is widely used in the current wind farm energy management platform. However, it does not take the differences in electrical distance (Lagonotte et al., 1989) between the WTs into account, resulting in some WTs exceeding their voltage limits when participating in reactive power dispatch. Therefore, a reactive power allocation method based on dynamic weight adjustment of electrical distance and reactive power capacity is proposed in this paper.

By reducing the reactive power output of WTs with a long electrical distance, the voltage limit of WTs can be avoided due to the increase of output reactive power, and has no complex logical operations, making it easy to implement.

The remainder of this paper is structured as follows. “Wind farm grid connected system and analysis of wind farm voltage characteristics” introduces the wind farm system and the voltage distribution characteristics of the wind farm. The optimization dispatch method is introduced in “Improved reactive power scheduling method”. “Case study” validated the proposed method through simulation models; “Conclusion” concludes this paper.

Wind farm grid connected system and analysis of wind farm voltage characteristics

Wind farm grid connection system

This paper takes a 5 MW*25 wind farm as an example for research and explanation. The wind farm adopts a typical radial structure, and the spacing between WTs on each feeder line is 1 km, as shown in Fig. 1.

Among them, a 5 MW permanent magnet synchronous generator is used, which is connected to the grid through a full power converter with a terminal voltage of 690 V. Reactive power is injected into the grid through a grid side converter. The grid side converter is boosted to 35 kV through the WT box transformer, connected to the main boosting transformer of the wind farm through the collection line, and then sent to the grid after being boosted to 220 kV. The key parameters are shown in Table 1.

The reactive capacity of the grid side converter is constrained by the apparent power, current limit, and terminal voltage, as described below:

$$\begin{cases} -\sqrt{S^2 - P^2} \leq Q_{\max} \leq \sqrt{S^2 - P^2} \\ I_d^2 + I_q^2 \leq I_{\max}^2 \end{cases}, \quad (1)$$

where S , P , and Q , respectively, represent the apparent power, active power, and reactive power of the grid connected inverter. I_d , I_q , and $I_{\max}$, respectively, represent the d -axis current, q -axis current, and current limit value of the inverter.

Voltage distribution characteristics within wind farms

Taking the wind farm shown in Fig. 1 as an example, the voltage distribution characteristics in the wind farm are further analyzed. Figure 2 shows the power–voltage (P – V) curves of different feeder distance WTs when the output power of the wind farm increases from 0 to 1 pu, where V_{ij} represents the j th WT on the i th feeder line, and V_{11} and V_{55} are taken for comparative analysis, representing the WTs with the closest and farthest




Fig. 1 Wind farm structure diagram

Table 1 Equipment parameter table in wind farm

Equipment	Parameter
35kv/220 kV transformer	$R=0.005$ pu, $X=0.12$ pu
35 kV cable	$R=0.0754$ Ω /km, $L=0.3365$ mH/km, $C=0.1805$ μ f/km
Distance of collection line (35 kV)	Line1= 1 km; Line2= 5 km; Line3= 7 km; Line4= 9 km; Line5= 20 km




Fig. 2 P–V curves of WTs at different positions

electrical distances (the electrical distance calculation is derived in detail in Appendix A), respectively. It can be seen that as the output power increases, the

node voltage generally shows a slight increase followed by a decrease. Therefore, there is a risk of exceeding the upper and lower limits of the wind farm. Therefore, there is a risk of voltage exceeding both the upper and lower limits of the wind farm. Especially the voltage of the rear WT is more affected by fluctuations in the output power, and the voltage drop rate at the end increases faster with the increase of power, posing a greater risk of exceeding the limit.

Figure 3 shows the impact trend of reactive power output on voltage at different positions of the WT. It can be seen that the impact trend on voltage varies under different positions and reactive power direction settings. As shown in Fig. 3a, setting the output reactive power to +0.3 pu, when the reactive power output of the WT on the fifth feeder line is prioritized (where Q_{L5} represents the reactive power command of the WT on fifth feeder), its terminal voltage has already exceeded the upper limit. When the output reactive power is −0.3 pu, prioritizing the use of fifth feeder WT reactive power will result in a lower limit risk (Fig. 3b), while prioritizing the use of first feeder WT will result in a lower limit risk. Based on the above analysis, the reactive power output of WTs at different electrical distances has different risks of voltage exceeding the system limit. Therefore, the conventional proportional allocation method may result in allocating more reactive power output to the rear WTs, leading to frequent voltage exceeding and disconnection accidents for WTs with longer electrical distances.




Fig. 3 P–V curves of reactive power output from WTs at different positions. **a** Each WT on feeder lines 1 and 5 outputs reactive power of 0.3pu, respectively. **b** Each WT on feeder lines 1 and 5 outputs reactive power of –0.3 pu, respectively

Improved reactive power scheduling method

After receiving the reactive power dispatch instruction from the power grid, the wind farm energy management platform distributes the reactive power dispatch instruction to each WT according to certain rules, as shown in the following equation:

$$\begin{cases} Q_{Wref} = \sum_{i=1}^n Q_{i,ref} \\ Q_{i,ref} = Q_{dp} * \alpha_i \end{cases} \quad (2)$$

where Q_{Wref} and $Q_{i,ref}$ represent the reactive power dispatch command of the wind farm and the i th WT, respectively. N is the number of WTs in the wind farm, α_i is the reactive power allocation coefficient for the i th WT.

When allocating according to the proportion of reactive power capacity of the WT, the setting method of α_i is as follows:

$$\alpha_i = \frac{Q_{i,max}}{\sum_{i=1}^n Q_{i,max}} \quad (3)$$

where $Q_{i,max}$ are the reactive power output limits of the i th WT. However, as mentioned earlier, using this allocation method may result in excessive output power of the rear WTs (with a long electrical distance), leading to voltage exceeding the limit at the WT terminals. Therefore, this section further introduces the factor of electrical distance to form a new reactive power allocation method, which is described as follows:

$$\alpha_i = \lambda_1 \frac{Q_{i,max}}{\sum_{i=1}^n Q_{i,max}} + \lambda_2 \frac{d_i}{\sum_{i=1}^n d_i} \quad (4)$$

where d_i represents the electrical distance of the i th WT (detailed derivation is shown in Appendix A). In this paper, the wind farm adopts a typical radial structure, so the length of the line from the 35 kV feeder of the WT to the low voltage side of the 35 kV/220 kV transformer is directly used as the calculation method for electrical distance. λ_1 and λ_2 are the weight coefficients of the remaining reactive capacity of the inverter and electrical distance of the WT, respectively. By adjusting the weight coefficients, the reactive power output of WTs with longer electrical distances can be reduced to ensure that the terminal voltage does not exceed the limit.

The following rules should be satisfied for λ_1 and λ_2 :

Constraint:

- (1) $\lambda_1 > 1$, $\lambda_2 < 1$, which means reducing the reactive power output of WTs that are far away from the electrical distance;
- (2) $\lambda_1 + \lambda_2 = 1$, which means that all reactive power commands issued by the wind farm must be allocated to each WT.

Using conventional perturbation observation or mountain climbing methods to optimize the value of λ_2 , the optimization process is shown in Fig. 4.

In Fig. 4, λ_{2_Init} , λ_{2_Max} , λ_{2_Min} , and $\Delta\lambda_2$ are the initial, maximum, minimum, and optimization step values of λ_2 , respectively, with values of 0, 0, –2, and 0.01. ΔU is the node voltage deviation, considering the difference in node voltage between WTs at different electrical distances, the calculation method for ΔU here is $|V_{55} - V_{11}|$. Using this method can not only effectively reduce the voltage deviation of rear WTs, but also achieve a uniform distribution of node voltage within the wind farm. $\Delta U(t)$ and $\Delta U(t-1)$ represent the voltage deviation at the current time and the previous time, respectively.

Weight optimization process:




Fig. 4 Optimization process of λ_2 based on perturbation observation method

The optimization process is as follows: when the wind farm receives a reactive power dispatch command, it starts initializing parameters and collecting node voltage to calculate the current time $\Delta U(t)$. Then, the disturbance direction of λ_2 is determined by judging the magnitude of $\Delta U(t)$ and the previous time $\Delta U(t-1)$, if $\Delta U(t) > \Delta U(t-1)$, then $\lambda_2 = \lambda_2 - \Delta \lambda_2$, and vice versa. Finally, the perturbed value of λ_2 is substituted into Eqs. (2) and (4) to calculate the reactive power command of each WT, achieving the allocation of reactive power dispatch command from the wind farm to each WT. To sum up, the optimization process only has simple addition and subtraction operations, without complex iterative calculation process, so its single calculation time can be ignored.

It should be noted that this paper only deals with the problem of reactive power distribution under steady operation conditions of wind farms. When the system has a fault or large disturbance, it needs to switch from steady state operation to transient fault crossing or additional damping control (Kumar et al., 2020, 2021, 2022; Verma et al., 2023).

Case study

Based on the Matlab/Simulink simulation platform, a wind farm model as shown in Fig. 1 is established. The effectiveness of the proposed method is verified by setting different wind speeds (corresponding to different power outputs of the WTs), different reactive power dispatch command operating conditions, and the following methods are used for comparative analysis:

- (1) *Traditional method*. Currently the most widely used method based on equal proportional allocation of reactive power capacity.
- (2) *Proposed method*. Dispatch method Based on dynamic weight adjustment of electrical distance and reactive power capacity.

Set the output of WTs on feeders 1 and 2–4 MW, and the output of units on feeders 3, 4, and 5–3 MW. The reactive power dispatch instructions are shown in Fig. 5.

The trend of node voltage changes under different control strategies is shown in Fig. 6, when no reactive power




Fig. 5 Wind farm reactive power dispatch instruction




Fig. 6 Trend of node voltage changes under different strategies

command is received, the terminal voltage of the WT is within the range of [1.02, 1.03] pu. After 3 s, the reactive power dispatch command of 12MVar is received. Under the traditional proportional reactive power allocation method, the voltage deviation of nodes has significantly increased, especially for the rear WT (V_{55}), where the deviation has reached around 0.075 pu, the voltage stability margin is limited. When the reactive power dispatch command increased to 24MVar at 6 s, V_{55} reached 1.12 pu, exceeding the upper limit constraint of the terminal voltage. At 9 s and 12 s, the reactive power output was set to -12 MVar and -24 MVar, and the terminal voltage (V_{55}) of the rear WT decreased to 0.963 pu and 0.895 pu, indicating that the terminal voltage of the rear WT had exceeded the lower limit. The main reason is that according to the proportional distribution, the output active power of the rear WTs is smaller than that of the front WTs, resulting in a larger reactive power command allocated to the rear WTs, causing a greater voltage deviation.

After adopting the method proposed in this paper, the disturbance of weight λ_2 was observed and optimized to reduce the proportion of reactive power output of the rear WTs. When the output reactive power was set to ± 24 MVar, the terminal voltages were 1.074 pu and 0.932 pu, respectively. Compared with the conventional control method, the WT terminal voltage remained within the upper and lower limit constraints, and effectively improving the dispatch ability of the wind farm's reactive power. The deviation of the WT terminal voltage was significantly reduced, with a decrease of 38% and 35%. At the same time, V_{11} and V_{55} were closer, and $|V_{55} - V_{11}|$ decreased from the maximum 0.05pu to around 0pu, making the node voltage in the wind farm more balanced. Based on the above analysis, the simulation results are consistent with the theoretical analysis and expected design of the allocation method mentioned earlier, which verifies the effectiveness of the proposed method.

The variation curve of weight λ_2 is shown in Fig. 7. It can be seen that when receiving the reactive power command from the wind farm, λ_2 begins to perturb and optimize, and when the reactive power instruction changes abruptly, the optimization response speed of λ_2 is in ms level, which meets the real-time requirement. When the reactive power command from the wind farm is 12 and 24 MVar, the values of λ_2 are -1.11 and -0.89 , respectively. The corresponding reactive power commands for the WTs (shown in Fig. 8) are 0.78 ($Q_{11,ref}$), -0.137 ($Q_{55,ref}$), 1.4 ($Q_{11,ref}$), and -0.03 ($Q_{55,ref}$), respectively, in MVar. It can be seen that when the output reactive power direction is +, the selection of λ_2 effectively reduces the forward reactive power of the rear WT, achieving




Fig. 7 Variation curve of weight λ_2




Fig. 8 Comparison of reactive power allocation results under different methods strategies

a reduction in voltage deviation. When the reactive power commands are -12 and -24 MVar, the values of λ_2 are -0.36 and -0.51 , respectively, and the corresponding reactive power commands for the units are -0.52 ($Q_{11,ref}$) and -0.314 ($Q_{55,ref}$), -1.14 ($Q_{11,ref}$) and 4.45 ($Q_{55,ref}$), respectively, in MVar. This also reduces the reactive power output of the rear WTs to reduce voltage deviation.

To further validate the effectiveness of the proposed method, the output power of WF is set, as shown in Fig. 9. It can be seen that the power output range of the wind farm is within the range of [0.1, 0.9] pu, which can simulate the actual power fluctuations of wind farms.

The reactive power dispatch value for the wind farm is set to be the same as Fig. 5, and the switching time is changed to 0, 20, 30, and 40 s. Figure 10 shows the voltage variation trend of the WT nodes under different control strategies, and representative front WT (W11) and rear WT (W55) terminal voltages were still selected for




Fig. 9 Wind farm output active power waveform




Fig. 10 Trend of node voltage changes under different strategies

comparative analysis. It can be seen that the node voltage fluctuates with wind speed, and the voltage of the rear WT (W55) is higher than that of the front WT (W11), with a voltage variation range between [0.985, 1.03] (W11) and [0.99, 1.04] (W55). When receiving reactive power instructions and using the conventional proportional method, the voltage deviation at the rear is significantly increased due to the influence of reactive power output. The voltage variation range is within the range of [0.96, 1.05] (W11) and [0.937, 1.13] (W55), it is obvious that conventional allocation method has caused the voltage to exceed the limit, and the maximum difference in terminal voltage between WTs has reached 0.05 pu. When using the proposed method, the voltage variation range is within the range of [0.96, 1.08], which reduces the maximum voltage deviation by 38% compared to the conventional method, and there is no situation of the WT voltage exceeding the limit. Prove that the proposed




Fig. 11 Voltage variation trend of different control strategies under wind speed fluctuations




Fig. 12 Change curve of weight λ_2 under the simultaneous change of active and reactive power references

method can effectively reduce voltage deviation, improve system voltage stability and reactive power utilization.

The variation curves of reactive power output and λ_2 are shown in Figs. 11 and 12. It can be seen that as the wind speed and reactive power dispatch change, λ_2 can quickly and dynamically optimize to adjust the allocation of reactive power commands, and the response speed can meet the requirements of online applications. Compared with the conventional distribution method, the reactive power command of the front row is higher than that of the rear row, so as to reduce the risk of the rear row voltage exceeding the limit.

Through the above analysis, the effectiveness of the proposed method has been confirmed. It only adjusts the weight between electrical distance and reactive power capacity without the need for complex mathematical operations, such as power flow modeling. It not only

effectively reduces voltage deviation but also has the advantage of simple implementation.

Conclusion

Based on the study of voltage distribution characteristics in wind farms, this paper proposes a reactive power allocation method for wind farms that considers electrical distance and residual reactive capacity. Through theoretical analysis and experimental verification, the main conclusions are as follows:

- (1) Due to the influence of line impedance, when reactive power is output by units located at a longer electrical distance, it is easy to cause the terminal voltage to exceed the limit. When allocating reactive power proportionally based on the reactive capacity of the converter, it may result in WTs with longer electrical distances being assigned larger reactive power commands, causing the terminal voltage of the WTs to exceed the limit;
- (2) By adjusting the weight of electrical distance and reactive capacity based on real-time voltage deviation, there is no need for detailed parameter power flow modeling of the system, and there is no complex logical operation. This reduces the output reactive power of WTs with longer electrical distances, effectively solving the problem of voltage exceeding the limit of rear WTs caused by reactive power allocation. Compared with conventional methods, it can further improve system voltage stability and reactive power utilization of wind farms.

In future research, further consideration will be given to reactive power allocation methods for unconventional radial structure wind farms.

Appendix A

In this paper, the electrical distance calculation method is based on transmission impedance, which is illustrated below by taking the single power–single load network as an example, as shown in Fig. 13.




Fig. 13 Schematic diagram of power system simplification

where the equivalent transmission impedance between branches/nodes can be obtained by the serial–parallel relationship, respectively: $Z_{ik} = Z_{ij} + Z_{jk}$ (Fig. 13a), $Z_{ij} = Z_{ij,1} + Z_{ij,2}$ (Fig. 13b), and then the modulus value of the impedance is taken to represent the size of the electrical distance. This method is also used in the paper to calculate the electrical distance.

Considering that the unit impedance parameters of the lines in the wind farm are the same, the length of the line distance from the WT node to the PCC is used in this paper to indirectly represent the electrical distance, which is the same as the actual calculation method based on transmission impedance when calculating the weight, as shown follow:

$$\frac{d_i}{\sum_{i=1}^n d_i} = \frac{L_{i,pcc}(Z_{i,pcc})}{\sum_{i=1}^n (L_{i,pcc}(Z_{i,pcc}))} = \frac{L_{i,pcc}}{\sum_{i=1}^n L_{i,pcc}}, \quad (4)$$

where $L_{i,pcc}$ represent the line length from node i to PCC, $Z_{i,pcc}$ represent the unit line impedance from node i to PCC, and the line unit impedance in the wind farm is consistent or relatively close, so the weight calculation between electrical distances can be directly simplified to the ratio between line lengths.

Acknowledgements

We confirm that this manuscript has not been published elsewhere and is not under consideration by another journal. All authors have approved the manuscript and agree with submission to Sustainable Energy Research. We have read and have abided by the statement of ethical standards for manuscript submitted to Sustainable Energy Research. The authors have no conflicts of interest to declare.

Author contributions

Guodong Wu, Xiaohu Li, Ruixiao Zhang, Guangqing Bao, Guangqing Bao and Hongtao Tan wrote the main manuscript text; Guodong Wu and Xiaohu Li provides a simulated original model; Ruixiao Zhang make some data analytics.

Funding

This work is funded by State Grid Corporation of China project (No. SGGSKY00WYJS2310221).

Data availability

No data sets were generated or analysed during the current study.

Declarations

Ethics approval and consent to participate

Not applicable.

Competing interests

The authors declare no competing interests.

Received: 8 November 2024 Accepted: 26 February 2025

Published online: 20 March 2025

References

- Asadollah, S., Zhu, R., & Liserre, M. (2020). Analysis of voltage control strategies for wind farms. *IEEE Transactions on Sustainable Energy*, 11, 1002–1012.
- Chondrogiannis, S., Barnes, M., Osborne, M., & Yao, L. (2007). Point of connection voltage regulation strategies for AC connected large offshore wind farms. *Wind Engineering*, 31, 453–473.
- Dong, Z., Li, Z., Du, L., Liu, Y., & Ding, Z. (2021). Coordination strategy of large-scale DFIG-based wind farm for voltage support with high converter capacity utilization. *IEEE Transactions on Sustainable Energy*, 12, 1416–1425.
- Guo, Y., Gao, H., Wu, Q., Zhao, H., Østergaard, J., & Shahidepour, M. (2018a). Enhanced voltage control of VSC-HVDC-connected offshore wind farms based on model predictive control. *IEEE Transactions on Sustainable Energy*, 9, 474–487.
- Guo, Y., Gao, H., Wu, Q., Zhao, H., & Stergaard, J. (2018b). Coordinated voltage control scheme for VSC-HVDC connected wind power plants. *IET Renewable Power Generation*, 12, 198–206.
- Huang, S., Wu, Q., Guo, Y., Chen, X., & Li, C. (2019). Distributed voltage control based ADMM for large-scale wind farm cluster connected to VSC-HVDC. *IEEE Transactions on Sustainable Energy*, 11, 584.
- Kumar, R., Diwania, S., Singh, R., Ashfaq, H., Khetrpal, P., & Singh, S. (2022). An intelligent hybrid wind-PV farm as a static compensator for overall stability and control of multimachine power system. *ISA Transactions*, 123, 286–302.
- Kumar, R., Singh, R., & Ashfaq, H. (2020). Stability enhancement of induction generator-based series compensated wind power plants by alleviating subsynchronous torsional oscillations using BFOA-optimal controller tuned STATCOM. *Wind Energy*, 23, 1846–1867.
- Kumar, R., Singh, R., Ashfaq, H., Singh, S. K., & Badoni, M. (2021). Power system stability enhancement by damping and control of Sub-synchronous torsional oscillations using Whale optimization algorithm based Type-2 wind turbines. *ISA Transactions*, 108, 240–256.
- Lagonotte, P., Sabonnadiere, J. C., Leost, J. Y., & Paul, J. P. (1989). Structural analysis of the electrical system: Application to secondary voltage control in France. *IEEE Transactions on Power Systems*, 4, 479–486.
- Liu, J. H., & Cheng, J. S. (2021). Online voltage security enhancement using voltage sensitivity-based coherent reactive power control in multi-area wind power generation systems. *IEEE Transactions on Power Systems*, 36, 2729–2732.
- Moursi, E. M., Joos, G., Abbey, C. A secondary voltage control strategy for transmission level interconnection of wind generation. *IEEE Transactions on Power Electronics*. 2008.
- Peng, H., Huang, S., Wei, J., Wei, C., Wu, Q., Shen, F., et al. (2024). Two-stage decentralized optimal voltage control in wind farms with hybrid ESSs. *IEEE Transactions on Power Systems*, 39, 6552–6565.
- Sakamuri, J. N., Rather, Z. H., Rimez, J., Altin, M., Goksu, O., & Cutululis, N. A. (2016). Coordinated voltage control in offshore HVDC connected cluster of wind power plants. *IEEE Transactions on Sustainable Energy*, 7, 1592–1601.
- Shabbir, M. N. S. K., Liang, X., & Chakrabarti, S. (2022). A Hierarchical voltage control scheme for wind power plants through enhanced reactive power support. *IEEE Transactions on Industry Applications*, 58, 5776–5791.
- Tan H, Li H, Xie X, Yang T, Yang W. Reactive-voltage coordinated control of offshore wind farm based on deep reinforcement learning. In *2021 3rd Asia Energy and Electrical Engineering Symposium (AEEES)* 2021.
- Tan, H., Li, H., Xiang, X., Zhang, X., Yao, R., Zhou, Z., et al. (2023). Characterization of static voltage stability region of offshore wind farms considering submarine cable capacitance parameters and converter saturation. *International Journal of Electrical Power & Energy Systems*, 150, 109095.
- Tan, H., Li, H., Yao, R., Zhou, Z., Liu, R., Wang, X., et al. (2022). Reactive-voltage coordinated control of offshore wind farm considering multiple optimization objectives. *International Journal of Electrical Power & Energy Systems*, 136, 107602.
- Verma, N., Kumar, N., & Kumar, R. (2023). Battery energy storage-based system damping controller for alleviating sub-synchronous oscillations in a DFIG-based wind power plant. *Protection and Control of Modern Power Systems*, 8, 1–18.
- Wang, P., Wu, Q., Huang, S., Li, C., & Zhou, B. (2022). ADMM-based distributed active and reactive power control for regional AC power grid with wind farms. *Journal of Modern Power Systems and Clean Energy*, 10, 588–596.
- Zhang, B., Hou, P., Hu, W., Soltani, M., Chen, C., & Chen, Z. (2016). A reactive power dispatch strategy with loss minimization for a DFIG-based wind farm. *IEEE Transactions on Sustainable Energy*, 7, 914–923.
- Zhao, H., Wu, Q., Guo, Q., Sun, H., Huang, S., & Xue, Y. (2016). Coordinated voltage control of a wind farm based on model predictive control. *IEEE Transactions on Sustainable Energy*, 7, 1440–1451.

Publisher's Note

Springer Nature remains neutral with regard to jurisdictional claims in published maps and institutional affiliations.



中国测试
China Measurement & Test
ISSN 1674-5124, CN 51-1714/TB

《中国测试》网络首发论文

题目：考虑可再生能源接入的主动配电网双层规划消纳优化方法
作者：吴国栋，胡殿刚，张珍珍，包广清
网络首发日期：2025-03-20
引用格式：吴国栋，胡殿刚，张珍珍，包广清. 考虑可再生能源接入的主动配电网双层规划消纳优化方法[J/OL]. 中国测试.
<https://link.cnki.net/urlid/51.1714.TB.20250319.1543.004>



网络首发：在编辑部工作流程中，稿件从录用到出版要经历录用定稿、排版定稿、整期汇编定稿等阶段。录用定稿指内容已经确定，且通过同行评议、主编终审同意刊用的稿件。排版定稿指录用定稿按照期刊特定版式（包括网络呈现版式）排版后的稿件，可暂不确定出版年、卷、期和页码。整期汇编定稿指出版年、卷、期、页码均已确定的印刷或数字出版的整期汇编稿件。录用定稿网络首发稿件内容必须符合《出版管理条例》和《期刊出版管理规定》的有关规定；学术研究成果具有创新性、科学性和先进性，符合编辑部对刊文的录用要求，不存在学术不端行为及其他侵权行为；稿件内容应基本符合国家有关书刊编辑、出版的技术标准，正确使用和统一规范语言文字、符号、数字、外文字母、法定计量单位及地图标注等。为确保录用定稿网络首发的严肃性，录用定稿一经发布，不得修改论文题目、作者、机构名称和学术内容，只可基于编辑规范进行少量文字的修改。

出版确认：纸质期刊编辑部通过与《中国学术期刊（光盘版）》电子杂志社有限公司签约，在《中国学术期刊（网络版）》出版传播平台上创办与纸质期刊内容一致的网络版，以单篇或整期出版形式，在印刷出版之前刊发论文的录用定稿、排版定稿、整期汇编定稿。因为《中国学术期刊（网络版）》是国家新闻出版广电总局批准的网络连续型出版物（ISSN 2096-4188，CN 11-6037/Z），所以签约期刊的网络版上网络首发论文视为正式出版。

考虑可再生能源接入的主动配电网双层规划消纳优化方法

吴国栋^{1,2}, 胡殿刚², 张珍珍³, 包广清¹

(1.兰州理工大学电气工程与信息工程学院, 甘肃 兰州 730030; 2.甘肃省电力公司, 甘肃 兰州 730030;
3.甘肃省电力公司电力科学研究院, 甘肃 兰州 730030)

摘要: 可再生能源大规模接入电网后, 其固有的出力不确定性和波动性直接导致了电网消纳出现一定问题, 无法达到最大消纳, 增加了电网的整体运行风险。为保证可再生能源并网后主动配电网的稳定运行, 提出考虑可再生能源消纳的主动配电网双层规划方法。基于功率函数描述可再生能源消纳中的不确定性, 依据该计算结果构建主动配电网双层规划函数, 上层模型优化规划成本和网络灵活性, 下层模型提升可再生能源消纳能力并降低运行风险, 并设定相关约束条件。为求解该模型, 并采用精英策略优化布谷鸟算法, 通过更新鸟窝位置并结合精英策略进行迭代优化, 输出满足所有约束条件的主动配电网规划方案的最优选择, 实现电网消纳优化。仿真结果表明: 利用该方法的可再生能源消纳率达到 77.85%; 线路平均负载不超过 24.2%, 变电站平均负载不超过 30%; 该网络在不同波动比例下, 各个线路的传输充裕率均为正数, 结果均在 0.4 以上。由此表明, 所提方法可以实现主动配电网不确定性规划, 保证电网的稳定运行。

关键词: 可再生能源; 消纳能力; 主动配电网; 不确定性规划; 双层规划模型; 线路平均负载

中图分类号: TB9; TM711

文献标识码: A

Dual layer planning and consumption optimization method for active distribution network considering renewable energy access

WU Guodong^{1,2}, HU Diangang², ZHANG Zhenzhen³, BAO Guangqing¹

(1.College of Electrical and Information Engineering, Lanzhou University of Technology, Lanzhou 730030, China; 2.State Grid Gansu Electric Power Company, Lanzhou 730030, China;
3.State Grid Gansu Electric Power Company Electric Power Science Research Institute, Lanzhou 730030, China)

Abstract: After the large-scale integration of renewable energy into the power grid, its inherent output uncertainty and volatility directly lead to certain problems in grid consumption, which cannot achieve maximum consumption and increase the overall operational risk of the power grid. To ensure the stable operation of the active distribution network after the integration of renewable energy, a dual layer planning method for the active distribution network considering the consumption of renewable energy is proposed. Based on the power function to describe the uncertainty in renewable energy consumption, an active distribution network dual layer planning function is constructed based on the calculation results. The upper layer model optimizes the planning cost and network flexibility, while the lower layer model enhances the renewable energy consumption capacity and reduces operational risks, and sets relevant constraints. To solve the model and optimize the cuckoo algorithm using the elite strategy, the bird nest position is updated and the elite strategy is combined for iterative optimization. The optimal selection of the active

项目基金: 国网甘肃省电力公司电力科学研究院科技项目 (52272223000V)

作者简介: 吴国栋 (1985-), 男, 甘肃会宁县人, 高级工程师, 硕士, 研究方向为电力系统自动化、可再生能源发电。

distribution network planning scheme that meets all constraints is output to achieve power grid consumption optimization. The simulation results show that the renewable energy consumption rate using this method reaches 77.85%; The average load of the line shall not exceed 24.2%, and the average load of the substation shall not exceed 30%; The transmission adequacy ratio of each line in this network is positive under different fluctuation ratios, and the results are all above 0.4. This indicates that the proposed method can achieve active distribution network uncertainty planning and ensure the stable operation of the power grid.

Keywords: renewable energy; consumption capacity; active distribution network; uncertainty planning; dual layer planning model; line average load

0 引言

主动配电网能够高效地集成并优化分布式电源、储能装置及可控负荷等多元资源,提高电网的灵活性和可靠性^[1-2]。然而,可再生能源发电的不确定性对电网规划构成了严峻挑战,这种不确定性不仅体现在发电量的精准预测难度上,更直接关系到电网的调度策略与消纳能力^[3]。为保证主动配电网的稳定运行。众多学者对此展开研究。

刘帅等^[4]提出基于净负荷最优可接纳域的新模型用于配电网电源规划,有效解决了可靠性成本计算的难题。但可再生能源的间歇性和波动性可能导致电网功率频繁波动,影响电网的稳定性和安全性。孟令卓越等^[5]针对分布式光伏和储能装置接入主动配电网后的不确定性,提出了经济优化调度模型。该模型通过线性化方法和概率约束转换简化为混合整数线性规划问题,旨在平衡调度成本与可靠性。但在极端情况下无法保证系统的稳定运行和最大可再生能源消纳。董雷等^[6]为实现配电网规划,确保稳定运行并提升资源灵活性,构建了一个结合智能开关特点的双层优化模型。他们采用强化学习方法进行动态规划,以适应源荷不确定性场景。然而,在处理可再生能源出力的高度不确定性和波动性时,可能导致策略在极端情况下失效,影响可再生能源的最大消纳。Heitor 等^[7]为配电系统规划提出了交直流优化扩展方法,通过整数规划确定电网结构和转换器配置。但该方法未充分考虑其波动性和随机性,可能影响实际运行中的最大消纳能力。司威等^[8]为确保配电网规划后的稳定性,分析了风光能源的不确定性影响,并构建了以降低运行成本为主的优化模型来确

定规划调度方案。然而,该方法忽视了电网最大消纳能力,可能导致在可再生能源大规模接入时电网缺乏足够的灵活性和适应性。朱自伟等^[9]构建了风光储联合发电系统并优化柔性负荷调度,采用模糊自适应粒子群算法提高主动配电网对分布式可再生能源的消纳能力和运行稳定性。但可再生能源出力的不确定性可能导致预测偏差,从而难以准确评估配电网的消纳和运行稳定性。

本研究提出了一种考虑可再生能源消纳的主动配电网双层规划方法。以确保电网安全和满足负荷需求。

1 主动配电网双层规划消纳优化

1.1 双层规划优化模型建立

可再生能源,如太阳能和风能,其发电量受到天气条件(如日照强度、风速、风向、云层遮挡等)的直接影响,导致发电功率表现出显著的间歇性和波动性^[10]。这种不确定性使得可再生能源发电与电力需求之间难以实时匹配,增加了电网调度和消纳的难度^[11]。为了解决这一问题,本研究采用了双层规划方法,使主动配电网能够更加灵活地应对可再生能源消纳中的不确定性问题。利用鲁棒优化算法构建了可再生能源的功率函数,以准确描述其不确定性。双层规划模型包括上层网架规划和下层运行结构规划:上层模型旨在优化规划成本和网络灵活性,确保规划结果的前瞻性和经济性;下层模型则聚焦于提升可再生能源消纳能力、降低运行综合风险,并设定可再生能源消纳、渗透率及可靠性等约束条件。通过双层规划,该方法能够灵活应对可再生能源的不确定性,提高电网的消纳能力和运行稳定性。

为充分描述可再生能源消纳的不确定

性，选择鲁棒优化算法构建其功率函数，使得规划模型能够更好地适应实际运行中的不确定性因素。计算该能源的实际功率结果

$P_s(t)$ ，其公式为：

$$P_s(t) = \bar{P}_s(t) + \Delta P_s(t) \quad (1)$$

其中在 t 时段下， $\bar{P}_s(t)$ 表示预测功率；其与 $P_s(t)$ 之间侧差值结果用 $\Delta P_s(t)$ 表示。

依据公式 (1) 的结果，构建双层主动配电网规划目标函数^[12]，即上层函数和下层函数。

1) 上层函数

上层函数主要用于主动配电网的网架规划，通过设定合理的目标函数保证规划结果的合理性和经济性，文中设定该层的目标函数为主动配电网的规划成本最小 $\min C$ 、网络灵活性最大 $\max f_1$ ，目标函数的计算公式为：

$$\min C = C_1 + C_2 + C_3 + C_4 \quad (2)$$

$$\max f_1 = \sum_{t=1}^T \psi_{ij}^t \quad (3)$$

其中 T 表示调度周期； ij 表示线路，其在进行能源传输时的充裕度用 ψ_{ij}^t 表示； C_1 、 C_2 、

C_3 均表示成本，分别是规划投资产生的、电量购买产生、可再生能源运行产生； C_4 则是电网在出力不确定性时产生的惩罚成本。 C_3 、 C_4 的计算公式为：

$$\begin{cases} C_3 = \eta_3(t) P_s(t) \\ C_4 = \eta_4(t) P_s(t) \end{cases} \quad (4)$$

其中 $\eta_3(t)$ 和 $\eta_4(t)$ 分别表示两种成本对应的系数。

在上层函数中，主要考虑可再生能源的

运行特点对其功率进行约束：

$$\Delta P_{\min}(t) \leq \Delta P_s(t) \leq \Delta P_{\max}(t) \quad (5)$$

其中 $\Delta P_s(t)$ 的最大值和最小值分别用

$\Delta P_{\max}(t)$ 和 $\Delta P_{\min}(t)$ 表示。

通过上层函数完成主动配电网的网架规划后，则进行其内部运行结构规划，该规划核心目的是提升主动配电网的可再生能源消纳能力，同时保证主动配电网的安全、稳定运行^[13]。

2) 下层函数

下层以运行综合风险指标最小 $\min \chi_1$ 、

日前消纳能力最大 $\max f_2$ 以及可再生能源功率削减量最小 $\min f_3$ 为目标函数，其计算公式分别为：

$$\min \chi_1 = w_1 R_1 + w_2 R_2 \quad (6)$$

$$\min f_2 = \sum_{t=1}^T \sum_{g=1}^{N_s} [P_{s,g}^{\max}(t) - P_s(t)] \quad (7)$$

$$\min f_3 = \frac{\sum_{t=1}^T P_s(t)}{\sum_{t=1}^T P_{s,g}^{\max}(t)} \quad (8)$$

其中 R_1 和 R_2 分别表示失负荷风险和设备损坏风险；主动配电网运行时发生两种风险的权重系数用 w_1 和 w_2 表示； $P_{s,g}^{\max}(t)$ 表示可再生能源最大出力。

下层函数的主要目标是提升主动配电网的消纳能力以及安全运行，因此设定相关约束条件：

1) 可再生能源消纳约束：

可再生能源功率实际消纳功率需低于预测功率，该约束条件公式为：

$$P(t) < P_{\max}(t) \quad (9)$$

其中 $P(t)$ 表示在 t 时刻下, 能够调用的可再生能源出力; 其最大功率结果用 $P_{\max}(t)$ 表示。

2) 可再生能源渗透率约束:

为保证主动配电网规划后安全性^[14], 需保证规划后网络中节点、线路等不会发生电压和电流越限情况, 因此, 约束可再生能源的并网容量, 其公式为:

$$\gamma \leq \gamma_{\max} \quad (10)$$

其中可再生能源的实际渗透率和最大渗透率分别用 γ 和 $\gamma_{\max}$ 表示。

3) 可靠性约束:

主动配电网规划后, 需保证其能源的可靠性^[15], 满足用电需求, 因此, 该约束条件的计算公式为:

$$\xi_A \geq \xi_{\min} \quad (11)$$

$$\xi_A = \frac{N_u - T_o N_o}{N_u} \quad (12)$$

其中 ξ_A 表示平均供电可用率; $\xi_{\min}$ 表示最低供电可用率标准; T_o 表示线路发生故障后的持续时间; N_o 和 N_u 分别表示全部用户数量和供电受影响用户数量。

综上所述, 双层规划函数能够分别处理不同层次的优化问题, 并在两层之间建立联系。在上层规划中, 可以综合考虑可再生能源的不确定性对电网规划的影响; 在下层规划中, 则可以针对具体的电网运行场景进行优化。这种分层处理有助于更全面地考虑不确定性因素, 有效提高规划结果的准确性和可靠性, 为电网的安全稳定运行提供有力保障。

1.2 双层规划优化模型求解

在实际应用场景中, 主动配电网面临着复杂多变的运行环境, 其中包括可再生能源发电和负荷需求等多种不确定性因素, 这些

因素对电网的消纳能力构成了挑战。为了有效应对这些挑战, 本研究采用一种改进的布谷鸟算法来求解双层规划优化模型中的上下层目标函数。该算法融合了布谷鸟算法的全局搜索能力强和收敛速度快的特点, 并结合了精英策略, 以增强算法的适应性和鲁棒性。求解流程涉及设定运行参数、约束条件及初始化解集。随后, 通过更新鸟窝位置, 并结合精英策略将鸟窝划分为精英和普通两类。对于精英鸟窝, 采用随机变化方式更新位置; 对于普通鸟窝, 则采用引力搜索方式更新位置, 以此引导搜索过程向更优解方向移动。最终, 通过重复迭代直至达到预设的最大迭代次数, 输出双层规划问题的最优解, 为电网调度和规划提供可靠的决策支持。求解过程如下:

步骤 1: 设定主动配电网的运行参数。

定义规划模型的相关约束条件, 包括可再生能源出力约束、渗透率约束、可靠性约束等, 确保规划结果符合电网运行的实际情况。随机生成一组初始的鸟窝 (即目标解的候选集合), 每个鸟窝代表一个可能的配电网规划方案。确定算法的最大迭代次数, 作为算法终止的条件之一。对于每个上层函数的解 (即每个鸟窝), 需要求解对应的下层函数以得到最优解。这通常涉及到在满足下层约束条件下, 优化下层目标函数 (如运行综合风险最小、消纳能力最大等)。基于下层函数得到的最优解, 计算上层函数的适应度。适应度通常反映了该解对应的规划方案在经济性、灵活性等方面的优劣。适应度的表达式为:

$$f(k) = \min \chi_1(k) + \max f_2(k) + \max f_3(k) \quad (13)$$

其中 $f_i(k)$ 表示个体 i 的适应值; 其最大值和最小值分别用 $\max f(k)$ 和 $\min f(k)$ 表示; k 表示迭代次数。

步骤 2: 更新鸟窝位置。在每次迭代中, 根据布谷鸟算法的搜索机制更新鸟窝的位置和随机数 λ , 将 λ 和鸟窝位置被发现概率

$\gamma_a(k)$ 进行对比, 如果 $r > \gamma_a(k)$, 则通过随机的方式变化当前鸟窝位置, 即解的位置, 生成新一代鸟窝位置; 反之则不对鸟窝位置进行更新, 保持不变。

步骤 3: 依据精英策略进行鸟窝划分, 其公式为:

$$\begin{cases} M = M_e + M_z \\ M_e = M \times (1 - \beta) \\ M_z = M \times \gamma \end{cases} \quad (14)$$

其中 M_e 和 M_z 分别表示种群中精英个体和普通个体的数量; M 表示种群规模; β 表示个体分割黄金比例。

依据公式 (14) 即可完成当前鸟窝的划分, 形成精英和普通两种鸟窝。

步骤 4: 通过引力搜索的方式更新划分获取的精英鸟窝位置, 以此生成新的鸟窝位置。引力搜索的表达式为:

$$\kappa_{i,j}(k) = \mu(k) \frac{\bar{M}_e(k) \bar{M}_e(k)}{d_{i,j}(k) + \varepsilon} [x_i(k) - x_j(k)] \quad (15)$$

其中 $\mu(k)$ 表示引力系数; $d_{i,j}(k)$ 表示两个鸟窝 (目标解) 之间的欧式距离; $\bar{M}_e(k)$ 和 $\bar{M}_e(k)$ 分别表示鸟窝 (目标解) 的主动和被动引力质量; $x_i(k)$ 和 $x_j(k)$ 分别表示两个鸟窝 (目标解) 在 k 次迭代后的位置; ε 表示常数。

由此得到精英鸟窝的更新策略, 以引导搜索向更优解区域移动。表达式为:

$$x_i(k+1) = x_i(k) \kappa_{i,j}(k) + r_i v_i(k) + \delta_i(k) \quad (16)$$

其中 r_i 表示随机数; $v_i(k)$ 表示迭代速度;

$\delta_i(k)$ 表示引力加速度。

步骤 5: 重复步骤 2~4, 直到达到最大迭代次数。输出最终的上层最优解及其对应

的下层最优解, 作为双层规划问题的解。这个解代表了在满足所有约束条件下, 主动配电网规划方案的最优选择。

基于上述内容, 得出基于改进布谷鸟算法的双层规划优化模型求解流程图如图 1 所示。




图 1 双层规划优化模型求解流程图

通过上述步骤, 改进的布谷鸟算法能够有效地求解双层规划优化模型中的上下层目标函数, 为电网调度和规划提供可靠的决策支持。

2 仿真分析

2.1 仿真设置

为验证本研究所提出的方法对于主动配电网的规划效果, 以某地区待规划的局部配电网为例。该地区的气象、电负荷等基础数据如表 1 所示。

表 1 仿真区域基础数据

参数名称	参数值 (年平均)
风速	5.5 m/s
光照强度	450 W/m ²

温度	20.5 °C
历史负荷（平均）	450 MW
负荷预测（平均）	475 MW

该配电网中包含 2 个变电站，两条已建线路，待建设线路为 18 条，原始规划方案如图 2 所示。




图 2 局部配电网规划方案示意图

该配电网在规划时，需考虑光伏和风电场并网情况，因此，需保证规划后光伏的消纳率，同时考虑其不确定性的影响，并保证主动配电网规划后的运行安全。接入的光伏和风电场以及储能系统的详细参数如表 2 和表 3 所示。

表 2 光伏和风电场的详细参数

类别	安装节点	装机容量/kW
光伏	2	550
	6	800
	11	700
风电场	8	500
	4	700
	13	500

表 3 储能系统的详细参数

参数名称	数值
最大充电功率/kW	1500
最大放电功率/kW	1500
最大安装容量/kWh	6000
最大安装视在功率/kVA	1650
储能充电效率/%	85
储能放电效率/%	80
储能放电深度/%	92
储能安装单位容量/(组/kW)	100

实验过程中，所提方法的参数设置如表

4 所示。

表 4 算法的参数设置

参数名称	参数 值
贴现率	0.05
网络灵活性权重	0.4
规划成本权重	0.6
可再生能源渗透率目标	30%
时间步长	1 小时
仿真时长	365 天
可再生能源预测误差标准差（风力）	15%
可再生能源预测误差标准差（光伏）	10%
运行风险权重	0.3
可再生能源消纳能力权重	0.7
种群大小	50
最大迭代次数	1000
发现概率	0.25
精英个体比例	10%
步长缩放因子	0.01
局部搜索步长缩放因子	0.1

2.2 结果与分析

在上述设置的基础上，获取该配电网的网架规划结果以及规划前后配电网的内部运行情况，测试结果如图 3 和表 5 所示。




图3 主动配电网网架结构规划结果

表5 规划前后配电网的内部运行情况

测试内容	原始结果	规划结果
运行成本/元	33205.7	25505.4
可再生能源消纳率/%	41.72	77.85
网络灵活性/%	55.44	78.14
综合风险	1.83	1.47
可再生能源功率削减量 /TWh	6.11	5.53

对图3和表5测试结果进行分析后得出：通过本研究提出的方法进行主动配电网规划后，能够依据规划目标完成网架规划，并且规划的线路清晰，网架结构简单，不存在重复交叉情况；同时对比原始规划方案结果，规划后的总成本明显下降，可再生能源的消纳率达到77.85%。这是因为所构建的功率函数，能够充分描述可再生能源消纳中的不确定性。这种描述方式能够更准确地反映可再生能源出力的波动性和随机性，从而为规划提供更加可靠的数据支持。

为进一步全面评估本研究提出方法的规划效果，采用了线路平均负载 ϕ_{ij} 和变电站平均负载 ϕ_{ij} 作为评价指标。这两个指标能够直观反映规划后配电网在实际运行过程中，网架结构以及内部变电站的负载情况。结合该配电网的实际规划需求与运行标准，设定了明确的期望阈值：即期望线路平均负载 ϕ_{ij} 不超过24.2%，变电站平均负载 ϕ_{ij} 不超过30%。两个指标的计算公式分别为：

$$\phi_{ij} = \frac{1}{TN_G} \sum_{\forall i,j} \sum_{t=1}^{24} \frac{|S_{ij}(t)|}{S_{ij}^{\max}} \quad (17)$$

$$\phi_{ij} = \frac{1}{T} \sum_{t=1}^{24} \frac{|L_e(t) + L_0(t)|}{E_o + Q_o} \quad (18)$$

其中 T 表示时段数量； N_G 表示支路数量；

$S_{ij}(t)$ 和 $S_{ij}^{\max}$ 分别表示线路 ij 的负荷以及

负荷最大值； $L_e(t)$ 和 $L_0(t)$ 分别表示变电

站新增和现有负荷功率； E_o 表示变电容量；

Q_o 表示额定负载率。

依据上述公式对本研究提出的方法在不同时段下规划后的配电网运行情况进行详细分析。各个时段内，线路平均负载和变电站平均负载结果，如表6所示。

表6 线路平均负载和变电站平均负载结果

时段/h	线路平均负载/%	变电站平均负载/%
3	17.6	21.3
6	18.1	24.6
9	19.3	25.7
12	16.6	20.2
15	21.2	23.9
18	20.7	24.4
21	22.2	25.6
24	19.8	27.7

对表6测试结果进行分析后得出：通过本研究提出的主动配电网规划方法，在不同运行时段下，无论是线路平均负载还是变电站平均负载，其值均保持在合理且可控的范围内，并且满足规划需求。其中，线路平均负载在16.6%至22.2%之间波动，远低于可能导致过载的阈值；而变电站平均负载则在20.2%至27.7%之间变化，同样保持在安全、经济的运行区间内。这是因为本文所设计的双层规划方法通过构建上层和下层规划函数，能够综合考虑可再生能源的不确定性以及主动配电网的经济性和可靠性。上层规划可能侧重于整体的电网结构和资源配置，而下层规划则可能更关注具体的运行策略和

优化调度。这种分层处理使得规划过程更加系统和全面，能够更好地应对可再生能源并网带来的不确定性。因此，本文提出的方法在提升可再生能源消纳能力的同时，也有效地优化了配电网的运行状态，确保了电网的稳定性和可靠性。在不同时段的运行中，电网能够灵活应对负荷变化，保持高效的能源传输和分配能力。

为验证本研究提出的考虑可再生能源消纳的主动配电网双层规划方法的应用效果，选取配电网内规划线路的传输充裕率 F_{ij} 作为衡量标准。传输充裕率定义为实际传输容量与最大传输容量之间的比值，其取值在-1 至 1 之间。当传输充裕率为正数时，表明线路的传输能力完全满足甚至超出规划需求，能够有效保障可再生能源的充分消纳及电网的稳定运行；相反，若传输充裕率为负值，则意味着线路的传输能力不足以满足规划需求，可能导致电网运行风险增加。传输充裕率计算公式为：

$$F_{ij} = \frac{S_{ij}^{\max} - S_{ij}}{S_{ij}^{\max}} \quad (19)$$

其中 S_{ij} 和 $S_{ij}^{\max}$ 分别表示线路的传输量以及传输上限。

依据上述公式获取不同线路在不同波动比例下的传输充裕率结果，如图 4 所示。




图 4 传输充裕率测试结果

对图 4 测试结果进行分析后得出：本研究提出的主动配电网规划方法在应对各种可再生能源电力波动时表现出色。本研究方法应用后该网络中所有线路的传输充裕率均维持在正数水平，并且稳定在 0.4 以上。

这一结果有力地证明了经过规划后的网络整体运行状态优秀，完全达到了预定的运行性能标准。这种优越性能的取得，主要原因在于本研究提出的方法所采用的双层规划函数及其设定的相关约束条件。不仅考虑了可再生能源的消纳能力，还兼顾了电网的稳定性、安全性以及经济性等多方面的因素，通过设定合理的约束条件，规划方案得以在优化可再生能源消纳的同时，保证电网的整体性能不会受到负面影响，从而在实际应用中能够显著提升可再生能源的消纳率，并维持电网在高效率、高稳定性和高安全性状态下的运行。

为了更全面的验证所提方法的有效性，选择文献[4]方法和文献[5]方法作为对比方法，以误差率为评估指标展示不同方法在求解性能上的显著差异。具体如表 7 所示。

表 7 不同方法的求解性能对比结果表

迭代次数	所提方法/%	文献[4]方法/%	文献[5]方法/%
100	0.32	0.43	0.48
200	0.30	0.41	0.43
300	0.26	0.38	0.40
400	0.19	0.36	0.35
500	0.13	0.33	0.31
600	0.09	0.30	0.26
700	0.07	0.27	0.20
800	0.06	0.22	0.18
900	0.05	0.15	0.12
1000	0.03	0.09	0.07

从表 7 中可以看出，随着迭代次数的增加，三种方法的误差率均呈现出下降趋势。在相同迭代次数下，三种方法误差率的大小对比为：文献[5]方法>文献[4]方法>所提方法。这可能是由于文献[5]方法在处理不确定性时采用了更为复杂的概率约束和机会约

束规划模型，导致求解过程相对复杂。文献[4]方法通过线性化计算方法和对偶理论等技术的应用，实现了模型的高效求解。因此，尽管文献[5]通过线性化方法和离散步长变换方法简化了模型，但相较于文献[4]的线性化计算方法，其计算效率可能仍受到一定影响。而所提方法采用了精英策略优化布谷鸟算法。通过更新鸟窝位置并结合精英策略进行迭代优化，能够高效地搜索满足所有约束条件的最优解。这种算法的应用使得所提方法在求解复杂规划问题时具有较高的效率和准确性。因此，当迭代次数达到 1000 次时，所提方法的误差率可以降低至 0.03%，有效的增加了规划方案的实际可行性和有效性。

由此，衡量三种方法下，主动配电网中可再生能源发电量的占比。

通过比较规划前后的可再生能源渗透率，可以评估该方法对提高可再生能源利用率的效果。如果渗透率显著增加，则说明该方法在促进可再生能源并网和消纳方面有效。得到的结果如图 5 所示。




图 5 三种方法的渗透率结果

从图 5 中可以看出，三种方法的渗透率均是从 70% 开始，随着迭代次数的增加，呈现出不同趋势的增加。其中，所提方法的渗透率可以增加到 99% 左右，增长幅度相对较快且增量较大。相比之下，文献[4]方法虽然通过引入节点净负荷可接纳域和线性化计算新方法提高了模型求解效率，但在可再生能源并网和消纳方面的优化策略不足，导致渗透率增长幅度和增量较小。而文献[5]方法主要关注经济优化调度问题，对规划层面的考虑较少，因此在提升可再生能源利用率方面也相对有限，渗透率增长同样不如所提方

法显著。这是因为所采用的精英策略优化布谷鸟算法是一种高效的优化算法，能够快速收敛并找到全局最优解。在求解双层规划目标函数时，该算法能够充分利用其搜索能力，找到最优的规划方案。因此，所提方法可以显著提高可再生能源的渗透率。

3 结束语

本文针对可再生能源大规模接入电网后带来的不确定性挑战，提出了基于可再生能源消纳的主动配电网双层规划方法。通过该方法，不仅有效应对了可再生能源出力的波动性和不确定性，还显著提升了电网对可再生能源的消纳能力，实现了高达 77.85% 的消纳率。同时，该规划方法确保了电网内各线路及变电站的负载维持在合理水平，平均线路负载低于 24.2%，变电站平均负载控制在 30% 以内，显著增强了电网的整体稳定性和运行效率。在不同波动场景下，该方法均能保持各线路传输充裕率为正且稳定在较高水平，从而全面验证了所提方法在主动配电网不确定性规划中的有效性和可靠性，为可再生能源的广泛接入和电网的安全稳定运行提供了有力支持。

参考文献

- [1] 李庆生, 李震, 孙斌, 等. 考虑源荷储协调的高弹性配电网最优负荷转供方法[J]. 中国测试, 2023, 49(10): 64-70.
LI Q S, LI Z, SUN B, et al. Optimal load transfer method of high elastic distribution network considering coordination of source-load-storage[J]. China Measurement & Testing Technology, 2023, 49(10): 64-70.
- [2] 杨东俊, 涂智福, 徐敬友, 等. 计及低碳排放和需求侧管理的主动配电网双层规划[J]. 武汉大学学报(工学版), 2022, 55(7): 709-715.
YANG D J, TU Z F, XU J Y, et al. Bi-level planning of active distribution network considering low carbon emissions and demand side management[J]. Engineering Journal of Wuhan University, 2022, 55(7): 709-715.

- [3] 李庆生,李震,孙斌,等.计及不确定性的主动配电网分布式能源多时间尺度消纳方法[J].可再生能源,2023,41(5):692-698.
LI Q S, LI Z, SUN B, et al. Multi-time scale consumption method of distributed energy in active distribution network considering uncertainty[J]. Renewable Energy Resources, 2023, 41(5): 692-698.
- [4] 刘帅,王明强,丁天池,等.考虑净负荷最佳可接纳域的主动配电网电源规划[J].电网技术,2023,47(6):2239-2254.
LIU S, WANG M Q, DING T C, et al. Generation planning of active distribution network considering optimal admissible region of net load[J]. Power System Technology, 2023, 47(6): 2239-2254.
- [5] 孟令卓超,杨锡运,赵泽宇.考虑光-荷不确定性和旋转备用约束的主动配电网经济优化调度策略[J].电力建设,2022,43(11):63-72.
MENG L Z C, YANG X Y, ZHAO Z Y. An economic optimal dispatch strategy for active distribution networks considering photovoltaic-load uncertainty and rotating reserve constraints[J]. Electric Power Construction, 2022, 43(11): 63-72.
- [6] 董雷,吴怡,张涛,等.基于强化学习的含智能软开关主动配电网双层优化方法[J].电力系统自动化,2023,47(6):59-68.
DONG L, WU Y, ZHANG T, et al. Reinforcement learning based double-layer optimization method for active distribution network with soft open point[J]. Automation of Electric Power Systems, 2023, 47(6): 59-68.
- [7] DE BARROS H F, ALVAREZ-HERAULT M C, RAISON B, et al. Optimal AC/DC distribution systems expansion planning from DSO's perspective considering topological constraints[J]. IEEE Transactions on Power Delivery, 2023, 38(5): 3417-3428.
- [8] 司威,刘慧芳,傅文进,等.计及风光不确定性的主动配电网优化调度研究[J].华中科技大学学报(自然科学版),2022,50(5):73-77+101.
SI W, LIU H F, FU W J, et al. Research on optimization scheduling of active distribution network considering uncertainty of wind and photovoltaic[J]. Journal of Huazhong University of Science and Technology(Nature Science Edition), 2022, 50(5): 73-77+101.
- [9] 朱自伟,黄彪,袁昕月,等.基于平抑风光出力波动的主动配电网优化调度[J].太阳能学报,2022,43(5):90-97.
ZHU Z W, HUANG B, QIU X Y, et al. Optimal dispatching of active distribution network based on suppressing wind and photovoltaic power fluctuation[J]. Acta Energaie Solaris Sinica, 2022, 43(5): 90-97.
- [10] 朱瑞金,龚雪娇,张娟娟.基于EEMD-MPE-LSSVM的光伏发电功率预测[J].中国测试,2021,47(9):158-162.
ZHU R J, GONG X J, ZHANG J J. Forecast of photovoltaic power generation based on EEMD-MPE-LSSVM[J]. China Measurement & Testing Technology, 2021, 47(9): 158-162.
- [11] 陈倩,王维庆,王海云.计及需求响应和混合博弈含多微网主动配电网协调优化[J].电力系统自动化,2023,47(9):99-109.
CHEN Q, WANG Q, WANG Y. Coordinated optimization of active distribution network with multiple microgrids considering demand response and mixed game[J]. Automation of Electric Power Systems, 2023, 47(9): 99-109.
- [12] 林永君,陈鑫,杨凯,等.含多微网的主动配电网双层分布式优化调度[J].系统仿真学报,2022,34(11):2323-2336.
LIN Y J, CHEN X, YANG K, et al. Bilevel

Distributed optimal dispatch of active distribution network with multi-microgrids[J]. Journal of System Simulation, 2022, 34(11): 2323-2336.

- [13]汪泽州,毛琳明,刘维亮,等.计及分布式光伏的三相不平衡低压配电网快速潮流计算[J].电子器件,2024,47(4):1065-1072.

WANG Z Z, MAO L M, LIU W L, et al. Fast power flow calculation of three-phase unbalanced low-voltage distribution network considering distributed photovoltaic[J].Chinese Journal of Electron Devices,2024,47(4):1065-1072.

- [14]刘洪达,李德全,王栋.基于种群熵的变步长布谷鸟搜索算法[J].计算机仿真,2022,39(9):370-376.

LIU H D, LI D Q, WANG D.Variable step-size cuckoo search based on population entropy[J].Computer Simulation,2022,39(9):370-376.

- [15]彭虎,李源汉,邓长寿,等.多策略调和的布谷鸟搜索算法[J].计算机工程,2022,48(8):85-97.

PENG H, LI Y H, DENG C S, et al.Multi-strategy reconciled cuckoo search algorithm[J].Computer Engineering, 2022, 48(8): 85-97.

吴国栋, 孙涛, 陈学君, 等. 蝗虫优化算法与单一预测模型在干旱区光伏功率预测中的比较研究[J]. 干旱气象, 2024, 42(5): 694-701, [WU Guodong, SUN Tao, CHEN Xuejun, et al. Comparative study of grasshopper optimization algorithm and single prediction model for photovoltaic power prediction in arid region[J]. Journal of Arid Meteorology, 2024, 42(5): 694-701], DOI:10.11755/j.issn.1006-7639-2024-05-0694

蝗虫优化算法与单一预测模型在干旱区光伏功率预测中的比较研究

吴国栋¹, 孙涛¹, 陈学君², 景慧², 闫晓敏², 李遥²

(1. 国网甘肃省电力公司, 甘肃 兰州 730030; 2. 甘肃省气象服务中心, 甘肃 兰州 730020)

摘要:为了找出适用于干旱区的更为精确的光伏功率预测方法, 基于2022年甘肃省敦煌某光伏电站的实际观测数据和数值预报资料, 利用原型预报法、短期误差订正法、逐步回归法建立3种短期光伏功率预测模型, 同时, 使用蝗虫优化算法对3种单一模型优化形成组合预测方法, 并对4种方法的预报效果进行检验和评估。结果表明, 单一预测模型中逐步回归法均方根误差、相对均方根误差均小于原型预报法、短期误差订正法, 逐步回归法的预报精度更高, 变化幅度最小, 预报效果更为稳定; 与3种单一模型相比, 经过蝗虫优化算法形成的组合预测模型预报效果有所提升, 平均均方根误差分别降低145.21、153.48和70.91 kW; 不同天气状况下, 组合预测模型均优于单一预测模型, 晴天预测效果最好。

关键词:光伏功率预测; 原型预报法; 短期误差订正法; 逐步回归法; 组合预测; 蝗虫优化算法

文章编号:1006-7639(2024)05-0694-08 DOI:10.11755/j.issn.1006-7639-2024-05-0694

中图分类号:P49

文献标志码:A

0 引言

近年来, 全球不可再生能源匮乏严重(王开艳等, 2022), 可再生能源电力的发展生成技术显得尤为重要(Wang et al., 2020), 由于太阳能具有绿色、丰富的优势, 因此它将成为最突出的替代能源(El-hadidy and Shaahid, 2000; Khare et al., 2016)。截至到2023年12月底, 我国累计发电装机容量约29.2亿kW, 其中光伏累计装机规模已达6.1亿kW, 同比增长55.2%。受天文因子、气象因素、光伏组件等诸多因素影响, 光伏发电在并网时呈现出波动性和随机性特点, 会对电网系统造成严重冲击(丁明等, 2014; 赵书强和李志伟, 2018)。因此提高光伏功率预测效果, 对电网安全调度、电力系统的功率平衡意义重大。

光伏功率预测从形式上分为点预测、区间和概

率预测(Mitrentsis and Lens, 2022)。从时效上看主要有超短期、短期及中长期预测, 其中, 超短期预测时效为0~4 h, 短期预测时效为0~48 h, 中长期预测时效为1个月甚至更长(赖昌伟等, 2019)。方法上, 主要分为物理方法(Monteiro et al., 2013)、统计和机器学习(Moreira et al., 2021; Aslam et al., 2021)模型。物理法(或者叫原理法)是结合辐射预报结果和光伏发电原理开展功率预测的间接预测方法(陈正洪等, 2011), 该方法将气象数值天气预报数据作为输入, 不需要大量的历史数据支持, 但要求电站系统元数据信息精确程度较高, 适用于无法提供大量历史数据的新建光伏电站; 统计和机器学习方法是基于历史光伏电站数据和历史天气预报数据及相关气象站数据等, 通过统计分析和机器学习建立一种输入与输出的映射关系, 常见的有自回归模型和移动平均方法(Li et al., 2016)、回归分析(Persson et

收稿日期: 2024-06-06; 改回日期: 2024-08-20

基金项目: 甘肃省重点研发计划-工业类项目(23YFGA0016)资助

作者简介: 吴国栋(1985—), 男, 甘肃白银人, 高级工程师, 主要从事新能源功率预测与调度运行管理工作。

E-mail: wugudong0943@126.com。

通信作者: 陈学君(1971—), 男, 甘肃天水人, 高级工程师, 主要从事新能源气象服务、算法研究、数据分析与处理工作。

E-mail: xuejunchen1971@163.com。

al., 2017)、人工神经网络(Yagli et al., 2019)、支持向量机(殷豪等, 2019)等方法, 此类方法需要经过质量控制的电站历史数据。随着机器学习研究的深入, 不同的机器学习方法可以适应不同的应用场景和需求。相关研究中, 李遥等(2020)在斜面辐射算法改进的基础上, 发现利用多元回归法建立的短期光伏功率预测模型的预测效果要优于经验公式法; 达选芳等(2021)利用马尔科夫链模型对有云条件下的短临辐射进行了订正预报并起到提高预报质量的作用; 韩自奋等(2022)利用自动矢量变换订正方法有效降低了河西地区的太阳辐射预报偏差。

随着可再生能源需求增长和国家政策支持, 光伏发电预测技术和方法的研究得到国内外学者的广泛重视, 而我国幅员辽阔, 光伏电站建站区域差异明显, 单一类型模型不能满足需求, 因此可针对不同区域的电站建立满足实际业务需求的多种功率预测模型(王林等, 2014)。另外, 不同的单一模型有不同的优点, 根据不同模型优势建立组合模型并优化的组合预测方法也受到广泛关注, 组合模型预测精度往往较传统单一模型有不同程度提高。如许沛华等(2021)通过 softmax 集成预报算法使每个月功率预报的合格天数提升 1~3 d; Wang 等(2015)提出了一种基于“杜鹃搜索”的混合系统, 试验结果表明, 优化后的预测系统与其他基准模型相比预测效率明显提高; 杨锡运等(2014)提出的基于熵权法的组合预测模型、赵文清等(2017)提出的 IWD-Elman 神经网络模型均表现出组合预测模型效果较单一模型明显提高。

甘肃河西地区是我国太阳能最丰富的地区之一, 年太阳总辐射量为 4 700~6 350 MJ·m⁻²(朱飙等, 2010), 与国内其他太阳能资源丰富的地区相比, 具有日照时间长、辐射量强等优势。近年来, 甘肃光伏市场规模增长迅速, 光伏单日发电出力可达 1 604 万 kW, 占当时全省总发电出力的 57%(王占东, 2024), 然而甘肃本地太阳能光伏发电预测精度仍然不能满足电网调度部门的需求。近年来, 深度学习技术各个领域取得巨大成功, 蝗虫优化算法是一种新型的元启发式算法(Saremi et al., 2017), 通过模拟蝗虫群体的觅食行为来搜索最优解, 在解决复杂的优化问题方面表现出色。鉴于此, 本研究选取甘肃省河西地区典型光伏电站, 基于原型预报法、短期误差订正法、逐步回归分析方法, 提出基于蝗虫优化算法的组合预测方法, 建立适用于光伏电站短期光伏发电功率预测模型, 并获得适用于当地的更为精确的光伏功率预测方法。

1 数据与方法

1.1 数据来源

敦煌某光伏电站位于甘肃省敦煌市七里镇光伏产业园内, 电站装机 20 000 kW, 采用倾角固定式安装方式, 于 2015 年 1 月实现并网运行。

使用的观测实况数据来自 2022 年该光伏电站, 选取 1、4、7、10 月作为典型月, 分别代表一年中冬、春、夏、秋季开展研究。所用资料包括数值预报资料 and 实况资料。数值预报资料来自甘肃省气象局区域中尺度数值模式预报“绿海”, 预报产品主要有太阳总辐射、地面风速风向、2 m 气温、相对湿度及气压, 每天 20:00(北京时, 下同)定时起报, 时间分辨率为 15 min, 空间分辨率为 9 km, 预报时效为 126 h, 所采用的预报数据时段为 17~41 h。实况资料为逐 15 min 光伏功率和太阳总辐射实况数据。资料均已经过质控, 剔除了各类异常值, 数据较完整。

1.2 评价指标

利用均方根误差和相对均方根误差对功率预测效果进行检验及对比分析, 计算公式(赵书强和李志伟, 2018)如下:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (P_f^i - P_o^i)^2} \quad (1)$$

$$RRMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (P_f^i - P_o^i)^2 / C_{ap}} \quad (2)$$

式中: RMSE(kW)为均方根误差; RRMSE 为相对均方根误差; P_f^i (kW)表示功率预测值; P_o^i (kW)表示功率实际观测值; C_{ap} (kW)为电站每日开机容量, 即所有运行逆变器容量总和; i 为样本; N 为样本总数。

1.3 方法

1.3.1 单一预测方法

1) 原型预报法

根据光伏电板的发电原理和各参数间的转换效率, 建立光伏功率转换模型, 将辐射预报代入转换模型, 实现光伏功率预测, 称为原型预报法(王林等, 2014)。转换公式(陈正洪等, 2011)如下:

$$P_{dc} = \eta_s \times [1 - \alpha(T_c - 25)] \times I_T \times S \times K_1 \times K_2 \times K_3 \times K_4 / 1000 \quad (3)$$

$$T_c = T_a + \frac{T_{NOC} - 20}{800} \times I_T \quad (4)$$

$$K_1 = 1 - k \times y_a \quad (5)$$

式中: I_T (W·m⁻²)为斜面总辐射, 采用李遥等(2020)方法进行计算; T_{NOC} (°C)为电池额定工作温度; T_a (°C)为气温; T_c (°C)为板温; P_{dc} (kW)为发电功率; η_s 为标准光电转换效率; α (°C⁻¹)为温度系数; S (m²)为

光伏组件有效面积; K_1 为老化损失系数; K_2 为损失系数,可取为0.95~0.98; K_3 为遮挡损失系数,可取为0.90~0.95; K_4 为直流线路损失系数,可取为0.95~0.98; k 为使用年数; y_a 为电池材料年衰减率。

2) 短期误差订正法

选取过去15 d历史资料,求得每天实况辐射与数值预报辐射的相关系数,取相关系数最大一天的实况与预报平均误差作为模式预报辐射的系统误差 e ,然后订正未来预报辐射: $F_{订正} = F_{预报} + e$,将订正后的预报辐射代入原型预报法的光电转换模型得出预测功率。

3) 逐步回归法

从变量中选取最重要的变量,建立回归分析预测模型。首先建立所有自变量参加的回归方程,矩阵形式可以表示为

$$Y_n = X_{n \times k} B_k + U_n \quad (6)$$

式中: Y_n (kW)表示因变量,即短期光伏功率预测结果; $X_{n \times k}$ (W·m⁻²)表示自变量,即总辐射预测结果; B_k 表示模型参数,采用最小二乘法估算得到; U_n (kW)为随机误差项; $k=1,2,\dots,p$,其中, k 为待选因子, p 为待选因子总个数; n 为样本长度。

1.3.2 组合预测算法

1) 蝗虫优化算法

受蝗虫捕食过程中种群行为启发,Mirjalili等(2018)提出蝗虫算法。这种算法收敛速度快、搜索效率高,通过简单的局部规则(觅食、迁徙)实现了复杂且高效的集体行为,较好地平衡了全局和局部搜索过程,寻优精度高,已广泛应用于生物信息学、参数调优、工程设计、电网调度等多个领域。蝗虫种群行为的数学模型为

$$X_i = S_i + G_i + A_i \quad (7)$$

$$S_i = \sum_{j=1, j \neq i}^N s(d_{ij}) \hat{d}_{ij} \quad (8)$$

式中: X_i 是蝗虫种群中第 i 个蝗虫的位置; S_i 是第 i 个蝗虫受到其他蝗虫相互作用力的影响; G_i 是第 i 个蝗虫受到的重力影响,实际应用中,重力对蝗虫种群的影响微小可以忽略; A_i 是第 i 个蝗虫受到的风力影响,应用中假设风向始终为最佳个体位置所在方向; d_{ij} 是第 i 和第 j 个蝗虫之间的距离; $\hat{d}_{ij}$ 是单位向量,表示为 $\hat{d}_{ij} = \frac{(x_j - x_i)}{d_{ij}}$;影响函数 S 表示与其他蝗虫的相互作用力,公式为 $s_r = fe^{-\frac{r}{l}} - e^{-r}$, f 是吸引强度参数; l 为吸引长度比例参数; r 是第 i 和第 j 个蝗虫之间的距离。

蝗虫位置的更新模型可表示为

$$x_i^d(t+1) = c \times \left\{ \sum_{j=1, j \neq i}^N c \frac{ub_d - lb_d}{2} s(|x_j^d(t) - x_i^d(t)|) \frac{x_j^d(t) - x_i^d(t)}{d_{ij}} \right\} + T_d \quad (9)$$

式中: ub_d 、 lb_d 分别为蝗虫在 d 维度上的位置上、下界; T_d 是当前种群中精英个体的具体位置; c 为线性衰减系数, $c = c_{\max} - l \times \frac{c_{\max} - c_{\min}}{L}$ 。随着迭代次数逐步增加,参数 c 减小了算法全局寻优能力,同时提高了局部搜索能力。

蝗虫优化算法流程参见图1。




图1 蝗虫优化算法流程图

Fig. 1 Flowchart of grasshopper optimization algorithm

2) 组合预测算法

利用蝗虫优化算法对3种单一预测模型(短期误差订正法、原型预报法、逐步回归法)结果进行优化,初始化权重空间,以最小均方根误差为目标函数,利用训练集通过蝗虫优化算法优化每个模型相应权重,从而确定组合预测结果。通过对3种单一光伏功率预测算法结果搜索最优权重,从而建立短期光伏功率组合预测模型,实现蝗虫优化算法在光伏功率预测中的应用。

具体步骤:利用各单一预测方法分别对预测日的光伏功率进行预测;根据训练数据,通过蝗虫优化算法获得其权重值 ω_i ;根据各单一预测方法的预

测值,通过公式 $f=\sum_{i=1}^N\omega_i f_i$ 完成光伏功率组合预测,其中, f 为短期光伏功率组合预测结果; f_i 为第 i 个单一预测方法的短期光伏功率预测结果; ω_i 为第 i 个单一预测方法的加权系数; $i=1,2,\dots,N$; $\sum_{i=1}^N\omega_i=1,\omega_i\geq 0$ 。

2 结果分析

根据原型预报法、短期误差订正法、逐步回归法以及基于单一模型的组合预测法,计算得到2022年1、4、7、10月典型月份甘肃某光伏电站的逐15 min短期功率预测结果。下文以 P_r 表示实况功率, P_1 、 P_2 、 P_3 、 P_4 分别表示短期误差订正法、原型预报法、逐步回归法、组合预测法的短期功率预测结果。

2.1 模型预测效果对比

对比3种单一模型的功率预测效果(表1)发现,典型月份 P_3 的RMSE和RRMSE均小于 P_1 、 P_2 , P_1 、 P_2 、 P_3 的RMSE平均值分别为2 057.73、2 066.00和1 983.43 kW,RRMSE平均值分别为0.102 9、0.103 3

和0.099 1,三者标准差没有太大变化。总体来说,逐步回归法的预报效果优于短期误差订正法和原型预报法。

分析典型月份3种单一模型预测结果的RRMSE变化特征,可以看出,三者全年均呈现波动变化趋势,由于辐射及温度变化在夏季较为剧烈,导致 P_1 、 P_2 在7月的预测结果误差增大,而1、4、10月3种模型RRMSE变化幅度相对较小。 P_3 与 P_1 、 P_2 的RRMSE差值最小和最大的月份为1月和4月,差值分别为0.000 17和0.012 14;7月三者RRMSE均出现峰值; P_1 、 P_2 月份之间的差异更明显。

对比单一模型和组合预测模型预测效果(表1)发现,典型月份 P_4 的RMSE均小于3种单一模型,其典型月份RMSE均值为1 912.52 kW,RRMSE均值为0.095 6,也均小于3种单一模型,说明组合模型的预报效果优于单一模型。

4月4种预测方法的RMSE相差最大, P_4 与 P_1 、 P_2 、 P_3 分别相差-432.77、-434.76、191.19 kW;7月相差最小,分别为-29.76、-26.19、-6.42 kW。

表1 4种模型的功率预测检验结果
Tab. 1 Power prediction test results of four models

时间	RMSE/kW				RRMSE			
	P_1	P_2	P_3	P_4	P_1	P_2	P_3	P_4
2022年1月	1 722.99	1 733.70	1 718.65	1 638.71	0.086 1	0.086 7	0.085 93	0.081 90
2022年4月	2 126.74	2 128.73	1 885.16	1 693.97	0.106 3	0.106 4	0.094 26	0.084 70
2022年7月	2 242.34	2 238.77	2 219.00	2 212.58	0.112 1	0.111 9	0.111 00	0.110 60
2022年10月	2 138.86	2 162.80	2 110.89	2 104.81	0.106 9	0.108 1	0.105 50	0.105 20
平均值	2 057.73	2 066.00	1 983.43	1 912.52	0.102 9	0.103 3	0.099 10	0.095 60
标准差	229.11	226.26	224.73	288.53	0.011 5	0.011 3	0.011 20	0.014 40

注: P_1 、 P_2 、 P_3 、 P_4 分别表示短期误差订正法、原型预报法、逐步回归法、组合预测法的短期功率预测结果。

2.2 组合预测模型预测结果分析

对比组合预测模型的预测结果和实况功率的平均日变化特征(图2),发现各季节 P_4 与 P_r 变化趋势保持一致,均表现出单峰结构。其中,冬季的日照时数最短,导致曲线开口最小,春季和夏季由于日照时数最长,电站日平均光伏出力时间也最长,曲线开口程度大于其他两个季节,而秋季日照时数介于春夏季和冬季之间。春季实况功率峰值最大,冬季次之,秋季峰值最低。

组合预测模型预测结果(P_4)与实况功率(P_r)的偏差程度在各季节存在明显差异,干旱地区夏季太阳辐射变化较为剧烈,因此夏季两者日偏差最大,

日最大偏差为1 369.4 kW;而秋季偏差最小,日最大偏差为1 204.4 kW,主要由于太阳辐射的实际变化趋势没有被模式准确预报,使得光伏功率预测存在较大偏差。

2.3 不同天气条件下4种预测方法对比

由于研究所选光伏电站位于河西西部,气候上属于干旱区,以晴天和多云天居多,降水和沙尘天气较少。因此将2022年典型月份按天气条件进行分类,主要分为晴天、多云天、雨天和沙尘天,对比分析不同天气条件下4种预测方法的预报效果。

图3为不同天气条件下4种预测模型预测结果

与光伏功率实际出力的对比。可以看出,晴天时,各模型均能准确预测实际发电出力的变化趋势,其中组合预测模型预测结果(P_4)与实况最吻合,逐步回归方法的预测结果(P_3)次之;多云条件时,组合预

测模型能够大概预测出实际功率的变化趋势,但不能准确预测;雨天、沙尘天气时,4种预测模型均无法预测出实际功率的变化趋势和变化幅度,预测效果不理想。




图2 不同季节组合预测模型预测结果与实况功率的日变化对比

(a)春季, (b)夏季, (c)秋季, (d)冬季

Fig. 2 Comparison of diurnal variation between prediction results of combination prediction model and actual power in different seasons

(a) spring, (b) summer, (c) autumn, (d) winter




图3 不同天气条件下4种预测模型预测结果与实况功率对比

(a)晴天, (b)多云, (c)雨天, (d)沙尘天

Fig. 3 Comparison between prediction results of four prediction models and actual power under different weather conditions

(a) sunny day, (b) cloudy day, (c) rainy day, (d) dust day

3 讨 论

通过本文研究结果可看出使用蝗虫优化算法形成的组合预测模型,整体上基本满足提高甘肃本地太阳能光伏发电预测精度的需求,而3种单一模型在不同季节、不同天气过程上各有优势。

3种单一模型(原型预报法、短期误差订正法、逐步回归法)相比较,短期误差订正法和原型预报法相对于逐步回归法预报效果较差,回归法预报更稳定。从建模的机理上来说,逐步回归法是典型的统计方法(Li et al., 2016),原型预报法属于物理方法(陈正洪等, 2011),短期误差订正法属于误差结果补偿的方法(秦正坤, 2007)。后两种方法均存在天气剧烈变化时,天气要素对建模影响较大的情况,故而逐步回归法预报效果更稳定。由于云量作为影响地面辐照量的主要气象要素,其生消和移动是地面辐照度不确定性变化的根本原因之一,不同天气条件的预测结果也表明这一点。故而在单一模型预测中增加卫星云图的识别,进而提高辐射的预报准确率,这对单一模型光伏发电出力的预测非常重要。

使用蝗虫优化算法形成的组合模型优于单一模型,这是由于组合模型综合了各个单一模型的优点(综合均方根误差最小),并体现出蝗虫优化算法收敛速度快、精度高、简单易实现等特点(曾庆丰等, 2024)。而由于单一模型不同季节的预报效果不同,导致组合模型的预报效果与单一模型相比在不同季节有一定差异。有重大天气过程时,4种预测模型均无法准确预测光伏发电出力的实际变化趋势,其根本原因在于发生重大天气过程时,数值预报稳定性及准确性无法满足需求。由于组合预测模型是基于3种单一模型的预测,因此单一模型的预测能力对组合模型有非常重要的作用,提升单一模型或增加新的单一预测模型会进一步提升组合模型的预测能力,这也是下一步研究的方向。本研究采用蝗虫优化算法对3种单一模型进行组合优化,通过搜索最优解,建立组合预测模型,避免了单一模型的不稳定性。目前在光伏功率预测中业务应用的模型有统计模型,也有机器学习算法,可以将多种模型和算法进行组合优化,建立最优模型以提高光伏功率预测准确率。但该方法对于3种以上的单一模型优化效果是否依然稳定还需要深入的研究与分析。另外,蝗虫优化算法在其他天气复杂多变的电站是否适用也是今后需要继续开展相关研究与分析的另一项工作。

4 结 论

本文基于2022年甘肃省敦煌某光伏电站的实际观测数据和数值预报资料,利用原型预报法、短期误差订正法、逐步回归法建立3种短期光伏功率预测模型,同时,使用蝗虫优化算法对3种单一模型优化形成组合预测方法,并对4种方法的预报效果进行检验和评估,得到如下结论。

1)原型预报法、短期误差订正法、逐步回归法建立的3种短期光伏功率预测模型预测结果的平均RRMSE分别为0.102 9、0.103 3、0.099 1,逐步回归法典型月份预测结果的RMSE、RRMSE均小于原型预报法及短期误差订正法,且其RRMSE变化幅度最小,说明逐步回归法的预报精度更高且预报效果更稳定。

2)使用蝗虫优化算法形成的组合预测模型与3种单一模型相比,预报效果最优。原型预报法、短期误差订正法、逐步回归法典型月份平均RMSE分别为2 057.73、2 066.00、1 983.43 kW,而组合预测模型典型月份平均RMSE为1 912.52 kW。

3)组合预测模型预测功率的平均日变化曲线均呈单峰结构,预测的总体趋势与实况功率趋势一致,但峰值与开口程度存在明显的季节性差异。

4)不同天气状况下,组合预测模型均优于单一预测模型,晴天预测效果最好。但在雨天、沙尘天气时原型预报法、短期误差订正法、逐步回归法和组合预测模型预测效果均不理想。

参考文献:

- 陈正洪,李芬,成驰, 2011. 太阳能光伏发电预报技术原理及其业务系统[M]. 北京: 气象出版社.
- 达选芳,李照荣,王小勇,等, 2021. 有云条件下太阳辐射短临预报订正技术研究[J]. 干旱气象, 39(6): 1 006-1 016.
- 丁明,王伟胜,王秀丽,等, 2014. 大规模光伏发电对电力系统影响综述[J]. 中国电机工程学报, 34(1): 1-14.
- 韩自奋,颜鹏程,李扬,等, 2022. 基于短期历史资料的河西地区太阳辐射预报订正研究[J]. 干旱气象, 40(1): 125-134.
- 赖昌伟,黎静华,陈博,等, 2019. 光伏发电出力预测技术研究综述[J]. 电工技术学报, 34(6): 1 201-1 217.
- 李遥,李照荣,王小勇,等, 2020. 基于斜面辐射算法的短期光伏功率预测方法研究[J]. 干旱气象, 38(5): 869-877.
- 秦正坤, 2007. 短期气候数值预测的误差订正和超级集合方法研究[D]. 南京: 南京信息工程大学.
- 王开艳,杜浩东,贾嵘,等, 2022. 基于相似日聚类 and QR-

- CNN-BiLSTM模型的光伏功率短期区间概率预测[J]. 高电压技术, 48(11): 4 372-4 388.
- 王林, 陈正洪, 唐俊, 2014. 太阳能光伏发电预报方法的应用效果检验与评价[J]. 气象, 40(8): 1 006-1 012.
- 王占东, 2024. 甘肃光伏单日发电量突破1亿千瓦时创历史新高[N]. 甘肃日报, 2024-03-10(2).
- 许沛华, 陈正洪, 孙延维, 等, 2021. 湖北山区复杂地形条件下风电功率预报算法研究[J]. 干旱气象, 39(3): 524-532.
- 杨锡运, 刘欢, 张彬, 等, 2014. 基于熵权法的光伏输出功率组合预测模型[J]. 太阳能学报, 35(5): 744-749.
- 殷豪, 陈云龙, 孟安波, 等, 2019. 基于二次自适应支持向量的光伏输出功率预测[J]. 太阳能学报, 40(7): 1 866-1 873.
- 曾庆丰, 蔡延光, 胡城, 等, 2024. 蝗虫优化算法综述[J]. 自动化与信息工程, 45(1): 1-11.
- 赵书强, 李志伟, 2018. 考虑可再生能源出力不确定性的多能源电力系统日前调度[J]. 华北电力大学学报: 自然科学版, 45(5): 1-10.
- 赵文清, 郭丙旭, 李刚, 等, 2017. 基于智能水滴算法优化Elman神经网络的光伏电站输出功率预测[J]. 太阳能学报, 38(6): 1 553-1 559.
- 朱颀, 李春华, 方锋, 2010. 甘肃省太阳能资源评估[J]. 干旱气象, 28(2): 217-221.
- ASLAM S, HERODOTOU H, MOHSIN S M, et al, 2021. A survey on deep learning methods for power load and renewable energy forecasting in smart microgrids[J]. Renewable and Sustainable Energy Reviews, 144: 110992. DOI: 10.1016/j.rser.2021.110992.
- ELHADIDY M A, SHAAHID S M, 2000. Parametric study of hybrid (wind+solar+diesel) power generating systems[J]. Renewable Energy, 21(2): 129-139.
- KHARE V, NEMA S, BAREDAR P, 2016. Solar-wind hybrid renewable energy system: A review[J]. Renewable and Sustainable Energy Reviews, 58: 23-33.
- LI Y T, HE Y, SU Y, et al, 2016. Forecasting the daily power output of a grid-connected photovoltaic system based on multivariate adaptive regression splines [J]. Applied Energy, 180: 392-401.
- MIRJALILI S Z, MIRJALILI S, SAREMI S, et al, 2018. Grasshopper optimization algorithm for multi-objective optimization problems[J]. Applied Intelligence, 48(4): 805-820.
- MITRENTSIS G, LENS H, 2022. An interpretable probabilistic model for short-term solar power forecasting using natural gradient boosting[J]. Applied Energy, 309: 118473. DOI: 10.1016/j.apenergy.2021.118473.
- MONTEIRO C, SANTOS T, FERNANDEZ-JIMENEZ L, et al, 2013. Short-term power forecasting model for photovoltaic plants based on historical similarity[J]. Energies, 6(5): 2 624-2 643.
- MOREIRA M O, BALESTRASSI P P, PAIVA A P, et al, 2021. Design of experiments using artificial neural network ensemble for photovoltaic generation forecasting [J]. Renewable and Sustainable Energy Reviews, 135: 110450. DOI:10.1016/j.rser.2020.110450.
- PERSSON C, BACHER P, SHIGA T, et al, 2017. Multi-site solar power forecasting using gradient boosted regression trees[J]. Solar Energy, 150: 423-436.
- SAREMI S, MIRJALILI S, LEWIS A, 2017. Grasshopper optimisation algorithm: Theory and application [J]. Advances in Engineering Software, 105: 30-47.
- WANG F, XUAN Z M, ZHEN Z, et al, 2020. A day-ahead PV power forecasting method based on LSTM-RNN model and time correlation modification under partial daily pattern prediction framework[J]. Energy Conversion and Management, 212: 112766. DOI:10.1016/j.enconman.2020.112766.
- WANG J Z, JIANG H, WU Y J, et al, 2015. Forecasting solar radiation using an optimized hybrid model by Cuckoo Search algorithm[J]. Energy, 81: 627-644.
- YAGLI G M, YANG D Z, SRINIVASAN D, 2019. Automatic hourly solar forecasting using machine learning models[J]. Renewable and Sustainable Energy Reviews, 105: 487-498.

Comparative study of grasshopper optimization algorithm and single prediction model for photovoltaic power prediction in arid region

WU Guodong¹, SUN Tao¹, CHEN Xuejun², JING Hui², YAN Xiaomin², LI Yao²

(1. *State Grid Gansu Electric Power Company, Lanzhou 730030, China;*

2. *Gansu Provincial Meteorological Service Center, Lanzhou 730020, China*)

Abstract: In order to find a more accurate photovoltaic power prediction method to be suitable for arid areas, based on the actual observed data and numerical forecasting information from a photovoltaic power station in Dunhuang, Gansu Province in 2022, three short-term photovoltaic power forecasting models were established by using the prototype prediction method, short-term error correction method and stepwise regression method. At the same time, a grasshopper optimization algorithm was used to optimize the three single models to form a combined prediction method. The forecasting effects of the four methods were tested and evaluated. The results show that the root-mean-square error and relative root-mean-square error of the stepwise regression method are smaller than those of the prototype prediction method and the short-term error correction method, and the prediction accuracy of the stepwise regression method is higher, the fluctuation range is smallest, and the prediction effect is more stable. Compared with the three single models, the combined prediction model formed by the grasshopper optimization algorithm has improved the prediction effect, and the average root-mean-square error is reduced by 145.21, 153.48 and 70.91 kW, respectively. Under different weather conditions, the combined forecasting model is superior to the single forecasting model, and the forecasting effect is the best under sunny weather condition.

Key words: photovoltaic power prediction; prototype forecasting method; short-term error correction method; stepwise regression method; combined prediction; grasshopper optimization algorithm

(责任编辑:王涓力;校对:黄小燕)



自动化技术与应用
Techniques of Automation and Applications
ISSN 1003-7241, CN 23-1474/TP

《自动化技术与应用》网络首发论文

题目：基于双层调度模型和需求分析的新能源电网规划优化研究
作者：吴国栋，李晓虎，王晟，包广清
网络首发日期：2024-12-18
引用格式：吴国栋，李晓虎，王晟，包广清. 基于双层调度模型和需求分析的新能源电网规划优化研究[J/OL]. 自动化技术与应用.
<https://link.cnki.net/urlid/23.1474.tp.20241218.1155.054>



网络首发：在编辑部工作流程中，稿件从录用到出版要经历录用定稿、排版定稿、整期汇编定稿等阶段。录用定稿指内容已经确定，且通过同行评议、主编终审同意刊用的稿件。排版定稿指录用定稿按照期刊特定版式（包括网络呈现版式）排版后的稿件，可暂不确定出版年、卷、期和页码。整期汇编定稿指出版年、卷、期、页码均已确定的印刷或数字出版的整期汇编稿件。录用定稿网络首发稿件内容必须符合《出版管理条例》和《期刊出版管理规定》的有关规定；学术研究成果具有创新性、科学性和先进性，符合编辑部对刊文的录用要求，不存在学术不端行为及其他侵权行为；稿件内容应基本符合国家有关书刊编辑、出版的技术标准，正确使用和统一规范语言文字、符号、数字、外文字母、法定计量单位及地图标注等。为确保录用定稿网络首发的严肃性，录用定稿一经发布，不得修改论文题目、作者、机构名称和学术内容，只可基于编辑规范进行少量文字的修改。

出版确认：纸质期刊编辑部通过与《中国学术期刊（光盘版）》电子杂志社有限公司签约，在《中国学术期刊（网络版）》出版传播平台上创办与纸质期刊内容一致的网络版，以单篇或整期出版形式，在印刷出版之前刊发论文的录用定稿、排版定稿、整期汇编定稿。因为《中国学术期刊（网络版）》是国家新闻出版广电总局批准的网络连续型出版物（ISSN 2096-4188，CN 11-6037/Z），所以签约期刊的网络版上网络首发论文视为正式出版。

基于双层调度模型和需求分析的新能源电网规划优化研究

吴国栋^{1,2}, 李晓虎², 王 晟³, 包广清¹

(1. 兰州理工大学, 电气工程与信息工程学院, 甘肃 兰州 730030;

2. 甘肃省电力公司, 甘肃 兰州 730030;

3. 甘肃省电力公司电力科学研究院, 甘肃 兰州 730030)

摘 要:随着大规模的新能源并网, 电力系统的结构、形态等发生了根本性改变, 其电网规划难度逐渐提高。针对此现状, 研究提出一种基于双层调度模型和需求分析的新能源电网规划优化模型。该模型将电网调度优化分为两层结构, 上层结构中将用户对电价的需求以及响应纳入规划中。下层结构中主要考虑新能源发电的成本消耗, 将其作为下层目标函数。结果表明, 研究设计的模型能够有效降低运行成本, 并减小负荷波动, 具体表现在其运行成本仅为7584.88万元, 最优消纳率达到了83.47%, 峰、谷时段负荷差为165.87 MW。研究设计模型能够有效提高新能源的利用效率, 降低成本。

关键词: 双层调度模型; 需求分析; 新能源电网; 规划; 优化; 消纳率

中图分类号: TP18 文献标识码: A

New Energy Grid Planning Optimization Based on Two-layer Scheduling Model and

Demand Analysis

WU Guo-dong^{1,2}, LI Xiao-hu², WANG Sheng³, BAO Guang-qing¹

(1. College of Electrical and Information Engineering, Lanzhou University of Technology,

Lanzhou 730030 China;

2. State Grid Gansu Electric Power Company, Lanzhou 730030 China;

3. State Grid Gansu Electric Power Company Electric Power Science Research Institute, Lanzhou 730030 China)

Abstract: With the large-scale new energy connected to the grid, the structure and form of the power system have undergone fundamental changes, and the difficulty of grid planning is gradually increased. In view of this situation, a new energy grid planning optimization model based on double-layer scheduling model and demand analysis are proposed. The model divides the optimization of power grid scheduling into two layers, and the upper structure includes the demand and response of users to the electricity price into the planning. In the lower structure, the cost consumption of new energy generation is considered as the lower objective function. The results show that the model can effectively reduce the operating cost and load fluctuation, which is shown in that the operating cost is only 75.8488 million yuan, the optimal absorption rate reaches 83.47%, and the load difference between peak and valley is 165.87 MW. The research and design model can effectively improve the utilization efficiency of new energy and reduce the cost.

Keywords: two-layer scheduling model; demand analysis; new energy grid; planning; optimization; absorption rate

0 引言

随着全球气候变暖和环境问题日益突出, 可再生能源的利用成为各国政府和科研机构关注的重点。新能源, 如太阳能、风能等, 作为清洁、可再生的能源形式, 具有巨大的发展潜力和应用前景^[1]。然而, 新能源并网给传统电网带来了新的挑战, 分布式新能源的并网, 改变了电力系统的结构、形态与运行控制方式^[2]。而风、光等新能源具有较强的不确定性, 其出力受天气、季节等多种因素影响, 给电网的稳定运行和调度带来

了极大的困难。此外, 新能源的大规模并网还会引起电网电压波动、谐波污染等问题, 进一步加剧了电网规划的难度^[3]。为解决新能源发电系统的能源利用率低, 规划难的问题, 国内外学者们展开了深入研究。王文烨等人为解决风光等能源的并网造成的电力系统调度困难问题, 提出了一种含规模氢能综合利用的分布式新能源电力系统调度方法。该方法提出氢能和火电结合的补偿策略, 进一步提高系统消纳率。结果表明, 该调度方法能够有效促进新能源发电消纳和

基金项目: 国网甘肃省电力科学科技项目 (52272223004X)

备用能力^[4]。SinghE等人为提高风力发电系统的利用率以及电力系统的发电质量,提出了一种基于遗传算法和斐波那契方法的双层调度优化框架。该框架通过估计机组故障时间来对电力系统的调度进行优化。结果表明,该调度方法能够提高新能源发电的利用率^[5]。综合上述内容可知,分布式新能源电网的调度主要选择两种能源的组合方式,对于三个或三个以上新能源的电网调度问题研究较少。且目前的电网规划调度方法主要从能源自身特性出发,通过补偿机制保持系统发电稳定。但很少研究考虑从用户需求的响应角度实现用户用电量调度。针对此现状,研究提出了一种基于双层调度模型和需求分析的新能源电网规划优化模型。该模型通过对多能源发电系统的需求响应进行建模,之后利用双层调度模型对配电网进行调度规划。研究旨在构建一个新能源电网规划

模型,提高新能源的利用率,实现发电系统的调度优化。研究的创新性在于针对风光水火多能源的调度问题进行分析。同时从用户角度建立对应的需求响应模型,进一步提高配电网的能源利用率。

1 基于双层调度模型和需求分析的电网规划优化

1.1 风光水火多能源发电系统建模及需求分析

风光水火多能源发电系统结合了风能、太阳能、水能以及火力发电等多种能源形式,通过互补优化调度,提高了能源利用效率和系统稳定性^[6-8]。为了更好地进行新能源电网规划优化,首先需要对风光水火多能源发电系统进行建模,并深入分析其需求特性。四种发电方式的流程如图1所示。




图1 风光水电多能源发电的流程

风电出力预测值主要由风速来决定,其输出功率的计算方法如式(1)所示。

$$P_w = \begin{cases} 0, & 0 \leq v < v_{in} \\ P_r \frac{v - v_{in}}{v_r - v_{in}}, & v_{in} \leq v < v_r \\ P_r, & v_r \leq v < v_0 \\ 0, & v \geq v_0 \end{cases} \quad (1)$$

式(1)中, v_0 和 v_{in} 分别为切出和切入风速, v_r 为研究设定的风速阈值, P_r 为设定功率阈值, P_w 为风力发电功率。光伏发电的输出功率计算方法如式(2)所示。

$$P_{pv,t} = P_{STC} \frac{G G_t}{G_{STC}} [1 + k(T_{c,t} - T_{STC})] N_s N_p \quad (2)$$

式(2)中, P_{STC} 为标准条件下输出功率, G 为总太阳辐射量, G_t 和 G_{STC} 为当前时刻的太阳辐射量和标准条件下的太阳辐射量, k 为功率-温度系数, $T_{c,t}$ 和 T_{STC} 分别为光伏电池的表面温度和标准条件下光伏电池温度, N_s 和 N_p 为光伏阵列串联单元和并联单元

的数量。水力发电的输出功率计算方法如式(3)所示。

$$P_{h,t} = \frac{A V h_t \eta_t}{t} \quad (3)$$

式(3)中, A 为水电转换常数, 研究将其设为9.8, V 为发电引用流量, h_t 为上下游水位差, t 为当前时刻, η_t 为水力发电机效率。为保障新能源发电系统的安全稳定运行, 促进可再生能源高效消纳, 研究选择可控煤电机组作为调峰电源。为进一步提高系统的运行稳定性, 研究在多能源发电系统中引入储能系统, 在接入电网时对发电高峰和低峰进行调节^[9-10]。最优消纳率的计算方法如式(4)所示。

$$\begin{cases} \min F(P_{net}) \\ P_{net} = P_D - \lambda_w P_w - \lambda_{pv} P_{pv} \end{cases} \quad (4)$$

式(4)中, P_{net} 为电力系统的净负荷, $F(\cdot)$ 为电力系统的运行成本, λ_w 为风电场的输

出功率消纳率, λ_{pv} 为光伏机组的输出功率消纳率。虽然引入消纳率之后能够有效调整能源, 进一步降低调节压力。但在用电高峰时段, 此调节策略效果并不够理想。针对此, 研究引入价格需求响应模型, 通过调整电价进而引导用户的用电行为, 进一步降低高峰期的用电负荷。在电价调整过程中, 研究需要对用电量变化程度进行计算, 进一步对电价调整幅度进行优化。衡量变化程度的参数为价格弹性系数, 其计算方法如式 (5) 所示。

$$\varepsilon = \frac{\Delta q}{q} \frac{p'}{\Delta p'} \quad (5)$$

式 (5) 中, q 为电价调整前的价格, Δq 为调整后电价变化, p' 为电价调整前的负荷, ε 为弹性系数, $\Delta p'$ 为调整后负荷变化。研究根据用户的用电习惯将一天24小时分为三个阶段, 分别表示用电高峰, 用电低峰和用电平峰。具体划分情况以及电价调控应用到电力系统中的流程如图2所示。




图2 电负荷具体划分情况以及电价调控应用到电力系统中的流程

在通过电价调节用电量的过程中有两种需求响应, 分别为自响应和互响应。自响应是电价较高时, 用户自觉减少用电行为的响应。而互响应是电价从高降低时用户的用电行为。两种行为下的弹性系数分别为自弹性系数和互弹性系数。价格调整后, 各个时段的负荷情况如式 (6) 所示。

$$P_{de,t} = \begin{bmatrix} P_{ef} \\ P_{ep} \\ P_{eg} \end{bmatrix} + \begin{bmatrix} P_{ef} & 0 & 0 \\ 0 & P_{ep} & 0 \\ 0 & 0 & P_{eg} \end{bmatrix} E \begin{bmatrix} \frac{\Delta q_f}{q} \\ \frac{\Delta q_p}{q} \\ \frac{\Delta q_g}{q} \end{bmatrix} \quad (6)$$

式 (6) 中, P_{ef} 、 P_{ep} 、 P_{eg} 为响应前峰、平、谷时段的负荷, ΔP_f 、 ΔP_p 和 ΔP_g 为三个时段的总电价转移量。

1.2 基于双层调度模型的电网规划优化

在建立完新能源发电机组的模型并根据需求分析提出电网规划的考虑因素后, 研究将风光火电多能源发电系统的优化调度模型分为两层。上层通过电价需求响应以及消纳率实现电力系统净负荷方差最小、负荷波动率最小的目标函数。下层通过对新能源

发电系统的输电功率以及机组使用情况进行控制, 进一步降低系统的运行成本。研究设计的双层调度模型如图3所示。




图3 考虑价格需求以及消纳率的双层优化调度模型

如图3所示, 研究设计的双层调度优化模型中有三个不同的目标函数, 通过对消纳率、电价、系统功率等进行约束实现。其中净负荷指火电机组负荷量, 该目标函数的计算方法如式 (7) 所示。

$$\min F_1 = \frac{1}{T} \sum_{t=1}^T (P_{net,t} - P_{net,ave})^2 \quad (7)$$

式 (7) 中, T 为整个调度周期, $P_{net,t}$ 为该时段电力系统的净负荷, $\min F_1$ 为净负荷方

差最小目标函数, $P_{net,ave}$ 为整个调度周期内净负荷的平均值。上层的另一个目标函数是负荷波动率最小函数。为实现此目标, 研究从负荷侧进行考虑, 引入价格型需求响应。该目标函数如式 (8) 所示。

$$\min F_2 = \min \left(\sum_{t=1}^T (P_{D,t+1} - P_{D,t})^2 \right) \quad (8)$$

式 (8) 中, $P_{D,t}$ 和 $P_{D,t+1}$ 分别为实施价格型需求响应技术后 t 时段和 $t+1$ 时段的电负荷值, $\min F_2$ 为负荷波动率最小目标函数。通过对峰、平、谷三个时段的电价改变, 引导用户在价格信号的驱动下, 将用电需求从高峰时段转移至平、谷时段, 从而降低负荷波动率。由此在满足电网运行成本的前提下, 有效降低系统的净负荷方差和负荷波动率, 提高电网的稳定性和经济性。研究对三个时段的电价进行约束, 确保三个时段的电量转移保持平衡, 相加为0; 此外还需要保证转移量不能超过设定的阈值范围^[11-12]。除了对转移电量进行约束之外, 研究对用电支出以及用电过程的使用满意度进行约束。具体的约束如式 (9) 所示。

$$\begin{cases} M_s \leq 1 - \frac{\sum_{t=1}^T |\Delta P_t|}{\sum_{t=1}^T P_{et}} \\ M_p \leq 1 - \frac{\sum_{t=1}^T |\Delta q'_t|}{\sum_{t=1}^T q'_{et}} \end{cases} \quad (9)$$

式 (9) 中, M_s 和 M_p 分别为对电费支出的满意度以及用电过程的使用体验满意度, P_{et} 和 ΔP_t 分别为设施价格型需求响应前后的负荷和变化量, q'_{et} 和 $\Delta q'_t$ 为实施价格需求

响应前后的电价和电价改变量。下层优化调度模型以电力系统总运行成本为优化目标, 具体如式 (10) 所示。

$$\min F_3 = C_1 + C_2 + C_3 + C_4 + C_5 - C_6 \quad (10)$$


式 (10) 中, $C_1 \sim C_6$ 依次为几个新能源的发电成本、火力发电以及调峰成本、备用系统及维修成本、储能成本、环境保护费用、收益情况, $\min F_3$ 为电力系统总运行成本最小化目标函数。电力系统在运行过程中需要保持稳定性, 因此, 研究对输电负荷进行约束, 具体如式 (11) 所示。

$$0 \leq P_{L,t} \leq P_{L,max} \quad (11)$$


式 (11) 中, $P_{L,t}$ 为 t 时段线路的输电功率, $P_{L,max}$ 为线路的最大输电容量。综合上述内容, 研究建立了风光水火多能源发电机组的数学模型, 并通过需求分析选择了消纳率以及价格需求响应作为调度优化模型的主要考虑条件。之后建立了共计三个目标函数的双层优化调度模型。进一步实现了多能源电力系统的调度规划优化。

2 基于双层调度模型的新能源电网规划优化模型性能分析

为检验研究设计的基于双层调度模型的新能源电网规划优化模型的性能, 研究选取A地多能源发电系统的历史发电数据作为仿真软件的输入, 在MATLAB/Simulink中通过编程对风光水火多能源发电系统进行仿真。研究将电力系统中增加了储能系统以进一步提高新能源发电的消纳率。针对此, 研究对考虑储能前后风光发电的最优消纳率变化情况以及考虑消纳率调度前后运行成本的变化情况进行记录, 具体如图4所示。



(a) 引入储能系统前后最优消纳率曲线



(b) 考虑消纳率前后运行成本变化

图4 考虑储能前后风光发电的最优消纳率变化情况以及考虑消纳率调度前后运行成本的变化情况

如图4(a)所示,在引入储能系统之前,风电系统的消纳率在0点~4点期间的消纳率相对较低,在引入之后,其消纳率得到了明显提高。对于光伏发电来说,在16点~19点期间,其消纳率接近0,而引入储能系统后出现明显提高。如图4(b)所示,考虑新能源的最优消纳率后,各成本得到了显著降

低。为降低电力系统的净负荷波动率,研究引入了价格需求响应到调度模型中。为检验需求响应在调度模型中的应用价值,研究对比考虑需求响应前后系统的净负荷曲线变化情况同时记录各机组的输出功率。具体结果如图5所示。




图5 考虑需求响应前后系统的净负荷曲线变化情况及各机组输出功率

如图5(a)所示,在考虑需求响应之后,负荷峰谷差缩小了165.48kW。且在电负荷低谷时段,其等效负荷增加了21.66MW。如图5(b)所示,经过需求响应后,水电机组出力仅在早上九点至中午12点。火电机组仅在电负荷午高峰以及晚高峰开机运行。综合上述内容可知,引入需求响应之后,能够有效引导用户用电行为,实现削峰填谷,使机组的出力情况更加平稳。

为进一步检验研究设计的新能源电网规划优化模型(模型1)的性能,研究将其与目前较为流行的几种电网调度模型进行对比实验。对比模型包括文献[13]的调度模型(模型2)、文献[14]的调度优化模型(模型3)、文献[15]的调度优化模型(模型4)。对比指标包括负荷峰谷差、运行成本、污染物排放量、风电机组和光伏机组的单日平均最优消纳率。对比结果如表1所示。

表1 四种模型的电网规划优化效果对比

模型	负荷峰谷差 (MW)	运行成本 (万元)	污染排放量 (t)	风光机组平均最优消纳率 (%)
模型1	165.87	784.85	7584.88	83.47
模型2	231.14	915.87	8954.78	75.69
模型3	204.58	893.64	8497.52	79.88
模型4	251.74	934.72	9248.45	72.43

如表1所示,模型1的负荷峰谷差、污染排放量与运行成本相较于其他模型明显更低,模型1的峰谷差在200MW以下,而其他模型的峰谷差皆超过了200WM。而新能源发电的最优消纳率达到了80%以上,其余模型皆在80%以下。综合上述内容可知,研究设计模型能够有效维持新能源发电稳定,同时降低污染排放以及运行成本。

3 结束语

针对多能源接入电力系统的配电规划优化问题,研究提出了基于双层调度模型和需求分析的新能源电网规划优化方法。该方法通过引入储能系统、考虑新能源的最优消纳率以及引入价格需求响应等策略,实现电

力系统的多目标优化。实验结果表明,该方法在引入储能系统后,各新能源发电组件的最优消纳率得到了明显提升,且考虑消纳率后电力系统运行成本降低了共计降低了152.36万元。在考虑需求响应之后,负荷峰谷差缩小了165.48 kW。且在电负荷低谷时段,其等效负荷增加了21.66 MW。引入需求响应后,各机组出力更加平稳。相较于其他电网规划模型,模型1的负荷峰谷差、污染排放量与运行成本相较于其他模型明显更低,而新能源发电的最优消纳率达到了80%以上。目前研究仅考虑了运行成本、负荷波动等指标,在之后的研究中可进一步考虑供电可靠性、与其他电网的互联互通性等因素,进一步提高电力系统的智能化水平和

运行效率。

参考文献:

- [1] 吴文传,许书伟,杨越,等.风险量化的高比例新能源电力系统概率调度[J].电力系统自动化,2023,47(15):3-11.
- [2] 刘一民,郑少明,董鹏,等.新能源发电设备接入的电磁暂态仿真研究[J].自动化技术与应用,2024,43(1):161-165.
- [3] 李军徽,周家旭,朱星旭,等.含高渗透新能源电力系统中考虑变时段控制的火/储/荷日前优化调度[J].电网技术,2023,47(1):51-62.
- [4] 王文烨,姜飞,张新鹤,等.含规模氢能综合利用的高比例风光多能源系统低碳灵活调度[J].电网技术,2024,48(1):197-206.
- [5] Singh E,Afshari S S,Liang X.Wind Turbine Optimal Preventive Maintenance Scheduling Using Fibonacci Search and Genetic Algorithm[J].Journal of Dynamics, Monitoring and Diagnostics,2023,2(3):157-169.
- [6] 徐文哲,张哲任,徐政.适用于大规模纯新能源发电基地送出的混合式直流输电系统[J].中国电力,2023,56(4):16-27.
- [7] 梁振锋,范新伟,张娉,等.考虑实时备用率的中长时间尺度新能源发电备用的方法[J].电工电能新技术,2024,43(3):10-21.
- [8] 崔杨,于世鹏,张节潭,等.考虑光热电站调峰补偿的高比例新能源电力系统经济调度[J].中国电机工程学报,2023,43(13):4922-4934.
- [9] 井浩然,赵红生,姚伟,等.含分布式变速抽水蓄能的新能源发电系统灵活性资源规划[J].电力自动化设备,2023,43(11):117-123.
- [10] 童宇轩,胡俊杰,刘雪涛,等.新能源电力系统灵活性供需量化及分布鲁棒优化调度[J].电力系统自动化,2023,47(15):80-90.
- [11] 韩子娇,那广宇,董鹤楠,等.考虑灵活性供需平衡的含电转氢综合能源系统鲁棒优化调度[J].电力系统保护与控制,2023,51(6):161-169.
- [12] Kaur G,Dhillon J S.Electricity generation scheduling of thermal-wind-solar energy systems[J]. Electrical Engineering, 2023, 105(6): 3549-3579.
- [13] 臧延雪,边晓燕,梁思琪,等.计及线路传输能力的新能源电力系统灵活性评估及优化调度方法[J].电力系统保护与控制,2023,51(11):15-26.
- [14] 程宇,郭权利.计及动态能源价格和共享储能电站的多主体综合能源系统双层优化调

度策略[J].现代电力,2024,41(1):10-20.

[15] 李宇骏,陆艺源,牟同鹏,等.新能源发电经换流器并网系统的稳定性分析与控制综述[J].电网与清洁能源,2023,39(12):79-94.

作者简介:吴国栋(1985-),男,硕士,高级工程师,研究方向:电力系统自动化、可再生能源发电。

基于时序模拟的新能源合理利用率分析

吴国栋^{1,2}, 包广清¹

(1. 兰州理工大学电气工程与信息工程学院, 甘肃 兰州 730050; 2. 国网甘肃省电力公司, 甘肃 兰州 730030)

摘要: 研究长时间尺度下新能源出力的月度、季节性特征, 基于多年平均风光资源, 利用归一化序列表征新能源出力的波动性和间歇性, 再结合最新装机时序、最新气候气象预报形成的新能源理论出力序列, 考虑用电负荷、电网调峰、断面约束, 采用聚合法规划水火电机组开机形成的新能源消纳空间, 以新能源利用率最高为目标函数进行优化计算。通过多次调整边界变化, 建立电网装机规模、布局和时序与新能源电量、利用率的耦合关系, 综合分析得出合理的新能源利用率、最佳的储能配比需求。

关键词: 场景再现; 新能源; 时序模拟; 合理利用率

中图分类号: TK513.5

文献标识码: A

DOI: 10.19769/j.zdhy.2025.03.041

Analysis of Reasonable Utilization Rate of New Energy Based on Time Series Simulation

WU Guodong^{1,2}, BAO Guangqing¹

(1. College of Electrical Engineering and Information Engineering, Lanzhou University of Technology, Lanzhou, Gansu 730050, China;
2. Gansu Electric Power Company, Lanzhou, Gansu 730030, China)

Abstract: Study the monthly and seasonal characteristics of new energy output on a long-term scale, based on the average annual wind and solar resources, and use normalized sequences to characterize the volatility and intermittency of new energy output. Based on the latest installation time sequence and the latest climate and meteorological forecast, the new energy theoretical output sequence is formed. Considering the electricity load, grid peak regulation, and section constraints, the aggregation method is used to plan the new energy consumption space formed by the start-up of the hydro thermal power unit. The optimization calculation is carried out with the goal function of maximizing the utilization rate of new energy. By adjusting the boundary changes multiple times, the coupling relationship between the installed capacity scale, layout, and timing of the power grid and the new energy electricity quantity and utilization rate is established, and the most reasonable new energy utilization rate and optimal energy storage ratio demand are comprehensively analyzed.

Key words: scene reproduction; new energy; time series simulation; reasonable utilization rate

0 引言

为实现“双碳”目标, 新能源发电占比不断提升, 这对电网的调峰能力提出了更高要求^[1]。目前, 新能源利用率下降, 消纳成本快速增加, 因此亟需寻找最合理的新能源利用率, 以使综合成本最低。在新能源高渗透率情况下, 合理弃电是经济且必要的。设定过高利用率的消纳目标既不经济, 也将限制新能源的发展规模。但如何得到新能源的合理利用率, 尚缺乏具体的算法。现有的分析更多着眼于

基金项目: 国网甘肃省电力公司科技研发项目“适应新能源高占比送端电网的新能源运行评价及辅助决策关键技术研究”(52272223000W)

作者简介: 吴国栋, 男, 1985年生, 硕士研究生, 高级工程师, 研究方向为电力系统自动化、可再生能源发电。

电力系统的新能源消纳能力及电力电量平衡方法, 最多针对新能源装机、负荷等边界利用率, 但并未寻找合理利用率。目前, 分析的主要方法包括传统的典型日分析法、近年常用的时序生产模拟法、最新出现的随机生产模拟法^[2]3种。唐权^[3]基于典型日分析法, 从整体上分析电网的消纳能力, 但未考虑新能源的随机性、波动性; 吴冠男等^[1]基于时序生产模拟法, 通过诸周优化机组开机计算每小时的新能源消纳能力, 计算方法相对成熟, 且在电力生产规划中较为常用, 但所需数据量大、计算复杂; 陈旭等^[4]通过概率分布间的运算, 极大地加快了新能源消纳能力的计算速度, 但也带来了准确率小幅下降的问题, 同时也没有解决目标反推装机的问题。

时序生产模拟法最大的难点及最耗时的地方在于如何通过最优规划安排常规机组的出力^[5], 常规的时序模拟

法需要对每台机组进行建模,形成约束条件,并对每个时段的开机方式进行规划,确保在满足最大负荷需求的前提下最大化地消纳新能源^[6]。无论是机组的建模还是对开机的优化,它们都容易增加偏差和运算量^[7]。诸多文献在采用时序生产模拟法分析新能源消纳能力时,直接引入了新能源理论功率的时序出力曲线^[8],但对如何形成此曲线未作过多介绍,也没有考虑区域电网电力余缺互济^[9]。

综上,目前的新能源测算方法存在准确率与计算速度之间的矛盾,且均无法通过发电占比、利用率目标反推装机时序与布局,更无法得出合理利用率与最佳储能需求。本文将建立一种形成新能源理论功率时序出力曲线的模型,采用聚合法减少优化水火电开机的运算量,并提出新能源合理利用率、调峰能力需求的计算方法,以用于规划。以某省2023年的新能源消纳能力计算为例,验证本文计算方法的准确性。

1 新能源消纳能力计算机理

1.1 总体思路

电网的新能源消纳能力既与电网本身的负荷特性、调节能力有关,又与新能源的装机情况、出力特性相关。不同边界条件下的新能源利用率的计算最能表征新能源的消纳能力。利用率计算的本质是电力电量平衡问题,即通过对某个规定时间段内的新能源出力,结合电网负荷及外送的大小、常规电源的调节能力,确定新能源的理论电量与实际电量,进而确定新能源的利用率。新能源的利用率为:

$$\eta = \frac{Q_{\text{fact}}}{Q_{\text{theo}}} \quad (1)$$

式中: Q_{fact} 表示受电网消纳能力限制后新能源的实际发电量; Q_{theo} 表示新能源的理论发电量,即电网消纳能力在足够大的情况下新能源能发出的电量^[9]。

定义新能源消纳空间为某时刻电网最大可消纳新能源的电力值。通过时序生产模拟法比较逐时段的新能源出力与电网消纳空间,当新能源出力小于电网消纳空间时,全额消纳新能源;当新能源出力大于电网消纳空间时,消纳的新能源电量等于新能源消纳空间大小对时间的积分。例如,将计算周期分为 N 个时长为 T 的时段并逐个进行优化,则计算方法为:

$$Q_{\text{fact}} = \sum_{k=1}^N \int_0^T [\mu_t P_{\text{ne}}(t) + (1 - \mu_t) P_{\text{space}}(t)] dt \quad (2)$$

$$Q_{\text{theo}} = \sum_{k=1}^N \int_0^T P_{\text{ne}}(t) dt \quad (3)$$

$$P_{\text{ne}}(t) = P_{\text{wind}}(t) + P_{\text{thotov}}(t) \quad (4)$$

$$\mu_t = \begin{cases} 1, & \text{当 } P_{\text{ne}}(t) < P_{\text{space}}(t) \text{ 时} \\ 0, & \text{当 } P_{\text{ne}}(t) \geq P_{\text{space}}(t) \text{ 时} \end{cases} \quad (5)$$

式中: $P_{\text{ne}}(t)$ 表示 t 时刻新能源出力; $P_{\text{wind}}(t)$ 表示 t 时刻风

电出力; $P_{\text{space}}(t)$ 表示 t 时刻消纳空间; μ_t 表示计算因子。

1.2 消纳空间计算

电网消纳空间是由网内用电量加上外送电量形成的用电空间,减去常规能源的最小出力得到的。考虑安全约束,常规电源的开机容量应确保其最大出力能够满足某一段周期内的最大用电需求,保障电网安全稳定运行。结合火电机组运行特性及开停机特性,取计算时段 $T=3\sim 7$ 天,以1周最为典型,即取 $T=7$ 。

$$P_{\text{space}}(t) = P_{\text{con}}(t) + P_{\text{tra}}(t) - \sum_{i=1}^I \lambda_i P_{g,i,\min} - P_{\text{res}} \quad (6)$$

$$P_{g,i,\min} = \beta_i P_{g,i,\max} \quad (7)$$

$$\sum P_{g,i,\max} > \max \{ P_{\text{con}}(t) + P_{\text{tra}}(t) \} \quad (0 < t \leq T) \quad (8)$$

式中: $P_{\text{con}}(t)$ 表示网内用电量; $P_{\text{tra}}(t)$ 表示联络线外送电量; P_{res} 表示备用开机(在新能源消纳困难的省份,为保证新能源的最大化消纳,在区域电网备用充足的情况下可取负值); $P_{g,i,\max}$ 表示常规机组的最大出力; $P_{g,i,\min}$ 表示常规机组的最小出力; β_i 表示第 i 台机组的最小技术出力系数; λ_i 表示第 i 台机组的开机状态(即开机为1,停机为0)。

2 新能源消纳能力计算

2.1 新能源出力特性

分析北方某省份连续5年的新能源出力,发现随着时间尺度的拉长,新能源的波动性在降低,新能源在日内及数日中波动剧烈且没有规律可循,但当时间尺度拉到月度或年度时,会发现部分月份在各年度均为风电出力最大的月份,而另一部分月份总是风电出力最小的月份。

考虑上述因素,本文采用历史新能源理论功率的归一化时间序列,结合装机容量的变化匹配逐时段,形成测算周期的新能源理论出力。定义矩阵 P_{NE} 为新能源逐小时的出力序列, $\overline{P_{\text{wind}}}$ 、 $\overline{P_{\text{thotov}}}$ 为风、光逐小时的资源归一化序列, S_{wind} 、 S_{thotov} 为风、光逐小时的装机序列。以 P_{NE} 为例,其构成为:

$$P_{\text{NE}} = [P_{\text{NE},1}, P_{\text{NE},2}, P_{\text{NE},3}, \dots, P_{\text{NE},8760}]^T \quad (9)$$

各矩阵间的运算关系为:

$$P_{\text{NE},i} = [\overline{P_{\text{wind},i}}, \overline{P_{\text{thotov},i}}] \begin{bmatrix} S_{\text{wind},i} \\ S_{\text{thotov},i} \end{bmatrix} \quad (10)$$

$$\overline{P_{\text{wind}}} = \left[\frac{P_{\text{wind},1}^0}{S_{\text{wind},1}^0}, \frac{P_{\text{wind},2}^0}{S_{\text{wind},2}^0}, \dots, \frac{P_{\text{wind},8760}^0}{S_{\text{wind},8760}^0} \right]^T \quad (11)$$

$$\overline{P_{\text{thotov}}} = \left[\frac{P_{\text{thotov},1}^0}{S_{\text{thotov},1}^0}, \frac{P_{\text{thotov},2}^0}{S_{\text{thotov},2}^0}, \dots, \frac{P_{\text{thotov},8760}^0}{S_{\text{thotov},8760}^0} \right]^T \quad (12)$$

式中: $S_{\text{wind},i}$ 表示第 i 小时对应的风电装机容量; $S_{\text{thotov},i}$ 表示第 i 小时对应的光伏装机容量; $P_{\text{wind},i}^0$ 、 $S_{\text{wind},i}^0$ 分别表示上一年度风电第 i 小时风电的出力与装机容量; $P_{\text{thotov},i}^0$ 、 $S_{\text{thotov},i}^0$ 分别表示上一年度光伏第 i 小时风电的出力与装机容量。

上述资源归一化序列各项之和正好等于全年的资源小时数,即 $\sum_{i=1}^{8760} \overline{P_{wind,i}}$ 为全年风资源小时数, $\sum_{i=1}^{8760} \overline{P_{thotov,i}}$ 为全年光资源利用小时数。一般情况下,一个地区的风光资源小时数的变化不大,若气候预测有变强或变弱的趋势,则可通过在序列各项乘以系数的方式调整资源小时数。

2.2 断面约束

新能源电场和主网之间的输电断面受传输容量的约束,传统的时序模拟方法表示为:

$$P_l(t) \leq P_{l, \max} \quad (13)$$

式中: $P_l(t)$ 、 $P_{l, \max}$ 分别表示断面实际输送功率及最大输送功率。

这样的断面约束条件看似简单,但并不合理,因为断面的限额也是变量,会随着运行状态的不同随时变化。即约束条件为:

$$P_l(t) \leq P_{l, \max}(t) \quad (14)$$

$$P_{l, \max}^{\min} \leq P_{l, \max}(t) \leq P_{l, \max}^{\max} \quad (15)$$

最大输送限额的变化除了变化范围可以确定,其具体变化规律受运行状态的变化约束,难以建模描述。在本文的时序生产模拟法中,对断面限额的变化基于上一年度的分布序列,同时结合电网改造导致的限额提升、断面限额与电网运行状态的耦合关系,形成最新的断面限额序列,这最大限度地模拟了真实的运行情况。

2.3 调峰约束

在高比例新能源电网中,常规电源一方面要满足负荷的变化,另一方面要平衡新能源出力的波动。即需要满足约束条件:

$$\sum P_{wind}(t) + \sum P_{thotov}(t) + \sum P^m(t) + \sum P^h(t) = P(t) \quad (16)$$

电网调峰能力增加后,新能源的消纳能力同样会增加。在电网规划、生产运行中,经常需要确定新增调峰能力和新增消纳的新能源电量、或新能源利用率之间的定量关系。运用本文所述方法,可以很方便地完成计算。电网调峰能力增加 ΔP 后,则新的电网消纳空间为:

$$P'_{space}(t) = P_{space}(t) + \Delta P \quad (17)$$

将 $P'_{space}(t)$ 代入式(17),即可得到最新的新能源消纳电量和利用率。通过多次测算不同调峰能力,可测算出调峰能力和利用率之间的耦合关系,进而确定调峰能力增加带来的边际增发新能源电量,有助于制定合理的调峰能力提升方案。

2.4 常规机组出力约束

常规机组装机容量直接决定新能源小发时供电能力是否充足及新能源大发时新能源消纳空间的大小。对常规机组的约束主要考虑火电机组、水电机组调节能力、爬坡约束,其公式为:

$$P_{i, \min}^m (1 - S_f \beta) \leq P_{i, t}^m \leq P_{i, \max}^m \quad (18)$$

$$P_{i, \min}^h (1 - S_f \beta) \leq P_{i, t}^h \leq P_{i, \max}^h \quad (19)$$

$$P_{i, t+1}^m - P_{i, t}^m \leq \Delta P_{i, up}^m \quad (20)$$

$$P_{i, t}^m - P_{i, t+1}^m \leq \Delta P_{i, down}^m \quad (21)$$

$$P_{i, t+1}^h - P_{i, t}^h \leq \Delta P_{i, up}^h \quad (22)$$

$$P_{i, t}^h - P_{i, t+1}^h \leq \Delta P_{i, down}^h \quad (23)$$

式中: $P_{i, \min}^m$ 、 $P_{i, \max}^m$ 分别表示火电机组最小技术出力、最大技术出力; $P_{i, \min}^h$ 、 $P_{i, \max}^h$ 分别表示水电机组最小技术出力、最大技术出力; S_f 表示火电机组是否进行了灵活性改造(“1”表示已改造,“0”表示未改造); β 表示灵活性改造增加的可以继续降低的出力比例; $\Delta P_{i, up}^m$ 、 $\Delta P_{i, down}^m$ 表示火电机组的下爬坡速率、上爬坡速率; $\Delta P_{i, up}^h$ 、 $\Delta P_{i, down}^h$ 表示火电机组的下爬坡速率、上爬坡速率。

本文建立的模型基于上一年度时序的合理调整,为加快运算速度,优化常规机组模型,将所有火电机组聚合为一台聚合机组。

2.5 优化目标与方法

总体优化目标为在满足上述约束条件的基础上新能源利用率最高,即优化目标为:

$$\min(\eta) \quad (24)$$

本文建立的模型为混合整数线性规划模型,使用CPLE求解器求解。考虑到用电负荷和风光资源具有明显的季度、月度特征,基于上年度同期的开机容量作为基准值逐月进行优化。

在本文的模型中可将归一化时间序列与测算边界条件匹配形成最新时间序列,通过系数的变化调整边界变化或分析敏感性。新增新能源装机的规模、布局和时序的不同都会影响最终的新能源电量和利用率。通过多次调整上述边界变化,可以形成电网装机规模、布局、时序与最终新能源电量和利用率的耦合关系。

3 算例分析

3.1 算例介绍

以某新能源大省实际电网为例,利用基于场景再现的时序生产模拟法测算2023年的新能源消纳情况。测算采用2022年的实际数据形成新能源资源、用电负荷的归一化序列以及常规机组开机时间序列、断面限额序列。表1列出了计算的边界条件,各时间序列由于项数过多(8760项),故不具体列出。

表1 边界条件

	2023年	2024年	2025年
全社会用电量/亿kW·h	1 362	1 410	1 465
外送电量/亿kW·h	520	620	620
受入电量/亿kW·h	80	130	130
风资源小时数/h		2 800	
光资源小时数/h		1 500	
装机规模/亿kW	2 300	2 856	3 356

3.2 算例结果

年初预测2024年全年发电累计427亿kW·h,最终实际发电累计436亿kW·h,预测误差2.06%;预测全年利用率95.11%,实际利用率96.83%,偏差1.72个百分点。由于年内装机集中在四季度,其影响主要在于第二年。测算2025年数据,新能源理论电量为558亿kW·h,新能源发电量为506亿kW·h,利用率仅为90.72%。

按现有负荷、外送、常规电源最小出力水平,消纳空间全年为735亿kW·h,大于新能源理论电量579亿kW·h。分析8760h的消纳空间减新能源可用电力,6331h(占比72%)的消纳空间大于新能源可用出力。统计每小时全年累计的断面受限和调峰受限电量,午间时段(11:00—17:00)弃电矛盾最为突出,弃电量占全年的69.94%,尤其以15:00最为严重,弃电电力超52万kW(对应全天0.125亿kW·h),弃电量占全年的12%。

对增加50万~250万kW·h调峰能力的情形进行分析,增加到150万调峰能力后,利用率可接近95%,但单位调峰能力带来的边际增发电量在下降,如表2所列。其他调峰能力的增加只能通过储能实现,但储能受到功率和容量双重限制,故对储能配置进行分析,结果如表3所列。

表2 调峰能力灵敏度分析表

调峰能力/ 万kW·h	新能源发电量/ 亿kW·h	新能源 利用率/%	增发电量/ 亿kW·h	边际增发电量/ 亿kW·h
0	498	91.59		
50	507	93.07	8.025	0.161
100	511	94.14	5.829	0.117
150	516	94.90	4.121	0.082
200	518	95.41	2.763	0.055
250	520	95.75	1.874	0.037

表3 增加储能灵敏度分析表

	储能功率/ 万kW·h	发电量/ 亿kW·h	利用率/%	增发电量/ 亿kW·h	边际增发电量/ 亿kW·h
2h储能	0	498	91.59		
	50	4998	91.87	1.490	0.030
	100	5018	92.28	2.259	0.045
	150	503	92.67	2.120	0.042
	200	506	93.06	2.106	0.042
	250	5076	93.41	1.883	0.038
	600	5166	94.98	8.535	0.024
3h储能	0	498	91.59		
	50	500	92.08	2.655	0.053
	100	503	92.67	3.213	0.064
	150	507	93.24	3.062	0.061
	200	509	93.64	2.220	0.044
	250	511	94.00	1.940	0.039
	400	516	94.98	5.302	0.035

以2h储能为例,要达到95%的利用率,需要配置600

万kW·h的储能,但此时储能的利用效率很低。配置100万~200万kW·h的储能利用效率较高,建议配置150万kW·h×2h的储能,将92.5%作为合理利用率。

以3h储能为例,要达到95%的利用率,需要配置400万kW·h的储能,但此时储能的利用效率同样很低。配置50万~150万kW·h的储能利用效率较高,因此建议配置100万kW·h×3h的储能,将92.5%作为合理利用率。

4 结语

本文基于新能源出力时序特征,设计了一种基于场景再现的时序模拟法,避开复杂的建模、多变的相关因素,进行了电力电量平衡分析,实现了对新能源发电量、发电占比、利用率等指标的计算。与传统时序法相比,该方法在兼顾准确性与快速性的基础上,确定了装机时序、调峰能力、新能源利用率3种耦合关系。下一步,需要考虑新能源消纳的全社会成本、环境成本等因素,深入研究新能源的合理利用。

参考文献

[1]吴冠男,张明理,徐建源,等.适用于评估风电接纳能力的时序生产模拟算法研究[J].电力系统保护与控制,2017,45(23):151-157.

[2]胡殿刚,潘正婕,徐昊亮,等.大规模可再生能源并网条件下天然气机组调峰空间估算[J].电力系统保护与控制,2017,45(3):87-93.

[3]唐权.电力系统电源规划模型及算法研究[D].武汉:华中科技大学,2006.

[4]陈旭,杨雨瑶,张勇军,等.光伏光照概率性对配电网电压的影响[J].华南理工大学学报(自然科学版),2015,43(4):112-118.

[5]Kabouris J, Kanellos F D. Impacts of large-scale wind penetration on designing and operation of electric power systems [J]. IEEE Transactions on Sustainable Energy, 2010, 1(2): 107-114.

[6]张顺,葛智平,郭涛,等.大规模新能源接入后系统调峰能力与常规电源开机方式关系研究[J].电力系统保护与控制,2016,44(2):48-51.

[7]吴雄,王秀丽,李骏,等.考虑风电外送的省级系统调峰分析模型[J].电网技术,2013,37(6):1578-1583.

[8]姜欣,陈红坤,向铁元,等.考虑调峰特性的电网风电接入能力分析[J].电力自动化设备,2014,34(12):13-18+25.

[9]王晓海,乔颖,鲁宗相,等.供暖季风电电量消纳能力的评估新方法[J].中国电机工程学报,2015,35(9):2112-2119.

电力公司生产管理体系优化研究^{*}

吴国栋^{1,2}, 李晓晶¹, 包广清^{2△}, 郝培良², 吴娟霞³

(1.国网甘肃省电力公司电力调度控制中心, 甘肃 兰州 730050; 2.兰州理工大学, 甘肃 兰州 730050;
3.国网白银供电公司, 甘肃 白银 730900)

摘 要:在电网规划建设中,需要提升电力设备的建设管理水平。结合甘肃电力公司实际,分析属地化移交前后省检修公司和各运维站的业务流程与管理模式,以安全高效、快速响应为目标,统筹考虑电网结构、地理位置、供电区域、基础设施、运检便利性和调控运行需求等因素,以省市两级智能运检管控平台为依托,制定生产管理体系优化完善提升建设实施方案,从而破解管办职责不清晰、生产信息不顺畅等生产管理难题。

关键词:电网;属地化;智能运检管控平台

中图分类号: TM7

电力行业是关系到国计民生的重要基础性行业,随着电网规模不断扩大,输变电设备数量持续增长,电力公司运维工作面临巨大挑战。如何降低生产成本,缩短管理链条,解决管办职责不清晰,生产信息不顺畅等生产管理难题,成为电力公司的追求目标。

电力设备作为电网最重要的组成部分之一,在保障其可靠性的同时降低运维成本,对电网的安全稳定运行与提高用户用电体验至关重要。文献^[1]提出在运维站模式下的变电站运行维护工作策略,提升了电力公司运维工作的科学管理水平。从海洋等人对我国输电线路通道防护现状进行了总结,并针对输电线路通道防护管理的目标,工作流程,绩效考核和持续改进等问题提出建议,为我国供电企业安全生产与属地管理提供了一定的参考和借鉴^[2]。为提高设备运行的可靠性,降低运维成本,文献^[3]提出了输变电设备差异化运维策略,从设备检测,状态评估,风险评估等多个维度,为提升输变电设备可靠性提供了科学依据。针对我国 110 千伏变电站在运维站模式下面临的风险和形式,文献^[4]提出了预防运维风险的对策和措施,为运维站模式下变电站运维积累了宝贵的工作经验。文献^[5]提出了输变电设备智能化运维系统,有效提升电力设备状态检修技术水平与信息化数据利用率,为提升输变电设备运维管理工作提供了有力保障。

上述文献在细化运维目标,提高运维效率,提升输变电设备可靠性方面均取得一定成果。而从电力公司生产管理体系优化方面的研究成果并不多见。鉴于理论研究与实际应用两方面的需要,本文结合甘肃省电力公司实际,打造生产面三个中心(调度控制中心、生产指挥中心、供电服务中心)的生产管理体系架构,以省市两级智能运检管控平台为依托,对属地化后电力公司生产体系架构进行深入分析,并对生产管理体系进行优化,推进设备管理状态全方位可视,实现电网设备全面监控、主人制度全面落实、生产业务全面可控。

1 生产管理体系架构设计

生产管理系统能够对运营维护工作起到重要支撑作用。为降低生产成本,缩短管理链条,解决管办职责不清晰,生产信息不顺畅等生产管理难题,本文对原有生产管理体系架构进行优化。架构设计为四层,建成省市两级生产指挥中心,以可视化的智能运检管控平台为依托,与设备管理部、运维检修部部署办公,实现信息汇集、过程管控、预警研判、协调指挥功能;市(州)公司层面,实现管理职能和业务实施分离,成立变电运维(检修)中心、输电运检中心、配网带电作业中心等业务实施机构;落实设备主人制,调整优化运维站布点,实现主辅设备全面监控,实施差异化运维检修策略。生产管理体系架构建设构架图

^{*} 基金项目:本文受到国网甘肃电力公司科技项目资助,项目编号:SGGS0000TKWT1900858。

[△] 通讯作者:包广清(1972-),女,博士,教授,从事电力系统运行控制领域研究。

如图 1 所示。




图 1 生产管理体系新架构建设构架

2 建设运维站能力标准

2.1 运维站设置原则

各单位应根据实际情况,以安全高效、快速响应为目标,统筹考虑电网结构、地理位置、供电区域、基础设施、运检便利性和调控运行需求等因素,以满足日常工作需求,缩小工作半径为原则设置运维站。

运维站宜设置在枢纽变电站,原则以 330 千伏变电站为中心,覆盖附近变电站,工作半径不宜大于 60 公里或超过 60 分钟车程(以下简称“双 60”,这是甘肃省检修公司运维站当初按照国网规定的设置要求)。不满足“双 60”且不满足一体化信息监控要求的变电站,向省公司报备后可实行有人或无人值守。有人或无人值守的变电站驻站人员不应少于两人,且应能满足基本操作及巡视设备的要求。

2.2 运维站人员配置

电力设备数量激增与维护人力资源短缺的矛盾与日俱增,若人员配置不合理,将对运维工作造成影响。运维站人员配置应按照《国家电网有限公司供电企业劳动定员标准》执行,实际配置率应达到 100%,人员配置可考虑生产需求以及变电站发展需要适当增加备员。运维站值班方式应满足日常运维和应急处置工作的需要。运维站驻地应 24h 有人值班,并保持通讯畅通,夜间值班不少于 2 人。

2.3 运维站信息系统支撑

为积极适应国家电网公司建设“三型两网、世界一流”战略目标,提升智能化、信息化和现代化水平,加强生产人员对电网主辅设备状态信息掌控,完善信息支撑保障手段。运维站应配置一体化生产

信息系统平台,拓展变电移动作业应用,利用电力物联网技术,逐步实现变电业务全上线、状态管控全在线。

当前数据监测和采集系统得到的与电网相关的数据,具有体量庞大、种类繁多、形式多样的特点。为实现运维站应用系统数据信息贯通功能,保障各数据的安全、可靠、稳定,应避免数据多渠道、多端口重复录入。

一体化生产信息系统利用 5G 等网络安全接入,打造泛在物联网移动作业平台。通过手持终端实现远程监视、巡查、记录上传功能,实现变电运检业务全覆盖。应具备视频监控、后台主机联动功能,通过远程视频监控自动跟踪设备变位,减少人工巡检、现场设备核查频次,实现“科技减负”,提高工作效率。同时具备消防、视频一体化联动功能,逐步实现高清视频监控能实现自动跟踪监视火灾区域、人员流动区域以及温度异常设备等区域的功能,保证各级人员能通过视频监控系统实时掌握变电站现场突发事件或异常情况。

2.4 运维站通信网络支撑

通信网络的安全稳定对信息系统可靠运行至关重要。运维站及所辖变电站网络带宽应当满足主辅设备集中监控等运维业务要求。用于调度监控、远程巡视、一键顺控、辅助判断和应急处置的生产视频系统应进行高清化改造,专网传输,满足调度、运维对现场视频图像信息可靠性、实时性要求。

运维站及所辖变电站通信网络,应当满足移动作业、智能巡检机器人、在线监测装置等系统与生产信息支撑系统数据交互要求。信息内网带宽宜不低于 100M,便于探索 5G 网络安全接入或无线专网建设。并应具备与调度直接通讯及电力系统内、外部通讯功能。

3 职责分工

3.1 运维站相关职责

在优化后的生产管理体系架构中,运维站需要负责所辖变电站设备监视、设备巡视、日常维护、设备轮换试验、倒闸操作、两票管理、设备异常及故障处置、生产准备、调控业务联系等工作。并负责所辖变电站设备缺陷管理、风险管控等缺陷闭环管控、落实风险管控措施工作。负责所辖变电站安全措施落实、隐患排查治理等安全管理工作。同时还需要

负责所辖变电站设备状态评价,提出检修、技改大修策略等状态管理工作与所辖变电站火灾、自然灾害、突发事件等应急处置,并承担所辖变电站保供电任务。以及所辖变电站现场专用规程修编、档案资料收集、运维分析、技术培训等技术管理工作。

3.2 运检中心相关职责

一切管理都应该从制度开始。运检中心贯彻执行国家相关法律法规、行业标准、国网公司及省公司有关标准及制度,组织开展所辖变电站现场运行专用规程的编制修订工作。负责运维站的设置、日常管理、值班制度制定和后勤保障。指导、监督、检查、考核运维站变电运维工作,协调解决相关问题。制订相关维护、消缺方案并实施。同时还需要负责设备异动跟踪管控,设备缺陷、隐患的统计分析、跟踪、消缺闭环监督。以及各类作业现场管控,对施工、检修、抢修作业现场安全措施布置情况、现场管控措施执行情况、人员违章情况监督检查,收集、发布工作进度信息。

3.3 地市公司运维检修部相关职责

运维站信息汇集至省检修公司、市(州)公司智能运检管控中心(生产指挥中心),做为运检部职能的延伸,与运检部一体化运作。负责从“信息汇集、过程管控、预警研判、指挥协调”四个层面来履行其相关职责。

3.4 省公司设备部相关职责

省公司智能运检管控中心是设备管理的延伸,与电科院一体化运作,生产业务信息汇集至省级智

能运检管控中心,承担电网设备“信息汇集、过程管控、预警研判、协调指挥”的核心管理功能。充分发挥生产信息的汇集发布、既定流程工作的组织、过程管控和监督、突发情况的预警研判以及应急状况的追踪、监督的作用。

4 结语

本文在理论上,对电力公司生产管理体系进行了优化,并制定生产管理体系优化完善提升建设实施方案。以运维站方式对输变电设备进行维护存在一定的难度,需要相关部门和工作人员统筹协调,共同努力。降低生产经营成本,缩短管理链条,破解管办职责不清晰、生产信息不顺畅等生产管理难题,提高运维工作质量。这是国网公司体系建设的重要内容,也是加快推进甘肃电网建设的客观需要,是全面提升电网调控管理水平的重要举措。

参考文献:

- [1] 秦晓君.运维站模式下的变电站运行维护工作研究[J].通讯世界,2017(16):147
- [2] 丛海洋,范渤.输电线路通道防护属地化管理问题研究[J].东北电力技术,2014,35(06):23-26
- [3] 吴卓文.基于风险评估的输变电设备差异化运维策略应用研究[J].企业技术开发,2016,35(08):98-99.
- [4] 喻平江.110kV 运维站模式变电站的运维工作风险及预防对策[J].通信电源技术,2018,35(12):285-286.
- [5] 李穆,卢文华,向冬冬.输变电设备智能化运维系统研究与应用[J].电气工程学报,2015,10(07):71-77.

(上接第74页)

教师会遇到各种困难,主要集中在两方面:教师和学生的积极性不高。对于前者高校要有计划有步骤地推进该模式的运用,做好示范带头工作,让教师有学习的榜样。同时提高培训的质量,完善培训体系。建立多维评价体系和绩效体系提高教师使用该模式的积极性。混合教学的线下学习情况虽然很难了解,但是通过采用 SPOC 形式,为学生提供更有针对性、更有个性化的教学,提高学生学习的积极性。

参考文献:

- [1] 陈耀华,陈琳.互联网+教育智慧路向研究[J].中国电化教

育,2016(09):80-84+135.

- [2] 扈文英.创新扩散理论视阈下高校网络教学平台推广策略研究[J].继续教育,2018,32(04):26-29.
- [3] 李炜.MOOC 背景下三种常见混合式教学模式的比较研究[J].现代教育技术,2018,28(S1):5-10.
- [4] 田爱丽.借助慕课改善人才培养模式[J].中小学信息技术教育,2014(02):13-15.
- [5] 许蔚,方娇莉,张燕,等.“互联网+公共基础课”教学改革研究——以昆明理工大学为例[J].现代教育技术,2018,28(03):53-58.

证书号第8091394号



专利公告信息

发明专利证书

发明名称：一种基于新能源出力特性的新能源消纳能力测算方法

专利权人：兰州理工大学;国网甘肃省电力公司电力科学研究院
西南石油大学

地址：730000 甘肃省兰州市七里河区兰工坪路287号

发明人：吴国栋;包广清;马志程;郝如海;周治伊;张安安;许瑾
刘俊敏;张波

专利号：ZL 2022 1 1234104.X

授权公告号：CN 115622143 B

专利申请日：2022年10月10日

授权公告日：2025年07月22日

申请日时申请人：兰州理工大学;国网甘肃省电力公司电力科学研究院
西南石油大学

申请日时发明人：吴国栋;包广清;马志程;郝如海;周治伊;张安安;许瑾
刘俊敏;张波

国家知识产权局依照中华人民共和国专利法进行审查，决定授予专利权，并予以公告。
专利权自授权公告之日起生效。专利权有效性及专利权人变更等法律信息以专利登记簿记载为准。

局长
申长雨

申长雨





《“双碳”目标与新能源发展》系列丛书

新能源合理利用率之路

主 编：张柏林 胡殿刚

副主编：李晓虎 吴国栋

内容简介

本书在分析新能源出力特性的基础上,研究提升新能源消纳能力的措施,探究新能源合理利用率的内涵及计算方法。书中内容具有较强的实用性和一定程度的前瞻性,为“双碳”目标下构建新能源供给消纳体系提供思路与建议,可供从事新能源发电、电力系统运行与调度、新型电力系统建设等的研究、规划、管理、技术人员阅读参考。

Xinnengyuan Heli Liyonglü Zhilu

新能源合理利用率之路

主 编:张柏林 胡殿刚

副主编:李晓虎 吴国栋

出版发行:气象出版社

地 址:北京市海淀区中关村南大街46号

邮政编码:100081

电 话:010-68407112(总编室) 010-68408042(发行部)

网 址:<http://www.qxcbs.com>

E-mail: qxcbs@cma.gov.cn

责任编辑:万 峰

终 审:吴晓鹏

责任校对:张硕杰

责任技编:赵相宁

封面设计:

印 刷:

开 本:710 mm×1000 mm 1/16

印 张:8.25

字 数:150千字

版 次:2022年8月第1版

印 次:2022年8月第1次印刷

定 价:66.00元

本书如存在文字不清、漏印以及缺页、倒页、脱页等,请与本社发行部联系调换。

序 言

新能源跨越式发展是构建新型电力系统、实现“双碳”目标的必由之路。2021 年中国风电、光伏发电容量均突破 3 亿 kW, 全国平均风电利用率达 96.9%, 光伏发电利用率达 98.2%, 实现了新能源装机容量与利用率的“量率齐升”。但青海、蒙西等地区新能源利用率分别下降 5.7% 和 1.5%。“十四五”期间, 在新能源大规模发展的情况下, 部分新能源大省的量率矛盾开始进一步凸显。

回顾发展历程, 新能源发展先后经历了示范探索及产业化初期阶段, 正在经历着规模化发展阶段、即将面临高质量发展阶段。在此期间, 行业发展所面临的主要矛盾也由发展初期的并网技术问题, 发展为规模化发展后的新能源消纳问题, 即将转化为新能源保供保消纳与电网安全运行问题。中国新能源发展在“量率”关系方面经历了以下几个阶段:


第一个阶段是“量”的提升。在新能源发展起步阶段, 新能源消纳能力充足, “三北”地区的新能源装机有了迅猛的发展。

第二个阶段以“率”定“量”阶段。随着新能源装机的大规模发展, 新能源消纳能力不足的矛盾凸显, 利用率逐年下降。2016 年以来, 国家开始发布红色预警。2018 年以来, 中国新能源发展采用“以消纳能力引导发展规模”开发模式, 新能源利用水平持续提升。

第三个阶段是“量率”协同阶段。即随着“双碳”目标的提出, 新型电力系统的建设需要“量不能少、率不能低”。近年以来, “双碳”目标下国家相继出台了一系列政策文件, 围绕规划引导、规模管理、项目组织等方面, 提出了新的工作要求, 就是既要达到较大并网规模, 又要保持较高利用水平。目前各地正积极组织保障性、市场化等各类项目开发, 发展需求很大, 随着全国范围消纳能力、调峰潜力的全面挖掘后, 利用率下降的拐点已经出现。如何实现“量不能太少, 率不能太低”, 难度很大。甘肃省新能源发展起步早、发展快、新能源占比大

(2021年年底新能源装机占比达48%、发电占比达23%)、消纳难度大,在这方面做了很多有价值的理论研究和实践尝试。甘肃省的消纳困难也是其他省份即将面临的困难,甘肃省的实践措施也可为其他省份提供有益的参考。

本书在对“量率”矛盾的普遍性进行分析研究的情况下,以甘肃省新能源发展的困难和解决措施为例说明如何通过合理利用率解决“量率”矛盾,既具有理论性,又不失实践性;既具有典型性,又不失普遍性。这些经验对新能源从业人员开展新能源的分析研究、发展规划、调度管理等具有较大的参考价值。



2022年5月

前 言

甘肃省风资源和光资源丰富,开发起步早,第一座风电场始建于1997年,经历了“十二五”期间的初始扩张、“十三五”期间的红色预警,如今在国家“2030碳达峰、2060碳中和”目标背景下,2021年甘肃省新能源发展再次进入“十四五”期间的“快车道”。

为了做好新能源的消纳工作,国网甘肃省电力公司通过深耕省内、省外两个市场,不断补强电网送出结构,持续深挖电网调峰能力,积极服务新能源并网,实现了新能源利用率从“十三五”初的60%提升至2021年的96.83%,创历史最好。在“十四五”开局之年,甘肃省启动了826万kW存量新能源项目的建设,并规划了“十四五”第一批1200万kW的新增项目,电网“双高双峰(双高:高比例可再生能源,高比例电力电子设备。双峰:电网夏、冬季负荷高峰)”的特征愈发明显,新能源小发时供电能力不足和新能源大发时电网消纳能力不足“两难”同时存在,新形势下保供电保消纳“两保”任务艰巨。

2021年3月30日,在中华人民共和国国务院办公厅举行的中国可再生能源发展有关情况发布会上,国家能源局电力司司长在回应如何保障新能源消纳问题时,提到“要科学制定新能源合理利用率目标”,这是官方首次明确提出“合理利用率”的说法。在挖掘电网调峰能力同时,如何合理制定新能源利用率成为能源行业关注的热点话题。

本书总结了新能源发展历程、发展趋势和面临的挑战,在分析新能源出力特性及受限情况的基础上,挖掘电网调峰能力,提出了新能源合理利用率的内涵及计算方法,为推动甘肃省新能源绿色发展提供了解决方案。

限于作者水平,虽然对书稿内容进行了反复研究、测算、推敲,但难免会存在疏漏与不足之处,恳请读者批评指正。

作者

2022年4月

目 录

序言

前言

第 1 章 新能源发展历程	1
1.1 “双碳”目标下的新能源消纳	3
1.2 新能源合理利用率之路	4
第 2 章 新能源发展隐忧及挑战	9
2.1 “红色预警”之痛	11
2.2 “能源不可能三角”理论	14
2.3 新能源发展新机遇	16
2.4 新能源发展面临的挑战	18
第 3 章 新能源资源特性与出力特性	21
3.1 风光资源特性	23
3.2 风光出力特性	27
3.3 新能源总体出力特性	29
第 4 章 新能源消纳受限情况	33
4.1 国外新能源消纳受限情况	35
4.2 国内新能源消纳受限情况	37
4.3 甘肃新能源消纳受限情况	38
4.4 新能源消纳受限启示	40

第 5 章 电网调峰能力及提升措施	43
5.1 电网调峰能力分析	45
5.2 火电灵活性改造	53
5.3 抽水蓄能电站建设	56
5.4 自备电厂新能源消纳路径	60
5.5 现货市场下的新能源消纳	63
5.6 储能项目建设弥补电网调峰缺口	68
第 6 章 新能源时序生产模拟	75
6.1 新能源消纳水平评估方法	77
6.2 新能源时序生产模型	79
6.3 新能源时序生产模拟计算步骤	82
第 7 章 新能源合理利用率测算	85
7.1 新能源合理利用率内涵	87
7.2 新能源合理利用率分析的相关原则与准则	92
7.3 新能源合理利用率分析计算方法	95
7.4 甘肃省新能源合理利用率	102
第 8 章 甘肃省新能源绿色发展路径规划	107
8.1 工作思路	109
8.2 工作目标	109
8.3 消纳措施	109
第 9 章 新能源装机容量与利用率协调的建议	113
9.1 强化新能源发展统筹规划	115
9.2 适度超前能源基础设施建设与系统研究	116
9.3 深入推进电力体制改革	116
参考书目	118

第

1

章

新能源发展历程

1.1 “双碳”目标下的新能源消纳

2020年9月,国家主席习近平在第75届联合国大会上提出,我国二氧化碳排放力争于2030年前达到峰值,努力争取2060年前实现碳中和。“双碳”目标的提出为贯彻新发展理念、促进能源电力高质量发展提供了根本遵循。为推进碳达峰、碳中和,应按照源头防治、产业调整、技术创新、新兴培育、绿色生活的路径,加快实现生产、生活方式绿色变革。“双碳”目标的提出无疑为绿色清洁能源发展带来了机遇。在中国能源产业格局中,煤炭、石油、天然气等产生碳排放的化石能源占能源消耗总量的84%,而水电、风电、核能和光伏等可再生能源仅占16%。目前,我国光伏、风电、水电装机量均已占到全球总装机量的1/3左右,领跑全球。2060年中国要实现碳中和,核能的装机容量须是2020年的5倍,风电的装机容量是2020年的1.2倍,而太阳能须是2020年的70倍。为实现“双碳”目标,中国将进行能源革命,加快发展可再生能源,降低化石能源的比重,巨大的清洁、绿色能源产业发展空间将会进一步打开。所以,在“双碳”目标导向下,研究合理的可再生能源电力消纳权重和新能源利用率,探索新能源装机占比不断提升的新型电力系统发展路径,对实现新能源的健康可持续发展具有重要意义。

新能源消纳或将开启“合理利用率”新时代。2021年3月30日,国务院新闻办公室举行的发布会上提及如何保障新能源消纳问题,国家能源局电力司司长提到“要科学制定新能源合理利用率目标”这一举措。2010年以来,中国新能源装机容量大幅度增长,相应的输电通道等保障机制却没及时跟上。2017年前后,“弃风弃光”已严重制约电力行业健康可持续发展。在此背景下,国家发展和改革委员会、国家能源局联合印发《清洁能源消纳行动计划(2018—2020年)》,定下了2020年风电、光伏发电、水能利用率平均95%的目标。

该行动计划也针对清洁能源消纳问题集中在少数重点省份的特点,将目标分解,提出了分省份的年度消纳目标。如西北“风光”(风电资源和光伏发电资源,简称“风光”)大省新疆、甘肃的利用率目标相对较低,东部河北省则较高。这在某种程度上可视为有意识地开展合理利用率的探索。在该行动计划发布

新能源合理利用率之路

之后,国家能源局电力司有关负责人曾对“弃电率”改为“利用率”的改名问题做过公开解释:“弃电量”“弃电率”的说法只关注清洁能源电力的未利用部分,忽视了整个能源和电力系统为消纳清洁能源付出的努力和成本,易引起社会各界的误解。从整个能源系统经济性和全社会用电成本的角度,结合电力系统自身的特性,清洁能源消纳存在一个经济合理的利用率范围,片面追求百分之百消纳,将极大提高系统的备用成本,限制电力系统可承载的新能源规模,反而制约了新能源发展,因此并不是百分之百完全消纳最好。以一个 10 年周期为例,2010—2020 年,中国的新能源装机容量从 2984 万 kW 迅猛上升至 53496 万 kW,在电源结构上,“风光”为主的新能源占比也由 3.1% 跃升至 24.3%。尽管中国在清洁能源消纳方面做了很多工作,但 2017 年“弃水弃风弃光”的总量仍超过 1000 亿 kW·h。

随着中国碳达峰、碳中和目标的提出,未来 10 年,中国风能、太阳能发电装机容量将大幅度提升,是当前装机总量的 2 倍多。这种巨大的不确定性,让今年的新能源消纳指标的制定显得尤为艰难,不能够再套用之前的经验。到目前为止,国家层面的 2022 年新能源利用率目标尚未制定。但是国家能源局“合理利用率”的提法相较之前更进一步,体现了新能源高质量发展的需求。

2021 年 5 月 25 日,国家发展和改革委员会、国家能源局正式发布《关于 2021 年可再生能源电力消纳责任权重及有关事项的通知》,对各省可再生能源的消纳考核指标进行了明确。在时间上,正式通知也提出了更密集的跟踪监测要求。虽然更具体的时间节点,有利于加强监管,促进目标有序完成,但这无疑大大增加了可再生能源电力消纳责任权重的考核力度。

1.2 新能源合理利用率之路

1.2.1 新能源发展起步阶段

1949—1990 年,这一时期新能源占终端能源消费比重为 0。大多数技术还处在初级研发阶段。1990—2010 年,在国家产业政策作用下,新能源产业进入快速发展轨道,并出现 4 个重要的变化:①新能源利用从农村扩展到城镇。②设备从小型向大中型发展。③从研究开发走向市场化和产业化。④从着眼于

增加能源供应转向把改善环境作为主要目标。这一阶段新能源开发利用量从1990年60万t标准煤增加到2010年3260万t标准煤。“风光”等新能源已经有了较强的产业基础,中国成为世界最大整机制造、光伏组件制造国家,且在技术领域取得较大进步。2000—2008年,中国风电装机容量由2000年的34万kW增加到2008年的839万kW(图1.1)。2007年年底,中国光伏系统累计装机容量达到10万kW,并初步建立了从原材料生产到光伏系统建设等多个环节组成的完整产业链(图1.1)。




图 1.1 风电装机及占总装机比重(2000—2008 年)

2006年《中华人民共和国可再生能源法》开始施行,这是可再生能源发展历程中的标志性事件。该法案通过“设立可再生能源发展基金”(通过对所有工商用电加价来获取补贴资金)与“全额保障收购”(电网企业全额收购风电和光伏发电)两项规定,极大促进了中国可再生能源的发展。这段时间主要是以特许招标权的形式小规模推进风电和光伏发电的装机投资。风电的最低招标价格一度降到0.38元/(kW·h)。光伏发电的招标价格在0.7288~0.9907元/(kW·h)。

甘肃省风电发展从1996年起步,1997年从丹麦引进4台单机容量为300kW的风电机组,在玉门建成了甘肃省第一座示范型试验风电场。2008年11月国内第一个装机容量为1MW的并网型光伏电站——大唐武威太阳能电站建成投入运行,标志着甘肃省光伏产业迈上了新台阶。

1.2.2 新能源快速发展阶段

2009 年哥本哈根气候大会之后,中国提出 2020 年中国非化石能源消费比重提高到 15% 的发展目标。这 15% 的目标承诺主导了 2009 年之后中国风电和光伏发电行业 10 年大发展。全国风能资源按照由强到弱的顺序依次划分为 I 类风能资源区至 IV 类风能资源区,2009 年基于不同风资源区制定了风电固定上网电价政策,分别为 0.51 元/(kW·h)、0.54 元/(kW·h)、0.58 元/(kW·h)和 0.61 元/(kW·h)。为鼓励风电发展,中国将固定上网电价制定得较高,普遍高于之前的特许招标价格。当时光伏发电的成本远高于风电。2010 年,中国光伏发电总装机容量只有 80 万千瓦,但光伏制造却占到全球光伏产能的 50%。2011 年制定了光伏发电固定上网电价政策,为 1 元/(kW·h),高于之前的招标价格。2009 年和 2011 年的政策调整,为中国风电和光伏发电行业的超高速增长提供了契机。

图 1.2 显示,从风电行业来看,仅 2009 年装机容量就达到 1760 万 kW,是 2008 年 839 万 kW 的 2 倍。2010—2020 年,风电装机容量由 2958 万 kW 增长至 28199 万 kW,年均增长率高达 29.8%。中国太阳能光伏发电行业起步于 2009 年,此后 2010 年和 2011 年的 2 年内,增速高达 147% 和 204%。2012 年和 2013 年增速依然达到了 116% 和 164%,随后的 2014—2020 年,光伏发电的装机容量由 2839 万 kW 增长到 25383 万 kW,平均增速达 47.8%,中国的光伏产业进入了高速发展时期。




图 1.2 风电、光伏装机容量及增速(2009—2020 年)

1.2.3 “十四五”时期新能源发展形势

受诸多政策利好消息影响,中国可再生能源步入新一轮快速发展期。国家能源局公布的数据给了最有力的说明:截至2020年年底,中国可再生能源发电装机容量规模达到9.3亿kW,占总装机的比重达到42.4%,可再生能源发电量达到2.2万亿kW·h,占全社会用电量的比重达到29.5%。根据国家能源局的规划,“十四五”期间可再生能源发展将进入一个新阶段。反映在数字层面,即到“十四五”末,可再生能源的发电装机容量占中国电力总装机容量的比重将超过50%。

新能源装机增长将更加强劲。“十四五”期间,随着风电和光伏发电技术的不断进步,资源丰富地区的风电、光伏发电将逐步全面实现平价上网、成本优势以及碳中和目标的要求,推动新能源发展速度进一步加快。“十四五”期间预计中国年均新增新能源装机容量将远超过6000万kW,达到1亿kW的规模。

分布式新能源和储能技术快速发展。随着光伏发电成本的下降、平价上网政策的实施以及中东部地区基本全额消纳的电力系统条件,分布式光伏发电将以“全民光伏”的形式迅速增长。加之储能电池成本的快速下降,“光伏+储能”、大规模储能、综合能源系统等将在用户侧全面发展,分布式光伏装机容量很快将超过集中式光伏装机容量。

新能源装机布局变化明显。“十四五”期间,受“三北”(东北、华北、西北)地区新能源消纳困难影响,新能源装机空间分布将继续向消纳形势较好的中东部转移。另外,随着技术进步、成本下降和建设经验的积累,“十四五”期间中国海上风电将迎来大发展,具备建设条件的海上风电将全面开工,接入消纳条件好的华北、华东电网。中国将成为全球海上风电增速最快、潜力最大的国家。

市场成为促进新能源消纳的有力手段。电力系统市场化改革继续向纵深发展,调峰调频等辅助服务、省间电力交易、现货市场等将快速发展,市场机制不断完善,新能源电力将越来越多地通过市场来消纳,市场将成为促进新能源消纳的有力手段。

第

2

章

新能源发展隐忧及挑战

2.1 “红色预警”之痛

伴随着新能源产业的超常规发展,风电和太阳能发电装机容量的高速攀升,清洁能源产业不断发展壮大,为建设清洁低碳、安全高效的能源体系做出了突出贡献。但由于整体经济发展水平不高,电力消纳容量有限,经过连续多年爆发式增长,出现了严重的“弃风”现象,清洁能源发展不平衡、不充分的矛盾也日益突显。图 2.1 显示,全国范围内从 2015 年起,弃风量大幅度上升,2016 年出现了 498 亿 $\text{kW} \cdot \text{h}$ 的最大弃风量,随后弃风率逐年下降,2019 年平均弃风率只有 4%(图 2.1)。




图 2.1 全国弃风量及弃风率(2011—2019 年)

纵观全国,2012 年中国弃风率达 17.12%,成为有史以来“弃风”最为严重的一年。2015—2018 年是弃风量比较严重的年份,特别是西北地区形势显得尤为严峻,已经成为未来清洁能源发展的心腹大患。2015 年,风电弃风限电形势加剧,全年弃风电量 339 亿 $\text{kW} \cdot \text{h}$,同比增加 213 亿 $\text{kW} \cdot \text{h}$,平均弃风率 15%,同比增加 7 个百分点。全国风电平均利用小时数 1728 h,同比下降 172 h,利用小时数最高的地区是福建 2658 h,利用小时数最低的地区是甘肃 1184 h。其中弃风较重的地区是内蒙古(弃风电量 91 亿 $\text{kW} \cdot \text{h}$ 、弃风率 18%)、甘肃(弃风电

量 82 亿 kW·h、弃风率 39%)、新疆(弃风电量 71 亿 kW·h、弃风率 32%)、吉林(弃风电量 27 亿 kW·h、弃风率 32%)。

2016 年 7 月,国家能源局发布《国家能源局关于建立监测预警机制促进风电产业持续健康发展的通知》,风电投资监测预警机制启动。当年,全国“弃风”较为严重的地区是甘肃(弃风率 43%、弃风电量 104 亿 kW·h)、新疆(弃风率 38%、弃风电量 137 亿 kW·h)、吉林(弃风率 30%、弃风电量 29 亿 kW·h)、内蒙古(弃风率 21%、弃风电量 124 亿 kW·h)。此外,陕西弃风率为 6.61%,青海未发生弃风限电现象。光伏发电方面,新疆、甘肃光伏发电运行较为困难,弃光率分别为 32.23%和 30.45%。宁夏弃光率 7.15%,青海弃光率 8.33%,陕西首次发生弃光限电情况,弃光率为 6.89%。因此,由于 2016 年弃风率居高不下,新疆、甘肃、内蒙古、宁夏、吉林、黑龙江 6 省(自治区)被核定为红色预警省份。2017 年,甘肃并网运行情况仍不乐观,弃风率和弃光率分别达到了 32.7%和 20.8%。2018 年,全国弃风限电量 277 亿 kW·h,同比减少 142 亿 kW·h,全国弃风率下降至 7%,下降约 5 个百分点,实现弃风电量和弃风率“双降”。大部分弃风限电严重地区的形势均有所好转。2019 年全国弃风电量 169 亿 kW·h,同比减少 108 亿 kW·h,平均弃风率 4%,同比下降 3 个百分点,弃风限电状况得到进一步缓解。其中,弃风率超过 5%的地区是新疆(弃风率 14.0%、弃风电量 66.1 亿 kW·h),甘肃(弃风率 7.6%、弃风电量 18.8 亿 kW·h),内蒙古(弃风率 7.1%、弃风电量 51.2 亿 kW·h)。3 省(自治区)弃风电量合计 136.1 亿 kW·h,占全国弃风电量的 81%(表 2.1)。

表 2.1 主要省(区)弃风率(%)

省(区) 年份	新疆	甘肃	宁夏	内蒙古	辽宁	吉林	黑龙江
2015 年	32.0	39.0	13.0	18.0	10.0	32.0	21.0
2016 年	38.4	43.1	13.1	21.0	13.0	30.0	19.0
2017 年	29.8	32.7	4.8	15.0	8.0	21.0	14.0
2018 年	22.9	19.0	2.3	10.3	1.0	6.8	4.4
2019 年	14.0	7.6	1.9	7.1	0.4	2.5	1.3

风电和光伏发电高速增长的背后凸显两大问题:一是补贴资金缺口急剧扩大;二是“弃风弃光”率很高。补贴资金缺口,即政府每年从可再生能源附加收

取的资金远少于补贴需求,形成补贴资金缺口。由于风电和光伏发电的生产成本较高,国家一开始就采取补贴驱动政策。2006年出台的《中华人民共和国可再生能源法》提出,在全国范围对销售电量征收可再生能源电价附加补偿。这一电价附加补偿经过5次调整,从2006年的0.001元/(kW·h)增加至目前的0.019元/(kW·h)。然而,若补贴全部以可再生能源附加的形式解决,按照2020年发展风电2.2亿kW、光伏电1.2亿kW,煤电、风电、光伏价差不动计算,“十三五”期间可再生能源电价附加需要调整为0.025元/(kW·h)。因此,从2014年开始,风电和光伏发电行业大规模投资增长导致补贴资金缺口急剧扩大,缺口数额从2014年年底的140亿元增长到2018年的1200亿元。从最优税收的角度,如果化石能源的污染税和碳税缺失,那么就有必要对风电和光伏发电进行绿色补贴。给定当前的装机容量,如果以项目补贴周期20年计,大致可估算中国对风电和光伏发电的总补贴金额将在2万亿元以上。“弃风弃光”率问题方面,电力的供给和需求必须实时平衡,但风电和光伏发电都缺少稳定性,只有在有风有光的条件下才能发电,最终因供需不匹配造成“弃风弃光”率较高。

解除“红色预警”的当务之急,是强化电源和电网全局统筹、均衡发展,避免新能源装机远超电网承接能力的前车之鉴。新能源“单兵突进”超常规开发模式远超电网和消纳市场承接能力,是造成甘肃前一阶段“弃风弃光”问题突出的主要原因。因此,在后期建设中,需要甘肃省在顶层设计方面对全省的电源和电网统一规划、统筹建设,避免由于配套电网和外送通道难以匹配新能源装机容量,导致高“弃风弃光”困境重现。甘肃在2016—2018年连续3年被国家能源局列入新能源消纳红色预警省份后,积极统筹电源与电网的协调发展,加大电力外送,2020年上半年,实现电能替代电量77亿kW·h,同比增长46.7%。新能源利用率达94.41%,较2017年增长24.41个百分点,推动国家能源局解除了新能源投资红色预警。国家能源局于2020年3月30日发布的新能源监测预警结果显示,风电预警结果总体为橙色,其中河东地区为绿色;光伏评价结果河西地区为橙色,其他地区为绿色。由此,也代表着自2016年开始的新能源红色预警正式解禁。

2.2 “能源不可能三角”理论

“能源不可能三角”，也称为能源三元悖论。其概念最早被提出是用于解读一个国家的金融政策：各国货币政策的独立性、汇率的稳定性、资本的完全流动性，在这三者之中，一个国家只能三选二，不可能三者兼得。而在能源层面，“能源不可能三角”指的是无法找到一个能源系统同时满足“能源环境友好”“能源供给稳定安全”“能源价格低廉”这三个条件。而目前“碳达峰、碳中和”设定了强排放约束，能源供给稳定安全和能源价格低廉成为考虑的重点问题。而其中能源供给稳定安全是保障国计民生的基础，因此经济发展方面的考量成为解决问题的关键。

能源环境友好和能源价格低廉难以同时实现。一方面，为改善环境质量，政府不断提高环保标准，引入可再生能源。但由于提升光伏、风电、水电和核电的比重需要额外的系统成本、备用成本和传输成本，将这些因素都考虑进来，新能源的发电成本会远远超过化石能源，不可避免地抬高能源的价格，其比例的提升会更为艰难。以煤炭和电力市场为例，为了减少燃煤机组对环境造成的污染，国家逐步提高环保标准，对燃煤机组进行改造，加装脱硫脱硝设施，倒逼小机组退出市场。然而，由于燃煤机组发电等行业都处在产业链的上端，当将其所造成的负外部性内部化后，上游产业成本提高，环境治理的成本会最终传导到居民端，居民面临的能源价格提高，负担加重。相似地，电力市场绿色证书交易制度的建立，确实提升了可再生能源的比例，减少了 CO₂ 排放。但是购买绿色证书的成本加上可再生能源本身的净销售价格会使得消费新能源的用电成本依旧高于消费火电的成本，且对绿色证书需求的急剧上升会吸引高价光伏绿色证书进入市场，抬高部分企业和居民的用能成本。另一方面，为保民生，政府放开能源市场竞争，利用补贴等政策降低企业和居民的用能成本，使能源价格更加低廉，但这又会与能源绿色清洁的目标相冲突。低电价更刺激了电力成本占很大比重的高耗能产业的发展，增加了污染排放，环境进一步恶化。

经济高速增长和高质量发展难以同时实现。“两个一百年”希望我国可以保证 4%~5% 的增长速度，但治理环境往往意味着我们要改变现有的粗放型增长模式，放弃高污染型产品所带来的收益，通过降低增长速率来保证增长的质

量。中国的经济增长主要依靠的是要素资源的大量投入,而非全要素生产率的大幅提升,产业增长呈现出对投资和资源高度依赖的特征。根据统计数据:中国工业的终端能源消费量远远大于农业部门、建筑业部门和生活部门,占比持续大于 68%,而其行业增加值占比如图 2.2 所示。此外,图 2.3 展示了 2011—2020 年 GDP 增速与能源消费增速的变化趋势。由此可见,两者之间存在一定的相关性,2017 年以来能源消费总量均处于低速增长状态,实现了以较低的能源消费增速支撑经济的中高速发展。由此可见,在产业结构调整阶段,要想减少污染物排放、改善环境质量,就势必会牺牲一部分 GDP 的增长,而是否应该牺牲以及要做出多大程度的牺牲都是矛盾所在。

建立高效的能源经济体系、平衡生态环境保护与经济社会发展之间的关系,是当前甘肃省乃至中国经济中长期发展的重大命题。现代能源经济体系的建立需要以资源禀赋、技术发展水平和经济发展为基础,实现市场和政府之间合理分工协调、能源结构逐步优化和能源运行机制完善高效,解决市场失灵,减少能源不平等和保障国家能源安全。即便如此,甘肃省仍面临能源价格合理、能源供给充足和能源节能环保这 3 大目标难以同时实现的“能源不可能三角”。基于此,在禀赋和偏好下进行权衡抉择尤为重要。在需求侧,以经济增速放缓为代价,淘汰部分高耗能企业和产品,优化产业结构;在供给侧,以增加企业 and 个人的用能成本为代价,提升非化石能源比重和实现化石能源的清洁利用,优化能源结构,以助力实现“双碳”目标的达成。




图 2.2 分产业能源消费占比




图 2.3 GDP 增速与能源消费增速

2.3 新能源发展新机遇

2018 年以后,中国通过一系列改革试图解决新能源消纳问题。随着新能源领域技术进步,以及新的商业模式出现,尤其在光伏发电和风电领域,成本下降非常迅速。首先,最重要的措施是全面推广电价竞标,即上网电价不再由政府定价而是由市场竞争来决定。由此消除价格管制,同时引入补贴的价格竞争机制。此举首先解决了政府定价中的信息不对称问题,真实还原发电成本。光伏发电行业在国家能源局《关于 2018 年光伏发电有关事项的通知》(简称“531”新政)后全面推广电价竞标,新增装机从 2017 年的 53 GW(1 GW 等于 100 万 kW)超大规模降到了 2019 年的 30 GW。2020 年,参与价格竞标的 26 GW 项目中,最低竞价为 0.2427 元/(kW·h),加权平均 0.372 元/(kW·h)。2020 年,平价上网项目为 33 GW,同时,自 2021 年起取消新核准的陆上风电补贴。其次,引入了企业竞争。将发电项目资源配置到经营效率最高的企业,有利于高效率企业的做大做强以及行业整合,因此,2018 年以后行业的整合度大幅增加。此外,2019 年 5 月 10 日,国家能源局正式发布《关于建立健全可再生能源电力消纳保障机制的通知》。经过 10 余年酝酿、博弈、征求意见之后,可再生能源配

额制对每个省制定了最低可再生能源消费占比额度,以可再生能源电力消纳责任权重的形式落地,致使 2020 年全国电源新增装机容量达 19087 万 kW,其中水电 1323 万 kW、风电 7167 万 kW、太阳能发电 4820 万 kW。

“双碳”目标的提出也为可再生能源产业的进一步发展提供了契机。碳达峰、碳中和目标指引并推动着中国能源产业不断向低碳高质量方向发展,力促经济、能源与生态协同共赢。然而,传统的粗放式发展模式已经无法适应当前需求,实现“双碳”目标,需要推动传统能源结构的调整重构,实现能源低碳转型。节能减排是实现能源低碳转型的首要选择,可再生能源发展是实现能源低碳转型的主要方式,清洁高效利用是实现能源低碳转型的重要途径。为此,2020 年我国有关部门发布了《关于促进非水可再生能源发电健康发展的若干意见》《关于建立健全清洁能源消纳长效机制的指导意见(征求意见稿)》和《关于开展跨省跨区电力交易与市场秩序专项监管工作的通知》,分别从新能源补贴、消纳和市场交易方面制定了相关政策。此外,针对风电发展,我国有关部门于 2019 年 5 月和 12 月分别发布了《国家发展和改革委员会关于完善风电上网电价政策的通知》和《2019 年风电项目建设工作方案》,推进了平价上网电价项目的开展。同时,光伏产业被列为西部地区新增鼓励类产业。

能源转型进程中,一些诸如储能、氢能、能源互联网等新技术的突破,有可能重塑能源系统,新的能源系统将更具有柔性、开放性和兼容性。在储能的应用中,能源的大规模接入会对电网安全稳定带来冲击,大规模储能可以用来减少波动性,避免对电网的冲击;分布式就地消纳虽然可减少了对电网的冲击,但小型储能系统仍然是这种分散式利用商业化的必要条件之一。而氢能作为洁净的二次能源,能方便地转换成电和热,具有转化效率高、来源途径广、噪音低以及零排放等优点。其将广泛应用于交通运输行业并颠覆能源格局,技术成熟氢能汽车将取代传统燃油汽车和“传统”电动汽车。同时,采用可再生能源实现大规模制氢,可能实现由化石能源顺利过渡到可再生能源的可持续循环,催生可持续发展的氢能经济。此外,数字化、能源互联网、微电网、虚拟电厂、区块链等领域的技术进步,也逐渐渗透至能源系统内部,不仅有利于提高能源系统的包容性,而且更加丰富了新能源利用的商业模式,对新能源产业将是新的机遇。

为了“双碳”目标的如期实现,在相关政策的扶持下,急需充分利用新能源存量优势,加速完善新能源发展的基础设施建设、理顺制约新能源发展的管理体制等瓶颈,构建以新能源为主体的新型电力系统,保障新能源顺利消纳。

2.4 新能源发展面临的挑战

判断新能源的发展成绩不能唯规模论,必须要考虑发展速度与质量,其中新能源消纳始终是个关键点。与传统化石能源不同,风能和太阳能固有的随机性、间歇性和不稳定性,会对电网的安全稳定运行带来极大的不利影响。为了“碳中和”目标的实现,提高可再生能源占比是必然途径。当可再生能源规模大幅提升时,电网的消纳瓶颈将会显现。

在“碳中和”目标指引下,人们对风电、光伏等新能源产业发展热情高涨。国家能源局公布的数据显示,2020年,中国新增风电装机7167万kW、太阳能发电4820万kW,风光新增装机之和约为1.2亿kW,远超市场预期。考虑到2030年中国风电、光伏发电总装机容量达到12亿kW以上的目标,持续暴增的新能源装机量将面临消纳困境。尤其是资源富集地与电力消费不匹配及技术因素、体制障碍等诸多问题,导致新能源消纳面临诸多问题。其中,新能源爆发式增长与用电需求增长放缓矛盾突出,是消纳难的一个方面。2012—2016年,全社会用电量年平均增长率4.5%,风电装机容量年平均增长率26.4%。近5年来,全国用电量年均增长5%,同期电源装机年均增长近10%,新能源装机年均增长高达30%以上,新增用电市场无法支撑各类电源的快速增长。另一方面,缺乏灵活调节电源系统、调节能力不充足也导致消纳难。新能源发电具有间歇性、波动性等特征,大规模并网对电网稳定性、连续性和可调性造成极大影响,因此对电力系统调峰能力提出很高要求,而目前系统缺乏灵活调节电源,调峰能力不足。还有一个非常重要的原因,在于电力体制的改革程度不够,利益壁垒仍未消除。从深层次来讲,当前新能源消纳难、并网难不仅仅是新能源自身特点造成的,更是电力体制下各相关主体目标不一致,利益关系不畅所致。在国家大力倡导绿色能源大背景下,新能源具有优先上网、调度的优势,火电企业往往被迫为新能源调峰,企业利益得不到保证,形成“风火竞争”“光火竞争”利益格局,尤其是在能源需求放缓时,这一问题尤为突出。

目前,局部地区已形成了高比例新能源电力系统。受风资源、光资源、土地资源等因素影响,当前新能源占比高的省(区)的装机仍将进一步发展。

“十四五”期间,高比例新能源电力系统将从局部地区向全国扩展且比例进一步提升。

高比例新能源加大电力系统电力平衡难度。新能源随机波动性强,高比例新能源并网将导致发电波动大幅增加。2019年国家电网有限公司经营范围内新能源日最大功率波动已超过1亿kW,山东、山西、宁夏、新疆等地区日最大功率波动已超过1000万kW。在电源跟随负荷变化调节的运行要求下,其他常规电源必须跟随新能源波动调节。然而,中国电源结构以火电为主,可随新能源波动灵活调节的电源较少,未来高比例新能源并网将导致电力平衡非常困难。

高比例新能源并网导致电网安全稳定运行风险剧增。新能源发电具有弱支撑性和低抗扰性,随着新能源大规模接入,常规电源被大量替代,系统转动惯量和调频、调压能力持续降低,电网发生大范围、宽频带、连锁性故障的风险持续累积。同时,新能源机组有功调节能力不足,导致系统频率控制能力不断下降,故障冲击下电网频率跌落速度更快、幅度更大。新能源集中接入地区短路电流水平普遍较低,故障冲击下电压波动大,易引发新能源连锁脱网事故。此外,大量分布式新能源接入配电网可能引起系统功率失衡、线路过载、节点电压超限等问题,对供电可靠性带来极大挑战。

新能源发电单元与可控负荷信息感知能力不足,难以支撑精细化调控。新能源发电单元总量远超常规水电、火电机组,全国目前有超过6000座大型新能源电站和几百万个低压接入的分布式发电系统,未来新能源发电单元数量将达到数千万,气象环境、运行控制等各类信号数十亿个。新能源发电设备运行状态感知能力弱,运行管理极其复杂,现有信息化手段不能充分满足新能源功率预测与控制、可控负荷与新能源互动等需要。

总体来说,中国新能源发展面临几大关键性问题:一是平衡发展速度和发展质量。新能源发展过程中,一直在好与坏之间寻找平衡。而“十四五”期间,更需要实现速度和质量平衡;二是总体与局部的差异性给政策制定带来挑战。宁夏、甘肃、内蒙古、新疆都已超过20%,有些地区的消纳,尤其是系统性的问题仍然存在;三是集中与分散开发并举。从“双碳”目标提出可以看到,新能源的发展空间是非常大的。集中能干就干,分散能干就干,不存在集中好或分散好的问题,而是各有所长,共同发展;四是就近与跨省区消纳要同步推进。“三北”地区(东北、华北和西北)资源开发会不会重蹈弃电覆辙?其实,有了市

新能源合理利用率之路

场,行政干预再少一些,“十四五”无论从技术上、经济上都能比较好地解决这个问题;五是进市场与不进市场的艰难抉择。市场机制设计必须适应新能源的发展与消纳,新能源要积极拥抱市场;六是本体发电成本与综合利用成本的挑战。当新能源电量占比达到 40% 时,消纳成本和本体成本基本相当。所以,“十四五”消纳的成本怎么更好地疏导出去,还需要寻找解决方案。

第

3

章

新能源资源特性与 出力特性

3.1 风光资源特性

3.1.1 风能资源特性

中国气象局在 2009 年公布了最新的离地面高度为 50 m 的风能资源测量数据,其中达到三级以上风能资源陆上潜在开发量为 2380 GW(三级风能资源指风功率密度大于 300 W/m^2),达到四级以上风能资源陆上潜在开发量为 1130 GW(四级风能资源指风功率密度大于 400 W/m^2),而且 5~25 m 水深线以内的近海区域三级以上风能资源潜在开发量为 200 GW。

从表 3.1 和表 3.2 发现,青藏高原东部、横断山脉、云贵高原、东南丘陵、黄土高原、塔里木盆地等地区,由于受到地形的阻挡作用较强,属于风能资源的贫乏区。

中国风能资源比较丰富的区域主要有 3 个地区。第一个地区是东南沿海地区。中国拥有漫长的大陆海岸线,海岸线长度超过 1.8 万 km,东南沿海地区冬夏季风都十分明显,同时又有海陆风的影响,沿海地区特别是海面阻力很小,风力十分强劲。中国沿海海面拥有丰富的风能资源,是建设海上风电场的理想区域。东南沿海地区经济发达,能源需求量也很大。

第二个地区是东北和西北地区。中国东北地区的辽宁、吉林和黑龙江的西部地区,以及西北地区的内蒙古全境,加上新疆的东部地区,是中国风能资源最为丰富的区域。这一地区靠近中国冬季风的发源地,也就是靠近“亚洲高压”,冬半年风力强劲。同时这一地区的地形以高原地形为主,内蒙古高原是主要的地形单元,加上地广人稀,是中国建设风电场的理想区域,也是目前中国风电发展的重点区域。这一地区靠近中国能源主要的消费市场,比如华北地区。

第三个地区是青藏地区西北部。这一地区位于青藏高原西北部地区,地势海拔高而且平坦,气候十分干旱,地表植被稀疏,对风力的阻挡较弱,风力较为强劲。但是青藏地区由于海拔高,大气十分稀薄,风能的能量密度较低,利用难度较大。同时,青藏地区也远离中国主要的能源消费市场,开发条件不如前两个地区好。此外,风能的开发在很大程度上会受到其他能源如煤炭和石油的价格影响。因为风能开发成本较高,如果煤炭和石油价格低廉,风能开发就会受

到抑制;反之,如果煤炭和石油价格昂贵,那么风能开发就会加速。

表 3.1 中国风能分区及占面积比

指标	丰富区	较丰富区	可利用区	贫乏区
年有效风能密度/(W/m ²)	≥200	200~150	150~50	≤50
年≥3 m/s 累计小时数/h	≥5000	5000~4000	4000~2000	≤2000
年≥6 m/s 累计小时数/h	≥2200	2200~1500	1500~350	≤350
占全国面积的百分比/%	8	18	50	24

表 3.2 中国风能资源分布

风功率密度		分布地区
三北地区风能丰富带	>200~300 W/m ²	三北指的是东北、华北和西北,包括东北三省、河北、甘肃、青海、西藏和新疆等省(自治区)
沿海地区风能丰富带	>200 W/m ²	台山、平潭、东山、南鹿
内陆地区风能丰富带	<100 W/m ²	鄱阳湖、湖南衡山、湖北九宫山、河南嵩山、山西五台山、安徽黄山、云南太华山等
海上风能丰富区		中国近海 50 m 等深线浅海域 10 m 高度,包括福建、江苏、山东、浙江、辽宁、上海、河北、广西、海南、天津等省(市)

甘肃省能源资源富集,开发潜力巨大。甘肃省在中国能源发展总体布局和“西电东输”战略规划中,是重要的能源外送基地。根据中国气象局风能太阳能资源评估中心的《中国风能资源评估(2009)》,甘肃全省有效风能资源理论储量为 2.37 亿 kW,占全国总储量的 7.3%,技术可开发量 2700 万 kW,占全国的 10.6%。其中,风能资源丰富区和季节可利用区域的面积为 17.66 万 km²,占全省总面积的 39%,年平均风功率密度在 150 W/m² 及以上的区域占全省总面积的 4%。甘肃省的风能资源主要分布在河西走廊。在这一绵延 1000 多千米的狭长走廊内,有“世界风库”瓜州、“风口”玉门,许多地方都有建设大中型风力发电站的良好条件。并且这里没有台风,全年最低温度不低於-29℃,适于风电机组的建设和全年运行。还有大面积的荒漠可利用,广布风电场,可以减少同一地区季风变化带来的限制,形成“此起彼伏”的优势,降低运行成本。另外,在张掖、武威、金昌、白银、庆阳北部的部分地区可装机密度达到 2 MW/km² 以上,其中个别地区能达到 4~5 MW/km²,也具备开发百万千瓦级以上大型风电场的条件。

3.1.2 太阳能资源特性

中国属太阳能资源丰富的国家之一,全国总面积 2/3 以上地区年日照小时数大于 2000 h,年辐射量在 5000 MJ/m^2 以上。据统计资料分析,中国陆地面积每年接收的太阳辐射总量为 $3.3 \times 10^3 \sim 8.4 \times 10^3 \text{ MJ/m}^2$,相当于 2.4×10^4 亿 t 标准煤的储量。

按照中国气象局风能太阳能评估中心划分标准,中国太阳能资源地区分为以下五类:

(1)一类地区(资源最丰富带)。全年日照时数为 3200~3300 h,全年辐射量在 $6700 \sim 8370 \text{ MJ/m}^2$,相当于 225~285 kg 标准煤燃烧所发出的热量。主要包括青藏高原、甘肃北部、宁夏北部和新疆南部等地。

(2)二类地区(资源较丰富带)。全年日照时数为 3000~3200 h,全年辐射量在 $5400 \sim 6700 \text{ MJ/m}^2$,相当于 200~225 kg 标准煤燃烧所发出的热量。主要包括河北西北部、山西北部、内蒙古南部、宁夏南部、甘肃中部、青海东部、西藏东南部和新疆南部等地。

(3)三类地区(资源一般带)。全年日照时数为 2000~3000 h,全年辐射量在 $4200 \sim 5400 \text{ MJ/m}^2$,相当于 170~200 kg 标准煤燃烧所发出的热量。主要包括山东、河南、河北东南部、山西南部、新疆北部、吉林、辽宁、云南、陕西北部、甘肃东南部、广东南部、福建南部、江苏北部和安徽北部等地。

(4)四类地区(资源较少区)。全年日照时数为 1400~2000 h,全年辐射量在 4200 MJ/m^2 以下,相当于 140~170 kg 标准煤燃烧所发出的热量。主要是长江中下游、福建、浙江和广东的一部分地区,春夏多阴雨,秋冬季太阳能资源还可以。

(5)五类地区(资源最少区)。全年日照时数约 1000~1400 h,全年辐射量在 $3350 \sim 4200 \text{ MJ/m}^2$ 。相当于 115~140 kg 标准煤燃烧所发出的热量。主要包括四川、贵州两省。此区是中国太阳能资源最少的地区。

一、二类地区,年日照时数大于 2200 h,是中国太阳能资源丰富或较丰富的地区,面积较大,约占全国总面积的 2/3 以上,具有利用太阳能的良好资源条件。

3.1.3 甘肃太阳能资源特性

太阳能资源通常用年太阳总辐射量表示,甘肃省辐射资源的平均分布状况呈

现明显的区域性差异。甘肃省各地太阳总辐射值在 $4700\sim 6350\text{ MJ/m}^2$,其地理分布有自西北向东南递减的规律。酒泉、敦煌所在的西北部辐射量最大,年平均总量能达到 6000 MJ/m^2 以上,最高处能有 6500 MJ/m^2 ;河西走廊的年总辐射量次之,在 $5500\sim 6000\text{ MJ/m}^2$ 。最低处为甘肃省的东南部,平均为 5000 MJ/m^2 左右(图 3.1)。




图 3.1 甘肃太阳能分布图

(1)太阳能资源丰富区。包括河西走廊的酒泉、张掖、嘉峪关全部。本区年太阳总辐射量大于 6100 MJ/m^2 ,年日照时数 $2900\sim 3319\text{ h}$,日照百分率大于 64% ,每年太阳日照时数大于 6 h 的天数在 290 d 以上,太阳能资源稳定。

(2)太阳能资源较丰富区。包括金昌、武威、民勤的全部,古浪、天祝、靖远、景泰的大部分,定西、临夏部分地区,环县部分地区及甘南州玛曲的部分地区。本区年太阳总辐射量在 $5400\sim 6100\text{ MJ/m}^2$,年日照时数 2600 h 以上,日照百分率 $>58\%$,每年太阳日照时数大于 6 h 的天数在 260 d 以上,本区大部分地区太阳能资源稳定,个别地区属于资源较稳定区。

(3)太阳能资源可利用区。包括天水、陇南、甘南地区大部。本区年太阳总辐射量在 $4700\sim 5400\text{ MJ/m}^2$,年日照时数小于 2600 h ,日照百分率 $<58\%$,每

年太阳日照时数大于 6 h 的天数在 150 d 以上,本区大部分地区太阳能资源属于较稳定,个别地区属于资源稳定。

3.2 风光出力特性

3.2.1 风力出力特性

根据测风数据,风电出力呈现明显的季节特性,具有冬春季较小、夏秋季较大的特点。风电基地在一年的大部分天内,会有风速在接近零风速与额定风速之间变化的情况。与此对应,风电出力在全天大部分时间内都会有在接近零出力与额定出力之间变化的现象。酒泉风电基地折算后的日平均出力波动范围很大,最小值接近于 0,最大值接近于 24 h 满出力。风力发电具有一定的季节性,同时风力发电出力还与地理环境等综合因素有关。其时序特性曲线如图 3.2 所示。




图 3.2 风力发电时序特征

3.2.2 光伏出力特性

光伏出力与光照情况相关,呈现典型的钟形曲线(图 3.3),光伏最大出力一般发生在中午 12:00 至 13:00,晚 18:00 至早 6:00 光伏出力接近 0。光伏发电

除了具有一定的季节性,光伏发电出力不仅与季节有关还与天气有关。光伏电站日出力主要受天气影响(图 3.4)。在晴朗天气,光伏电站在白天中午时分出力达到最大,且曲线比较平滑,出力分布较规律;在多云天气,出力的白天时段分布没有规律。受光照强度和温度影响,光伏电站一般在春季、冬季发电出力较大。从甘肃、青海地区光伏电站的年出力分布来看,平均出力呈现春秋季节较大、夏冬季较小的特点。由于用电负荷一般在夏冬季较大,因此,光伏电站对于满足高峰负荷的贡献度有所降低。




图 3.3 光伏发电时序特征




图 3.4 不同气象条件下的光伏电站每日出力曲线

3.3 新能源总体出力特性

3.3.1 新能源出力波动性

新能源发电功率的大幅波动对电网影响非常大。按照甘肃省实际情况,10:00—17:00 新能源发电能力强,13:00 出力达日均出力的 175%;其余时段新能源发电能力较弱,降到平均出力的 70%以下。以日内均值为基准,新能源平均波动范围为 66%~175%,波动幅度超过了 100%。日内新能源最大波动幅度曾出现 15 h 内从 1422 万 kW 下降到 84 万 kW 的情况,波动幅度接近当日平均用电负荷(1371 万 kW)。

3.3.2 新能源出力随机性

新能源出力的随机性极强,短期超短期预测难度极大,一是因数值天气预报的偏差导致预测大幅偏差(图 3.5);二是时间的准确性难以保证,发电趋势与预测一致,但时间有可能提前或推迟(图 3.6)。

为了促进新能源消纳,甘肃电网在安排火电机组开机方式时按照晚高峰无风情况下负备用 200 万 kW 控制火电机组开机方式,为新能源腾出更大的消纳空间。但受新能源发电随机性及反调峰特性影响,经常造成晚高峰时电网电力无法平衡,在西北电网整体负备用成常态化的情况下,系统备用不足风险逐步加大,会造成甘肃电网大量购入外省电量或者降直流运行。




图 3.5 因天气预报的偏差导致的预测大幅偏差典型图




图 3.6 趋势一致而时间有偏差的典型图

3.3.3 新能源高电力、低电量特性

风电出力随机性和波动性强,发电出力特性的统计分析难度大。根据特许权风电场运行特性分析,其发电出力、发电量统计数据表明,风电场发电出力达到装机容量的 40%,所发电量可占到总可发电量的 74%;95%的发电量产生于出力低于额定容量的 70%时刻,具体统计结果见图 3.7。




图 3.7 风电不同出力所占总发电量比例

根据特许权项目等不限电光伏电站发电出力、发电量统计数据表明,光伏电站发电出力达到装机容量的 50%,发电量可占到总可发电量的 74.86%,95%的发电量产生于出力低于额定容量的 70%时刻,具体统计结果见图 3.8。

新能源的这种特性决定了增加外送及用电负荷,实际是提升了新能源的发电负荷率。当负荷率越高,其可增发电量越小,电网所需要的常规电源调峰电量越大。




图 3.8 光伏不同出力所占总发电量比例

3.3.4 新能源反调峰特性

由于甘肃省风电装机占比大，甘肃省风电基本全部表现为反调峰特性。光伏虽然在平段及早晚高峰发电，但最大出力已经超过全网峰谷差，正调峰率只有 50%。以新能源出力波动最大日发电曲线可以看出，虽然新能源日发电量很大，但集中在用电低谷期间，而晚高峰用电高峰期间，新能源出力偏低，与用电负荷波动特性严重不匹配，呈现出典型的有电力，无电量特性(图 3.9)。




图 3.9 新能源反调峰特性图

自甘肃省新能源快速发展以来，甘肃省电力系统由传统的只需平衡负荷波动，转换为既需要平衡负荷波动，又需要平衡新能源出力波动，系统对常规电源的调峰需求增加。

第

4

章

新能源消纳受限情况

4.1 国外新能源消纳受限情况

4.1.1 美国弃风、弃光情况

美国通过区域传输组织(RTOs)和独立系统运营(ISOs)来管理整个输电系统的运行,美国各个区域风电、光伏消纳情况良好,有一定弃风现象,均在5%以内,弃光现象只在美国得克萨斯州(简称得州)和加利福尼亚州(简称加州)出现,加利福尼亚州弃光率缓慢增加,在2%以内,得克萨斯州2018年弃光率为8.6%(图4.1)。




图 4.1 美国各电力机构弃风、弃光率

美国弃风、弃光主要原因包括：系统调峰能力不足、市场价格低于预期、新能源参与辅助调峰服务、线路约束和意外的线路中断、异常情况的紧急调度。

美国采取的主要措施包括：

电源——提升风光预测模型精度,提高常规机组灵活性。

电网——扩建远距离输电线路,提高已有线路利用率,加强区域协调。

负荷——采用分时电价,进行适当的需求侧管理,扩大电动汽车规模。

政策——通过立法保证新能源享有税收优惠和发电补助。

运行——优化火电机组发电/启停计划,新能源接受自动发电控制 ACG

(Automatic Generation Control)的控制,减小调度间隔。

市场——新能源参与实时交易市场,通过负电价引导自愿弃风、弃光,规定无偿弃风、弃光的基数和有偿弃风、弃光的补偿办法。

储能——优化储能充放电策略,合理配置储能电站,引入氢储能、化学储能等项目。

规划——提高负荷中心南部地区新增新能源装机容量配额。

4.1.2 德国弃风、弃光情况

德国光伏近 10 年弃光率均在 1% 以内,其风电从 2015 年开始出现了一定的弃风现象,弃风率达到 5%。该年新能源装机容量增长快,且由于风电主要分布在人烟相对稀少的北部和东部地区,而德国电力负荷中心分布在人口较稠密的南部地区,部分时段输电网阻塞,弃风电量从 2014 年的 1.2 TW·h 增加到 2015 年的 4.1 TW·h(图 4.2)。




图 4.2 2011—2019 年德国弃风情况

德国弃风、弃光主要原因包括:该年风力资源与历史均值相比更为丰富,大风期持续时间更长,全年的风力发电量较之前增长迅猛。风电集群和负荷中心分布的不一致,导致输送通道拥堵,本地无法消纳的电能难以送出。

德国采取的主要措施包括:




图 4.3 2011—2019 年德国弃光情况

电源——改进与可再生能源相关的天气预测，提高常规机组灵活性。

电网——扩建远距离输电线路，提高已有线路利用率。

负荷——推进电能替代，组建负荷聚合商或虚拟电厂参与辅助服务市场。

政策——德国可再生能源法案规定可再生能源拥有优先发电权。

规划——提高负荷中心南部地区新增新能源装机容量配额。

总的来说，仅看欧洲单一国家或许有些国家新能源接入比例很高，但其弃风、弃光率又非常之低甚至为 0，这似乎与前文所述“新能源具有不确定性，高比例接入弃风、弃光不可避免”这一论点相悖。然而事实上，“高渗透率低弃风、弃光率”是建立在强有力的欧洲互联电网之上的。丰富的传输通道，合理的电力市场机制，使得这种现象成为可能。

4.2 国内新能源消纳受限情况

中国新能源发展规模持续领跑全球，以风电、太阳能发电为代表的新能源逐渐显现出从替代电源向主流电源发展的喜人态势。新能源消纳形势取得显

著好转,弃电量持续下降,新能源利用水平不断提高。新能源是中国能源转型的主要力量,未来还将持续快速发展。在新能源持续发展的情况下,新能源消纳也将面临新的挑战。

技术因素是客观影响新能源消纳的主要因素之一。一是系统调峰能力。随着经济产业结构调整、用电结构及电源结构的变化、电网峰谷差逐渐加大,目前我国弃风、弃光主要集中在“三北(华北、东北、西北)”地区。这些地区有较长的供暖期,电网冬、夏季调峰矛盾突出;二是系统备用水平。高占比新能源地区需要保证足够的备用容量保证电网安全稳定运行。光伏昼夜出力特性、风电季节性、水电丰枯调节能力、火电供暖期等不同的特性,对系统灵活备用空间提出更高的要求;三是网架送出能力。我国资源分布与负荷中心分布有较大的差异,“三北”地区负荷占全国总负荷的比例仅为 36%,但集中了全国 75% 以上的新能源装机。其中,内蒙古、甘肃、宁夏、新疆新能源渗透率超过 100%,“三北”地区作为大规模新能源送出基地,受制于区域电力需求、网架结构、送出通道等约束,新能源消纳能力有限,需要进一步加强就地及外送消纳能力提升;四是负荷水平。受制于地域及经济增速的影响,全社会用电量和负荷需求增长缓慢,负荷增长速度严重滞后于新能源装机增长水平,系统调峰难度进一步加剧。

4.3 甘肃新能源消纳受限情况

在“十四五”及今后一段时期内,甘肃省以风、光为主的清洁能源将迎来新一轮大规模发展机遇。但受煤电发展放缓、新能源大规模发展等因素影响,甘肃省电力系统调节能力不足的问题将愈加凸显。作为目前国内外风光电比例最高的省份,其风光电建设规模远远超过全省用电市场需求,省内需求不足、外送有限导致市场消纳能力严重不足。从并网运行角度来看,甘肃省新能源发电受限原因主要包括:电网建设与新能源发展不协调不匹配、个别地区消纳能力不足、部分时段系统调峰能力不足和局部新能源富集地区通道送出受限。

(1)省内消纳空间不足且负荷特性与新能源发电特性不匹配。2020 年省内用电增长有限,新能源、水电、热电、电网安全约束电量等优先发电电量大于省内用电电量,新能源省内消纳空间仅 170 亿 kW·h。甘肃电网日负荷呈现明显

的“双峰双谷”特点,而光伏发电主要集中在 11:00—16:00,例如,在此时间段的平均出力约在 2000 MW。风电发电具有较强的随机性和波动性,日与日之间最大发电能力可相差 5 倍以上。负荷特性与新能源发电特性的不匹配导致早、晚用电高峰新能源发电能力不足与中午用电低谷时段新能源消纳能力不足并存(图 4.4)。




图 4.4 甘肃省电网日负荷曲线

(2)中长期外送交易与电网特性和新能源发电特性不匹配。甘肃省内用电负荷增长缓慢,新能源无法就地消纳,需开拓外送市场。目前,甘肃省电力总体上供大于求,属于电能输出型省份,年均富余电量已超过 300 亿 $\text{kW} \cdot \text{h}$,并逐年增加。而与此相对应,甘肃省仅有祁韶直流一条自有输电通道,远少于宁夏、青海、新疆、陕西、内蒙古等周边省(自治区)。另外,由于祁韶直流的配套火电厂机组未能完全建成投运,导致祁韶直流无法满功率运行。此外,甘肃电网二季度、三季度水电量较大,省内用电量较小,电力电量大量富余;一季度、四季度水电供应较小,火电机组因供热约束出力受限,而此时是省内用电高峰期,考虑外送后将出现时段性电力供应紧张,无法满足冬季受电省份旺盛的购电需求。

(3)基础保障性电源不足,影响电力安全供应。冬季是省内用电高峰,甘肃省冬季风电资源远低于全年平均水平,加之进入枯水期水电发电能力下降,火电机组因供热约束出力受限,2021 年冬季约有 2/3 时段存在电力缺口,最大缺口 400 万 kW ,电量缺口 46 亿 $\text{kW} \cdot \text{h}$ 。随着“十四五”期间省内用电持续增长,

除直流配套煤电外,省内规划自用电源无新增煤电,“十三五”核准的 614 万 kW 煤电项目仍处于停缓建状态,新能源发电“靠天吃饭”,可靠性电源不足的问题非常突出,加之周边省份电力支援能力有限,省内供电安全将面临严峻考验。

(4)调峰能力缺口较大,制约新能源发展。新能源出力波动大,需要配置一定规模的火电、储能作为辅助,才能形成平稳的电力曲线。调峰能力不足是制约甘肃省新能源消纳的首要因素。随着新能源装机占比进一步提高,甘肃省电力系统主要依靠煤电调峰,系统现阶段最大调峰能力仅 730 万 kW 左右,而省内调峰实际需求为 850 万~1050 万 kW,且热电机组占比高,总规模占全省火电总装机的 60.9%,同时,冬季供暖对系统调峰能力影响也比较大。2021—2023 年甘肃省存在 340~600 万 kW 调峰缺口,“新能源大发期间消纳困难、新能源小发期间电力供应紧张”矛盾将愈发突出。因此,如何解决甘肃省调峰问题将会对省内加快构建以新能源为主体的新型电力系统、推动经济社会发展全面绿色转型产生重大影响。

4.4 新能源消纳受限启示

一是新能源发展必须与电网发展和常规电源发展统筹协调。在欧洲新能源发展较快的国家,在电网规划中高度重视发挥电网综合平衡能力。政府出台了新能源保障性收购的法律或政策要求,在具体落实过程中,虽然提出未来 10~20 年新能源发展目标,但都没有拿出实现目标的具体步骤,明确电源安排、消纳市场、电网工程等。新能源发电要求有必要的灵活性,各国电网在规划、运行中都充分考虑到新能源的特殊性,首先加强抽蓄、燃机、水电等灵活调节电源建设,挖掘燃煤机组的调峰能力,弥补新能源出力的不确定性。其次加强传输通道、电网互联服务,保证当地不能消纳的新能源可以外送到其他有需求的国家或地区,并且在自身电源及新能源发电不能充分满足用电需求时,通过联络线获得外来电力补充。此外,出于电网安全考虑,建立火电机组储备机制。德国近年计划关停部分火电机组,电网运营商和德国联邦网络监管局每年都会校核电网是否安全、是否具有足够的运行灵活性,系统需要保留一定的火电机组作为安全保障,将这些电厂列为战略储备,避免被盲目关停。

二是建立新能源消纳的市场化机制是发展方向。国外新能源均从不参与市场竞争、电网全额收购、政府补贴政策,转为建立了可再生能源市场竞价和政府补贴相结合的市场化消纳机制。国外在新能源发展初期,固定上网电价加全额收购是新能源发展初期为推动产业快速发展的有效激励政策,但是随着新能源规模增大,补贴额度不断增加以及对电网运行的影响日益凸显,建立合理的政府补贴机制后参与市场,已成为新能源发展的政策调整方向,通过新能源参与市场竞价,也培育了新能源“自主决策、自负盈亏”的市场化消纳意识,鼓励其提高功率预测水平,实现新能源的资源配置。

三是新能源发展需要依托大电网,在更大空间和市场范围内消纳。新能源发电具有反调峰、间歇性和波动性等特点,扩大市场范围可以“熨平”新能源发电曲线,充分发挥联网机组的调节能力。目前欧洲电网已基本互联,各国电网之间功率交换能力比较充分。同时,在欧盟统一电力市场的建设目标的指导下,欧盟各国市场间相互开放,逐步向统一电力市场发展,促进了新能源的消纳。目前欧洲各国在欧洲输电运营商联盟 ENTSO-E(European Network of Transmission System Operators for Electricity)的协调下,签订国与国之间中长期交易,在此基础上,7个主要市场(交易所)已经实现了日前和日内市场联合出清,新能源在欧洲电力市场统一竞价,实现了新能源在其他市场消纳。

四是加强新能源功率预测以更好地适应市场和运行。调度机构开展新能源功率预测主要用于安排常规机组开机方式、留取旋转备用等用处,提高预测准确率有利于减小常规火电机组开机方式,增加新能源消纳能力。近年来国外调度机构在风电和太阳能日前、日内功率预测方面进行了持续改进和提升,提供新能源预测的社会机构已经实现了商业化竞争,调度机构可以进行多数据源对比分析,预测算法和系统功能逐步成熟,预测误差进一步缩小,中国调度机构在此方面仍有提升空间。同时,新能源发电企业出于参与市场需要,普遍开展功率预测工作,通过对自身发电能力的准确掌握更好地参与市场,降低市场竞争风险。

五是充分发挥需求侧响应机制促进新能源消纳。建立新能源参与的市场机制,可以根据市场价格信号引导电力用户改变用电行为,优化负荷特性,增加新能源消纳能力。同时,负荷波动和新能源发电波动的偏差部分一般由常规电源配合调整,在常规电源调节能力不足时,可以发挥负荷侧的调节能力。西班牙建立了可中断负荷市场机制,在新能源发电大幅低于预期时,调度机构根据

新能源合理利用率之路

拍卖结果,通知可中断负荷减少用电。在中国建立可中断负荷市场化机制,可以在新能源预测偏差较大时,为调度机构提供常态化的负荷调整手段,起到减少火电机组开机方式、提高新能源消纳能力的作用。

六是发展新能源需要考虑清洁低碳和经济性安全性的权衡。新能源消纳比例较大的国家普遍存在补贴额巨大,终端用户电价持续上涨的压力。促进新能源消纳发展要求相应降低煤电、核电、燃气等传统能源的发电利用小时和电厂数量。德国在发展新能源后,关停一定数量的燃煤电厂,2022 年前还将关闭国内所有核电站。发电企业投资积极性下降,缺少长期投资激励机制,影响电力系统安全水平。

第

5

章

电网调峰能力及提升措施

5.1 电网调峰能力分析

5.1.1 甘肃电网调峰能力分析

调峰能力是制约甘肃电网接纳风电、光电能力的重要因素。高比例新能源发电使甘肃电网调峰压力增大。风能发电出力随机性强,波动性大,反调峰特征明显,基本无法与负荷匹配;太阳能间歇性、波动性特点决定了其出力稳定性难以保证。火电和水电作为重要的调峰电源,二者参与调峰的原理都是将调峰电源和新能源发电出力进行叠加,使得总体出力基本恒定。火电调峰能力较好,但调峰成本高,且深度调峰时火电年利用小时数大大降低,影响火电效益。水电调峰是利用水库的调节能力降低水电出力进而提高新能源出力,其调峰深度、成本和响应速度都较为理想。对于甘肃电网调峰能力和快速反应能力不足的问题,在充分发挥黄河上游常规水电调峰能力的基础上,配置一定规模的抽水蓄能电站,可以增强电网调峰能力,并相应提高电网接纳风电、光电的能力。

甘肃电网内火电以热电机组居多,冬季调峰能力有限,具备年调节特性的水电所占比重小。一般情况下,由常规火电承担基荷,经济火电、热电和径流水电承担腰荷,抽水蓄能水电、调节灵活的水电和不经济的火电承担短时峰荷。

(1)火电调峰能力分析

火电机组的调峰能力是指火电机组跟踪系统负荷变化的能力。火电机组调峰通常可分为正常基本调峰、深度调峰和启停调峰,深度调峰又分为不投油深度调峰和投油深度调峰。

如图 5.1 所示,其中 $P_{\max}$ 为机组最大出力; $P_{\min}$ 为给定的机组最小运行方式出力,即火电机组有偿调峰基准负荷值。当火电机组平均负荷率在 $P_{\max}$ 和 $P_{\min}$ 之间时提供基本调峰辅助服务,火电机组平均负荷率小于或等于 $P_{\min}$ 时提供有偿深度调峰辅助服务。 P_a 为机




图 5.1 火电机组调峰深度

组不投油深度调峰稳燃负荷值。

火电机组深度调峰交易采用“阶梯式”报价方式和价格机制,即不投油深度调峰报价区间为 $0 \sim 0.4$ 元/ $\text{kW} \cdot \text{h}$,投油深度调峰报价区间为 $0.4 \sim 1$ 元/ $\text{kW} \cdot \text{h}$ 。

甘肃电网火电调峰能力不足。火电为新能源调峰是指降低火电出力,提高风光发电出力。火电调峰成本高,深度调峰时运行小时数大大降低,目前甘肃电网火电年利用小时数在 3500 h 左右,火电机组最大调峰能力只有装机容量的 50%,即使在冬季火电大发期,全省最大调峰能力也只有 400 万 kW 左右。在水电大发期(5—10 月)、火电按照最小开机、最小技术出力运行方式下,低谷及早高峰时段基本无调峰能力,高峰时段最大调峰能力约 200 万 kW 。目前甘肃省纯凝火电机组调峰能力只有 50%,受供热抽汽影响,热电联产火电机组调峰能力只有 40%左右,调峰能力不足严重影响新能源消纳和电网运行灵活性。甘肃电网新能源消纳受到常规能源调峰能力不足的严重限制,若想解决火电为风电频繁调峰,火电企业运营困难,保证新能源发挥最大效益,需要国家制定相应新能源与火电配套电价政策。

火电关停风险影响调峰安全。一是煤电发电量无法满足省内需求。如果甘肃公网火电利用小时数从目前 2900 h 增加到 5000 h,需要增加煤炭消耗 1800 万 t 左右,现有的煤炭供应形势是难以支持的。二是火电安全问题。高煤价和煤炭质量下降是严重挤占火电的利润空间和现金流,造成火电企业困难;火电企业为了追求利用小时数,被迫将纯凝机组改供热运行,或者寻求非供热季常年供热,为电量而被绑在供热上,但在热价上又陷入“以电补热”的圈子里,进一步加剧了亏损,使火电基本无利可图。目前甘肃电网火电关停的苗头已经出现,一味压低火电企业发电量必然导致火电企业亏损扩大,导致大量火电企业无钱买煤被迫停运,将严重影响甘肃省的电力调峰安全。

(2) 风电调峰能力分析

风电反调峰率高。与水力发电、火力发电等常规发电方式相比,风力发电最根本的不同点在于其有功出力的随机性、间歇性和不可控性。这一特点决定了风电并网运行时,必须由常规电源为其有功出力提供补偿,以保证对负荷安全可靠地供电。这种对风电有功出力的补偿调节可看作是对负的负荷波动的跟踪,即对风电“调峰”。

风电出力对系统负荷峰谷差的影响,取决于风电日内出力变化幅度及方向

与负荷变化幅度及方向的关系。根据风电对电网等效负荷峰谷差改变模式的不同,将风电日内出力调峰效应分为反调峰、正调峰与过调峰3种情形。

风电反调峰是指风电日内出力增减趋势与系统负荷曲线相反,风电接入后,系统等效负荷曲线峰谷差增大,其典型日曲线如图5.2所示;风电正调峰指风电日内出力增减趋势与系统负荷基本相同,且风电出力峰谷差小于系统负荷峰谷差,风电接入后系统等效负荷曲线峰谷差减小,其典型日曲线如图5.3所示;风电过调峰是指风电日内出力增减趋势与系统负荷基本相同,风电出力峰谷差大于系统负荷峰谷差,风电接入后系统等效负荷曲线峰谷倒置,其典型日曲线如图5.4所示。值得说明的是,风电过调峰的情况仅在风电装机容量相对于负荷的比例较大时才有可能出现。




图 5.2 风电反调峰




图 5.3 风电正调峰




图 5.4 风电过调峰

甘肃省风电具有明显的反调峰特性,对电力系统调峰所产生的不利影响主要体现在两个方面:风电接入使系统可调机组需要应对的等效负荷峰谷差变大;可调机组需要增加应对等效负荷从低谷到高峰或从高峰到低谷变化的调峰响应能力。甘肃电网受风能的波动性、随机性影响,风电反调峰率高达 80%~90%。风电的运行对电网产生了“挖谷垒峰”的反调峰效果,进一步加大了电网的等效峰谷差,使系统的负荷特性恶化。尤其是大规模风电接入后增加了电网调度的难度,需要电网运行时留有更多的备用电源和调峰容量,不仅增加了电网运行的费用,而且扩大了全网调峰的范围,这就大大增加了调度对电网运行管理的难度。

根据风电典型日出力特性,最大平均出力出现在夜间 00:00—01:00,最小平均出力出现在 15:00—16:00,从图 5.5 中可以看出,甘肃省风电夜间的平均出力大于白天的平均出力,风电日内平均出力曲线与负荷曲线的变化趋势相反,可以推断,风电出现反调峰效应的概率大于出现正调峰效应的概率。




图 5.5 风电日内各时段平均出力曲线

(3) 光伏调峰能力分析

甘肃电网光伏发电具有削峰作用。光伏发电的规律性和波动性与风电不同,其反调峰特性与负荷峰谷特性相似。白天发电曲线为基本光滑的正弦曲线,对电网而言可以视为负的负荷,发电曲线可以与负荷曲线叠加,具有一定的削峰作用。甘肃电网日最大峰谷差率约为23%,负荷高峰表现为早高峰和晚高峰,甘肃电网以负荷晚高峰最为突出。晴天光伏电站存在典型发电曲线可以与负荷曲线叠加,白天光伏发电对负荷具有削峰作用,增加系统调峰压力,但对晚高峰不具备调峰能力,且电网夜间小负荷方式光伏出力为零。因此,在理论上可认为光伏能够承担电网负荷中的腰荷,在光伏出力小于最大平均负荷时无须考虑调峰问题。

甘肃电网夏季和冬季典型日负荷特性及光伏典型日发电特性一般是光伏发电时段对应于大负荷时段,最大出力时刻系统通常处于腰荷位置。因此,白天光伏曲线与负荷曲线叠加之后形成更为平直的负荷特性曲线,光伏发电替代部分常规调峰电源,一定程度上减小了系统的调峰需求容量。因此,对含大规模光伏电站的电力系统而言,当光伏群整体发电出力小于系统腰荷与低谷之差时,不需要电网新增调峰容量,相反可以为风电腾出部分调峰容量。可以说,即使不采用储能技术,光伏发电也具有显著的并网潜力。仿真分析表明,电网的调峰能力是无储能光伏发电接入能力的主要限制因素,光伏并网的目标是以尽可能低的成本增加光伏电量的占比,而不是保证百分之百的容量利用率。

(4) 水电调峰能力分析

甘肃省阶梯水电站调峰能力有限。水电的季节性波动大,日波动较小。当水电厂水库具有一定调节库容时,水库的蓄水可以平抑来水的短期波动,但对于年季或季节性来水波动,大多数水电厂调节能力不足。除黄河、白龙江梯级水电具备调峰能力外,其余的均为径流式水电站或者地方小水电站,基本不具备调峰能力。刘家峡水电厂受防凌、防汛、社会用水的约束较多,可用于电网调峰的容量有限,一般认为刘家峡及其下游梯级水电厂参与负荷调峰,而不参与风电调峰。甘肃电网除10月、11月外,其余时刻由于受到黄河进入防凌期后,梯级水电站出力向上调整能力受限;水电大发期间,机组负荷向下调节能力受到限制,总体对电网的调峰能力减弱,尤其在上游来洪水期间,水电机组基本满发,基本丧失调峰能力。因此,可以利用光伏发电白天多,夜间低的特性,全网

新能源合理利用率之路

水电在光伏白天大发时期降低出力运行,为了尽可能多地提升调峰能力,2014年年底甘肃电力部门编制下发《甘肃电网水电配合新能源调度规则》,要求全网水电在 9:00—17:00 光伏大发时段或风电大发时段尽量少发,在系统消纳能力一定的情况下,为新能源发电腾出消纳空间;并要求黄河梯级水电根据电网情况在后夜低谷时期大发,刘家峡水电厂以下梯级水电早上 9:00 水位必须降低至要求水位,为白天光伏大发错峰。

电网调峰稳定运行,需要一定规模的抽水蓄能电站。根据中国能源资源特点,今后相当长时期内的电源仍将以燃煤火电为主。火电机组调峰方式主要是常规的出力调峰方式和非常规的开停机调峰方式,满足不了系统负荷急剧变化的要求,易发生设备事故,对电网的安全运行有一定影响,而且调峰运行时发电煤耗上升、厂用电率高、设备损耗加大、检修费用增加,发电成本高。常规水电机组开停机迅速,运行灵活,具有较强的调峰能力。但是水电机组出力受季节和水库水位的影响较大,尤其是水库调节性能差、水库库容小的水电站,参与调峰受到很大限制。抽水蓄能电站兼有调峰和填谷的双重功能,同时具有调频、调相、黑启动、事故备用的功能特点,调峰幅度大,启动速度快。可通过替代火电机组的负荷调峰或旋转备用容量,腾出火电调节容量为新能源发电提供调峰能力。抽水蓄能电站是当前最具规模化和最经济的“储能”方式。利用这种独特的“储能”功能,可以平滑风电、光电的出力过程,减轻对电网安全稳定运行的影响;抽水蓄能电站是构建“多能互补”平台的关键组成部分。抽水蓄能、风电、光电、水电、火电等多种电源合理组合形成“多能互补”平台,能够取长补短,发挥各类电源的优势,能对出力过程进行控制、调节和优化。抽水蓄能电站是调节、优化出力过程的关键和有效措施,对促进风电、光电规模化持续发展具有重要作用和长远意义。玉门市昌马和大古山(肃南)两座分别装机 4 台 30 万 kW 抽水蓄能电站项目列入全国“十三五”抽水蓄能电站重点开工项目名单,同时,张掖盘道山抽水蓄能电站已列入甘肃省 2020 年新建抽水蓄能电站,也已列入《甘肃省“十三五”新能源和可再生能源规划》建设项目。这 3 座抽水蓄能电站建成后主要承担甘肃电网调峰、填谷、调频、调相及事故备用等任务,对新能源电力外送以及解决本省电力消纳问题具有重要意义。

5.1.2 提高甘肃系统调峰能力对策

(1)建设发电、用电、电网三位一体灵活电力系统。从发电上体现在发电

负荷“能上能下”“随上随下”，满足新能源和用电负荷的波动，这就需要大力实施火电灵活性改造，实现热电解耦运行；从用电侧体现在能够“随风而动”，随时可中断用电，随时可启动用电，满足新能源的波动性要求；从电网上体现在要建设“互联互通”“吐纳自如”的电网和“灵活柔性”的调度运行机制，满足省内新能源发展和大规模外送的需求；同时应用“荷—网—源”协调控制，在发电、用电、电网3个方面各自满足灵活调度与控制的基础上，实现三方的优化控制。

(2)大力推进火电机组灵活性改造。根据国家能源局《清洁能源消纳行动计划(2018—2020年)(征求意见稿)》，要求甘肃加大火电灵活性改造力度，力争2018年完成改造规模达到500万kW，2019年煤电灵活性改造规模500万kW，2020年改造620万kW。目前甘肃省纯凝火电机组调峰能力只有50%，受供热抽汽影响，热电联产火电机组调峰能力只有40%左右，调峰能力不足严重影响新能源消纳和电网运行灵活性。

在当前储能类电源尚难以实现大规模应用的情况下，煤电机组灵活性改造仍是提升电网调节能力、推动新能源高效利用最有效、最经济的手段之一。2022年4月，国家电网有限公司西北分部组织五家省级电力公司及相关火电发电企业，参与2022年西北区域火电灵活性改造全网攻坚计划。结合地方政府关于火电灵活性改造的部署和要求，国网西北分部明确91台火电机组年内改造目标，其中改造深度20%及以下的机组达26台，最低改造深度可至机组额定容量的10%。

煤电调峰改造技术成熟、效果好、见效快，通过火电灵活性改造，争取在2~3a内，将省内火电机组调峰能力普遍提高到70%~80%，调峰深度由现在40%~50%的水平提高到70%左右，纯凝机组最小技术出力达到30%~35%额定容量，部分机组可以达到20%~25%额定容量；热电联产机组最小技术出力达到40%~50%额定容量。电网可增加调峰能力210万kW左右，一方面提升新能源发电空间，另一方面火电企业可进一步从调峰辅助服务市场获得收益。运用经济手段，组织自备电厂及供热机组参加电网调峰。挖掘电力系统调峰潜力，利用省间错峰出力、互补互济的优势调峰，最大限度地消纳新能源。

(3)推广热电解耦，提高热电机组灵活性。积极协调当地政府推动供热机组开展热电解耦改造，减少供热机组供热期间的开机方式约束，提高电网运行

新能源合理利用率之路

调节灵活性。同时建议当地政府主管部门制定《甘肃火电机组灵活性改造计划》，推动纯凝火电机组开展灵活性改造，使火电机组调峰深度从目前的 50% 下降到 30%，增加新能源消纳能力。推进热电解耦工作，提升热电机组运行灵活性。不仅可以解决目前甘肃省火电企业为追求利用小时数，将纯凝机组改供热运行，甚至寻求非供热季常年供热，但在热价上又“以电补热”，加剧企业亏损的怪圈问题；也可以解决热电机组调峰能力受限于供热需求的问题，进一步挖掘热电机组的调峰能力。

(4) 扩大辅助服务市场规模、深入推进有偿调峰机制。开展辅助调峰服务市场，可以形成火电机组通过辅助服务获得的补偿金额超出发电收益的局面，主动开展机组灵活性改造，提高电网调节能力，促进省内新能源消纳。通过市场的手段发挥常规电源在稳定电力运行中的作用。引导发电企业主动调峰，培育具有需求侧响应能力的用电负荷，优化统筹全网调节资源。加快推动甘肃电网调峰辅助服务市场建设，利用市场化手段，拓展清洁能源消纳空间。加快推动跨区域电力交易，扩大外送电规模。但是，就目前中国的调度模式来看，仍采取的是以省作为实体的，而跨省的大规模消纳风电的探索与发展还是一种全新的道路、方式、方法，还需要继续探索。另外，实现对跨省大规模消纳风电的计算、考核、调整等的构建，鼓励电力企业在本区域内能够积极主动地实现调峰服务，最大限度地实现风电的消纳还需要研究。

(5) 加快储能项目建设，推动抽水蓄能电站建设。加快推进肃州区新能源微电网示范项目建设，积极发展压缩空气储能、熔融盐蓄热储能、电化学储能等多种储能技术，推进集发、输、配、用一体的智能电网建设，提升电网灵活可靠接纳新能源的能力，建立高比例新能源电力系统。储能项目建设周期短，可作为火电灵活性改造新增调峰能力的补充，拟在酒泉地区配置容量为 660 MW 时，最大充放电功率为 130 MW 的锂电池储能装置，预计 2018 年年底建成。

为了提高系统调峰能力，在火电等传统电源灵活性改造的基础上，发展能够快速调节的抽水蓄能电站，建设大规模储能调峰电站，推动储能商业化应用。同时发展适应新能源发电的储能装置及可中断的、可调节的用电负荷等多种手段，促进新能源消纳。

(6) 开展光热电站调峰运行。光热电站作为地区调峰手段之一，可满足地区光伏、风电等传统新能源对调峰容量的需求，根据对甘肃光热示范项目业主

的咨询,光热电站储热时间和调峰深度因电站本体设计及设备制造能力的不同而具有差别,整体上光热电站机组净出力能降低到 $10\%\sim 30\%$ 。因此,随着甘肃 55 万 kW 的光热示范项目的并网,甘肃电网调峰能力将有所提高。

含风电场电力系统调峰工作既是一个技术问题,也是一个经济问题,选择何种调峰对策需要综合考虑各种因素,进行经济技术比较。从甘肃电网新能源的高渗透率实际情况出发,风功率预测中的数据采集、风能预测以及风功率预报模式等问题,为缓解该地区电力系统的调峰压力提供一种技术手段。同样,通过合理设计风电调度管理模式,采取最大负荷模式安排日发电计划,可以较好地完成甘肃电力系统的调峰任务。在此模式下,甘肃风电调度管理水平不断提高,电网运行管理的压力日益减小,可再生能源也最大限度地可以得到有效利用。总之,风功率预测、风功率控制、互补能源发电以及系统可控备用的调度,在含风电场电力系统调峰问题的研究中,为维持有功功率的供需平衡发挥了重要作用。

5.2 火电灵活性改造

5.2.1 火电灵活性改造的含义

火电灵活性改造即在当前的背景下,主要是指通过改造降低纯凝机组(非供暖期间的热电机组)的最小技术出力以及实现供暖期热电机组的热电解耦运行。通过改造降低火电机组的最小出力,增加新能源发电的消纳空间,减少弃风、弃光现象。

机组灵活性改造主要包括两个方面的含义:一是增加机组运行灵活性,即要求机组具有更快的变负荷速率、更高的负荷调节精度及更好的一次调频性能;二是增加锅炉燃料的灵活性,即机组在掺烧不同品质的燃料下,确保锅炉的稳定燃烧以及机组在掺烧工况下仍有良好的负荷调节性能。

火电灵活性改造具体涉及增强机组调峰能力、提升机组爬坡速度、缩短机组启停时间、增强燃料灵活性、实现热电解耦运行等方面。与新能源等电源相比,火电具有较好的调节能力。当新能源在电网的比例逐渐扩大时,对调峰电源的需求也逐渐升高。同时,当火电规模被控制在一定范围内的前提下,煤电

和新能源之间可形成协作关系。从国际上新能源的消纳与发展经验来看,不难发现,风电光伏的成就背后离不开包括火电机组在内的调峰电源的支撑。不过,与国际先进经验相比,中国火电机组由于以煤电为主,还存在灵活性不足的问题,在调峰深度、爬坡速度、快速启停等方面仍有很大提升空间。

5.2.2 火电灵活性政策时间轴线

(1)2016 年 6 月,国家能源局下达两批火电灵活性改造试点项目的通知,确定 22 个项目为第一、第二批提升火电灵活性改造试点项目。

(2)2016 年 7 月 22 日,国家发展和改革委员会、国家能源局发布《关于印发〈可再生能源调峰机组优先发电试行办法〉的通知》(发改运行〔2016〕1558 号),要求“逐步改变热发电机组年度发电计划安排原则,坚持以热定电,鼓励热发电机组在采暖期参与调峰”。

(3)2016 年 11 月 7 日,国家发展和改革委员会、国家能源局发布《电力发展“十三五”规划(2016—2020 年)》,要求“加强调峰能力建设,提升系统灵活性”“全面推动煤电机组灵活性改造”。

(4)2017 年 11 月 15 日,国家能源局发布《完善电力辅助服务补偿(市场)机制工作方案》。

(5)2018 年,《甘肃省电力调峰辅助服务市场运营规则(试行)》发布。

(6)2021 年 4 月,新版《甘肃省电力调峰辅助服务市场运营规则(试行)》征求意见。

5.2.3 火电灵活性调峰补偿机制

依据《甘肃电力辅助服务市场运营规则(试行)》,火电厂实施有偿调峰,2021 年 4 月前,实施的补偿政策标准如下(表 5.1):

表 5.1 2021 年 4 月前补偿标准

报价档位	火电厂负荷率	调峰报价/(元/kW·h)	
		报价上限	报价下限
第一档	40%≤负荷率<50%	0.4	0
第二档	负荷率<40%	1.0	0.4

2021 年,对原有的补偿政策进行修订,实时深度调峰采用“阶梯式”报价机制和价格方式,火电企业由原来的两档修改为五档浮动报价,新制定的补偿标准如下(表 5.2):

表 5.2 2021 年 4 月后补偿标准

报价档位	火电厂负荷率	调峰报价/(元/kW·h)	
		报价上限	报价下限
第一档	40%≤负荷率<50%	0.2	0
第二档	35%≤负荷率<40%	0.3	0
第三档	30%≤负荷率<35%	0.4	0
第四档	20%≤负荷率<30%	0.6	0
第五档	负荷率<20%	0.8	0

5.2.4 甘肃省火电灵活性改造现状

甘肃省火电厂灵活性改造及深度调峰近几年取得了一些成效。截至目前,甘肃省火电机组(100 MW 及以上,不包含自备电厂)共计 19 厂 43 台机组,尚未参与深度调峰机组 8 台(带较大工业供汽或百万机组),参与深度调峰机组 35 台,平均调峰深度为 37%,最大调峰深度为酒泉热电厂#1、#2 机组,调峰下限为 27.27%。另外,靖远三厂#7、#8 机组在 2020 年年底进行了热电解耦改造,其他参与深调机组主要在纯凝工况下实施,未进行热电解耦改造。

燃煤机组灵活性改造及深度调峰涉及锅炉、汽机、辅机、控制系统等多个方面,因此,技术路线应反映多方面的需求。甘肃省火电装机中,供热机组占比较大。绝大多数供热机组均采取汽轮机中压缸排汽供热方式,而受汽轮机低压缸最小冷却流量的限制,在机组供热量一定的情况下,机组发电负荷不能低于某一限值,这种“以热定电”的模式限制了供热机组在供热期的深度调峰能力,这也是甘肃省供暖期调峰困难、弃风、弃光现象严重的重要原因。因此,要在保证机组供热量不变的前提下,降低机组出力,就需要打破机组供热期的热、电耦合关系。目前,甘肃省主要采取的灵活性改造路线有:纯凝工况下的深度调峰控制系统优化改造、低压缸零出力技术改造、电锅炉供热灵活性调峰改造、高低旁联合供热灵活性改造、电化学储能调频等。

5.3 抽水蓄能电站建设

5.3.1 抽水蓄能电站的优势

抽水蓄能电站运行灵活、反应快速,是电力系统中具有调峰、填谷、调频、调相、备用和黑启动等多种功能的特殊电源,是目前最具经济性的大规模储能设施,对确保电力系统安全、稳定和经济运行具有重要作用。如表 5.3 所示,为保障电力系统安全稳定经济运行,适应新能源发展需要,国家陆续出台了一系列政策文件,旨在促进抽水蓄能电站持续健康有序发展。表 5.3 所示为整理的近年政府相关部门下发的相关抽水蓄能电站建设的文件。

表 5.3 抽水蓄能电站相关文件汇总

时间	文件名称	发布主体	重要内容
2021 年 7 月	关于加快推动新型储能发展的指导意见	国家能源局 国家发展和改革委员会	为实现碳达峰、碳中和,努力构建清洁低碳、安全高效能源体系,大力发展抽水蓄能以支撑新型电力系统的发展
2021 年 4 月	关于进一步完善抽水蓄能价格形成机制的意见	国家发展和改革委员会	逐步建立完善抽水蓄能电价形成机制,促进抽水蓄能电站健康发展、提升电站综合效益
2020 年 4 月	关于开展全国新一轮抽水蓄能中长期规划编制工作的通知	国家能源局	针对近年来抽水蓄能电站规划建设中出现的问题,进一步规范抽水蓄能电站的建设管理
2019 年 1 月	关于青海抽水蓄能电站选点规划有关事项的复函	国家能源局	同意青海抽水蓄能电站选点规划成果及审查意见,并对下一步工作开展提出具体工作意见
2017 年 12 月	关于在抽水蓄能电站规划建设中落实生态环保有关要求的通知	国家发展和改革委员会	高度重视抽水蓄能规划建设的生态环保要求,认真做好规划站点资源的保护工作,加强抽水蓄能规划工作与生态保护红线划定及相关规划工作的对接

续表

时间	文件名称	发布主体	重要内容
2014 年 12 月	关于促进抽水蓄能电站健康有序发展有关问题的意见	国家发展和改革委员会	适度加快电站建设步伐,把创新体制机制、完善支持政策、加强监督管理作为促进抽水蓄能电站持续健康发展的基本保障,把科技创新作为促进抽水蓄能产业发展的根本动力
2014 年 7 月	关于完善抽水蓄能电站价格形成机制有关问题的通知	国家发展和改革委员会	电力市场形成前,抽水蓄能电站实行两部制电价。在具备条件的地区,鼓励采用招标、市场竞价等方式确定抽水蓄能电站项目业主、电量、容量电价、抽水电价和上网电价
2013 年 6 月	关于加强抽水蓄能电站运行管理工作的通知	国家能源局	高度重视抽水蓄能电站运行管理,合理安排电站调峰和备用运行,加强调峰蓄能调度,充分发挥调峰填谷作用
2011 年 8 月	关于进一步做好抽水蓄能电站建设的通知	国家能源局	坚持为系统服务、“厂网分开”、建设项目技术可行、经济合理、机组设备自主化和科学合理调度的原则,进一步规范建设管理抽水蓄能电站

抽水蓄能电站除了具备调峰、填谷、调频、调相、备用和黑启动等功能外,抽水蓄能电站还具有良好的成本优势。

目前,低谷调峰能力是甘肃电网调峰问题的主要方面。可以考虑的低谷调峰措施主要有 4 个:一是弃水调峰;二是调停火电机组;三是调停燃气机组;四是建设运行抽水蓄能电站。不同的调峰方式所需调峰成本各有不同,选取各类机组中典型机组对其调峰成本进行计算比较。

水电机组以 $3\times 300\text{ MW}$ 机组为例,额定水头为 100 m ,机组的耗水率为 $3.75\text{ m}^3/(\text{kW}\cdot\text{h})$,单位发电利润为 $0.2\text{ 元}/(\text{kW}\cdot\text{h})$,则水电机组弃水调峰的成本为 $200\text{ 元}/(\text{MW}\cdot\text{h})$ 。

火电机组以 $2\times 600\text{ MW}$ 机组为例,额定负荷和降低负荷状态的运行效率 η_1 和 η_2 分别为 70% 和 40% ,燃料价格 C_0 为 $550\text{ 元}/\text{t}$,煤的发热量 Q 为 5500 大卡,即 $23\text{ MJ}/\text{kg}$,则火电机组的调峰成本为 $92.24\text{ 元}/(\text{MW}\cdot\text{h})$ 。

国内典型的燃气机组的等效发电时间 t_g 为 3 h,燃气机组的启停成本 C_q 为 520 元/(MW·h),火电机组与燃气机组的成本差值 ΔC 为 700 元/(MW·h),调峰时间 t 取 8 h,则燃气机组参与调峰的成本 $C_R=327.5$ 元/(MW·h)。

取抽水蓄能机组的效率 $\eta_e=75\%$,平均发电成本 $C_n=250$ 元/(MW·h),则抽水蓄能机组参与调峰的成本 $C_R=83$ 元/(MW·h)。

如表 5.4 所示,对不同类型机组的调峰成本进行对比可知,抽水蓄能电站参与调峰的成本最低,火电机组其次,而燃气机组和弃水调峰的成本相对较高。然而,目前甘肃省内尚未有投入使用的抽水蓄能电站,调峰电源主要是成本较高的火电机组和水电机组,因此调峰面临着巨大的经济损失。

表 5.4 各类型机组的调峰成本

调峰方式	弃水调峰	火电机组调峰	燃气机组调峰	抽水蓄能机组调峰
调峰成本/ (元/MW·h)	200	92.24	327.5	83

5.3.2 抽水蓄能电站对促消纳、促外送的作用

针对甘肃电网存在的输送通道建设、负荷水平、调峰能力、运行调度及管理体制等多方面的问题,通过配置一定规模的抽水蓄能电站能够得到有效解决。抽水蓄能电站对促进风电、光电消纳及外送的作用主要体现在以下方面:

(1)提升新能源利用率。抽水蓄能作为电网主要的调峰手段之一,对解决大规模风电光电并网带来的调峰问题起到重要的作用。当电厂发出的电量无法得到利用时,如在夜间用电低谷,电网通过输电线将风电输送到抽水蓄能电站,通过水泵把水从下库抬升到上库,实现对电能的储能;当电网达到用电高峰时,抽水蓄能电站则开闸放水至下库进行发电,发电量再传送到电网通过抽水蓄能与风电光电的协调运行,一定程度上实现了风电光电在时间上的转移,减少了风电光电的不可控性,提高了风能光能的利用率。合理高效地利用电网中抽水蓄能的调峰容量,对提高风电光电消纳能力,减少弃风弃光将起到重要作用。

(2)配合外送基地发展的需要。为推动甘肃新能源在全国范围消纳,甘肃省继 800 kV 祁韶特高压直流输电工程之后,又将新增陇东—山东特高压直流建设,开展河西第二条外送直流前期规划,全力争取扩大外送电量。送电电源

构成主要为风电、光伏发电,发电量具有间歇性、不稳定性和出力难以控制等特点,因此为外送基地配置一定规模抽水蓄能电站,具有以下优点:第一,不仅有利于提高输电线路有效容量,也有利于提高输电系统安全稳定性,更能适应受端电网负荷变化需求,减少受端电网调峰压力和调峰电源规模;第二,配置一定规模抽水蓄能电站,对提高风光电电量利用率、提高风光电开发规模、提高可再生能源电量在外送电量中的比例均具有较大的积极作用。

5.3.3 甘肃省抽水蓄能电站规划

甘肃省水资源主要分属黄河、长江、内陆河 3 个流域,横跨众多流域水系,为甘肃省抽水蓄能电站规划布点,提供了巨大优势。2011 年甘肃省开展了第一轮抽水蓄能选点规划工作,2021 年分别在黄河上游、武威、金昌、陇南开展了现场勘查工作,经初勘选址,可供建设抽水蓄能电站规模超过 1000 万 kW。

2011 年第一轮甘肃抽水蓄能选点规划共推荐了 7 个比选站点。2013 年 1 月,国家能源局批复甘肃省抽水蓄能电站选点规划,同意玉门昌马(装机 120 万 kW)和肃南大古山(装机 120 万 kW)为甘肃省新建抽水蓄能电站推荐站点。后期因祁连山自然保护区环保要求(肃南大古山站点位于祁连山自然保护区实验区),根据《中华人民共和国自然保护区条例》和相关规定,甘肃省发展和改革委员会和张掖市政府停止推进肃南大古山抽水蓄能电站前期工作,同时将张掖盘道山抽水蓄能电站(位于肃南县黑河峡谷黑河上游西流水电站饮水枢纽左岸)调整为国家规划选点站点并正式报请国家能源局。

2019 年 11 月,甘肃省发展和改革委员会委托中国电建西北勘测设计院开展黄河上游甘肃段抽水蓄能规划研究工作,通过查勘推荐刘家峡、乌金峡、刘家峡—盐锅峡混合式 3 处选点,规划装机分别为 120 万 kW、100 万 kW 和 30 万 kW。

2020 年 4 月,甘肃省电力公司邀请中国电建西北勘测设计研究院有关专家在武威、金昌、陇南地区开展抽水蓄能选点现场查勘工作,通过查勘推荐武威西营、黄羊,陇南成县、瑶池 4 处选点,规划装机分别为 120 万 kW、140 万 kW、140 万 kW 和 200 万~300 万 kW。

根据甘肃省抽水蓄能电站前期工作开展情况,甘肃玉门昌马 120 万 kW 抽水蓄能电站和张掖盘道山 120 万 kW 抽水蓄能电站进展较快。昌马抽水蓄能电站将在 2022 年上半年启动建设。盘道山抽水蓄能电站正在申请调整为甘肃

抽蓄规划优选站点,国网新源公司已于 2021 年 11 月 17 日进行了现场初勘。国家发展和改革委员会、国家能源局已表态支持甘肃利用刘家峡和盐锅峡水电站建设混合式抽水蓄能电站。从 2021 年抽蓄选点初勘结果看,4 座站址条件均相对较好,具备建站条件。

5.4 自备电厂新能源消纳路径

5.4.1 自备电厂发电权交易

近年来,随着中国新能源发电装机的迅速发展,电力行业出现了一些新的问题。一方面,装备相对落后的自备电厂在高负荷运行;另一方面,低碳环保绿色的新能源却出现了弃风弃光现象。作为新能源消纳新路径的自备电厂发电权交易,不仅可以降低自备电厂企业用能成本,而且新能源企业通过提高发电量增加效益,电网企业通过增加输送电量增加收益,实现各市场主体均共赢。

在电力供应紧缺的时代,自备电厂发挥了巨大的作用。但是随着国内电力供应偏向宽松,1.42 亿 kW 装机(1.15 亿 kW 煤电,2016 年数据)的自备电厂已经在国家政策中属于严控的范畴。2015 年,国家发展和改革委员会、能源局印发《关于加强和规范燃煤自备电厂监督管理的指导意见》,指出要严格新建机组能效、环保准入门槛,落实水资源管理“三条红线”控制指标。持续升级改造和淘汰落后火电机组,切实提升自备电厂能效、环保水平。2017 年,16 部委联合印发《关于推进供给侧结构性改革 防范化解煤电产能过剩风险的意见》,再次明确提出规范自备电厂,自备机组建设得到了控制。

那么发电权交易对企业用电成本产生怎样的影响呢?我们知道,拥有自备电厂企业的用电成本结构由自备电厂发电成本、备容费、政府性基金及附加和交叉补贴 4 部分组成。其中,发电成本主要由变动成本和固定成本两部分组成。自发电变动成本受当地煤价的影响较大,煤炭富集地区自备电厂发电成本低,优势大;离煤炭基地远的地区煤价高,自发电成本高。固定成本主要与机组类型、投资水平有关。据统计,国内并网运行自备电厂承担政府性基金及附加在 0.05 元/(kW·h)左右,备容费 0.03 元/(kW·h)左右,两项合计约 0.08

元/(kW·h)。在交叉补贴方面,2018 年度山东省等 5 省(市)相继下发文件,要求自备电厂依法缴纳政策性交叉补贴。征收标准分别为山东省 0.1016 元/(kW·h)、吉林省 0.15 元/(kW·h)、上海市 0.103 元/(kW·h)、福建省 0.1012 元/(kW·h)、四川省 0.015 元/(kW·h)。因各省差异性较大,执行情况不一,未在全国推行,故暂不列入。综上所述,企业自备电厂供电成本结构为:企业自备供电成本=自发电变动成本+自发电固定成本+备容费+政府性基金及附加。

发电权交易是优化电源结构、促进节能降耗的主要手段。通过对计划发电量的买卖交易,对电网系统内资源的合理配置有重要意义。自备电厂通过与新能源企业进行发电权交易将本厂的发电量腾让给风电、光伏等新能源机组,提高新能源发电的利用小时数,增加了系统供电负荷进而扩大了新能源上网电量空间。

企业内用电负荷通过电网采购系统电力来满足供应,由新能源企业给出售自备电厂发电权企业给予补偿,降低企业用电成本。风电、光伏等新能源发电主要采用集中式建设,个别企业自建有分布式新能源,但占比较低,对整体用电成本影响有限。通过网购电方式采购新能源电量,企业的用电电价结构为:用电价格=与新能源企业的交易电价+输配电价+基本电费+政府性基金及附加。拥有自备电厂企业开展发电权交易后,企业用电电价结构为:用电价格=基准电价-发电权交易补偿价+自备电厂固定成本+输配电价+基本电费+政府性基金及附加。对比可知,电网环节收费不变,通过发电权交易时用电企业需考虑自备电厂固定成本分摊部分。

自备电厂形成有其历史原因,而且这些企业多数生产经营都比较困难,特别是自 2020 年以来,企业经营更是举步维艰。如果简单关停自备电厂,迫使企业全部依靠电网供电,不给企业经济补偿,企业将无法生存下去。这种做法是不现实的,也是不合理的。

自备电厂与新能源企业进行发电权交易,可以保证双方利益,增加新能源电量消纳,减少碳排放,实现绿色发展。近年来,部分自备电厂通过发电权交易积极消纳新能源,极大地促进了新能源的消纳,降低了企业用电成本,促进了新能源健康快速发展。新能源企业的单位收益为上网电价与政府性补贴收入,减去变动成本和固定成本的差值。进行发电权交易后,只要新能源企业的上网电价及补贴减去变动成本后的差值大于发电权交易补偿电价,新能源企业的收益

为正,即边际成本为正,新能源企业就可以进行发电权交易。新能源发电的变动成本很低,尤其是弃风弃光部分电量,成本近乎为 0,所以存在较大的发电权交易电价空间。

自备电厂与新能源企业进行发电权交易,核心是不能提高企业的用电成本,只有在用电成本降低的前提下才有可能实现发电权交易。通过分析自备用电和发电权交易的用电结构可知,剔除共同项政府性基金及附加,基本电费和备容费基本相当,则当下式成立时具备发电权交易的条件,即:基准电价+输配电价-发电权交易补偿价<自发电变动成本。按照现行政策,基准电价+输配电价相当于目录电价,则可变为:目录电价-发电权交易补偿价<自发电变动成本。由此可知,煤价越高、发电权交易补偿价越高,越容易实现自备电厂与新能源的发电权交易;煤价较低的地方,实现发电权交易的可能性较低。

5.4.2 甘肃省自备电厂新能源替代发电

实施新能源替代发电,可实现多方共赢,新能源企业可以增加发电量,燃煤自备电厂将降低用能成本,增加电网企业售电量,有利于提高社会效益,促进新能源消纳和节能减排。新能源替代自备电厂发电权置换工作是依据《甘肃省电力中长期交易规则(暂行)》,立足降低甘肃省弃风弃光率主导开展的工作。工作开展以来,不仅为新能源消纳开辟了空间,而且降低了重点企业用能成本,减少了污染物排放,践行了绿色低碳发展理念,推动了经济社会的协调发展。

作为缓解甘肃省消纳矛盾的主要措施之一,就是不断探索开展自备电厂发电权置换与清洁能源采暖电能替代。新能源电厂通过市场化方式替代自备电厂火电机组发电指标,实现减少新能源电厂弃风(光)电量的目标。通过开展新能源替代自备发电交易可以实现 4 方共赢,自备电厂火电机组所属企业一方,通过上述交易,发电机组运行在经济区间,能耗降低,并为电网承担了部分新能源电厂电量消纳的任务,同时获取了新能源风电场电量替代交易补偿收益;新能源电厂一方虽然降低了部分上网电价,但是按照市场化方式提升了整体发电利用小时数,拓展了风电场弃风电量的消纳空间,同时可多得到该风弃电量对应的新能源补贴电费,综合效益得到提高;电网企业一方缓解了新能源发展过快引起消纳的问题(弃风弃光电量幅度增加)及电网调峰困难,确保电网安全稳定运行;工业的整体能耗得到下降,增加了工业整体效益。

推动省内自备电厂新能源替代发电,交易规模不低于 104.6 亿 $\text{kW} \cdot \text{h}$,其中新能源替代交易不低于 70 亿 $\text{kW} \cdot \text{h}$,增加调峰能力 250 万 kW 。为积极推进自备电厂发电权置换工作,2020 年甘肃省能源监管办同意兰州铝业有限公司、金川集团股份有限公司等 5 家自备电厂申请发电权置换电量 91.1 亿 $\text{kW} \cdot \text{h}$ 。据统计,2020 年完成自备电厂发电权替代电量 88.6 亿 $\text{kW} \cdot \text{h}$,其中,新能源电量 69.4 亿 $\text{kW} \cdot \text{h}$,通过发电权替代增加电网调峰能力 180 万 kW 。至此,甘肃省政府及电网将采取积极措施持续推动甘肃省内的自备电厂建设。

5.5 现货市场下的新能源消纳

5.5.1 推动新能源参与现货市场

实现“双碳”目标的关键在于促进可再生能源发展,而促进可再生能源发展的关键则在于消纳。自提出“双碳”目标以来,中国在风电和太阳能发电等新能源消纳方面,政策措施频频发力,2021 年 9 月,旨在消纳清洁能源的绿色电力交易试点在北京启动,共 17 个省份 259 家市场主体参与,达成交易电量 79.35 亿 $\text{kW} \cdot \text{h}$,此举是在能源领域以市场机制创新落实“碳达峰、碳中和”目标的重要举措,为可再生能源发展起到助推作用。

绿电交易是在电力中长期交易框架内设立的一个交易品种。而同时,在全国 8 个电力现货市场建设试点当中,已经有甘肃、山西和内蒙古西部等试点开展了有可再生能源参与的结算试运行。那么,围绕可再生能源参与电力市场尤其是电力现货市场,究竟有哪些问题需要引起业界的关注?新能源参与现货市场究竟有哪些优劣势?新能源如何参与现货市场?

(1) 推动新能源参与现货市场的动机

电力现货市场在试结算过程中常常出现不平衡资金问题,业界的共识是,不平衡资金的产生与计划市场并行的双轨制有重要关系,主要体现为优先发电量与优先购电量的不匹配,例如山东试点就是在短期内受入大量外电,从而导致计划性发电量与计划性购电量匹配度出现巨大错位,因此才产生了大量不平衡资金。问题是,近年来作为优先发电主体的新能源项目正在不断地大量并

网,短期内计划发电与计划购电不匹配问题无法缓解,反而会不断加剧。

2019年,全国并网风电和太阳能发电容量增速分别达到14%和17.4%。2020年,全国风电和太阳能发电容量增速则分别达到34.6%和24.1%。未来新能源更是能源生产和消费的主体。每年,新能源装机都有大幅增加,意味着优先发电量的大幅增加,同时,随着用户侧市场的不断放开,优先购电量却在不断减少。这种计划发电量与计划购电量的差额不断加大,有可能导致电力市场上不平衡资金的不断增多。因此,让新能源进入市场从而减少计划性优先发电量的呼声渐渐高涨起来。除去不平衡资金,还有一个就是新能源消纳问题。

2018—2020年,中国弃风弃光情况逐年好转,风电光伏利用率大幅上升,到2020年风电利用率已经达到97%,光伏利用率达到98%,这个水平在全世界领先。然而,即便按照这个“全世界领先”的利用率来看,根据2020年中国风电和太阳能发电分别为4665亿kW·h和2611亿kW·h计算,弃风弃光电量仍然分别达到144亿kW·h和53亿kW·h,总计达到197亿kW·h。这是个什么概念呢?2020年,中国每个县级行政区平均全社会用电量为26亿kW·h,也就是说,中国2020年的弃风弃光电量相当于7~8个县级行政区的全社会用电量。由于装机容量的增长,2021年一季度部分省份弃风弃光率有所抬头,青海省风电、光伏利用率同比分别下降9.4%、3.3%;陕西和宁夏存在弃风率上升问题;河南、贵州也出现弃风弃光增多现象。为此,部分新能源消纳形势比较严峻的省份和地区,将缓解弃风弃光问题试着交给了电力现货市场。

在现货市场上,电能可以更好地体现时空价值,在每天的不同时段尤其是高峰和低谷时段,由于电力供需情况变化,电价也会出现相应波动,这种波动,会让供需两端出现响应。这种响应表现为,在高峰时段,供不应求,电价较高,所有类型的电源均开足马力发电;在低谷时段,供大于求,电价较低,新能源发挥边际成本低的优势继续发电,化石能源尽力压缩出力以节约成本。当然,无论是负荷高峰还是负荷低谷,只要处在大发期,新能源项目都可以通过拉低电价的方式迫使化石能源出局,从而争取到发电空间。由此来看,参与现货市场确实可以在一定程度上促进可再生能源消纳。

(2) 新能源参与现货市场存在的问题

在中国,消纳可再生能源普遍采用两种机制,一是保障性收购。核定为保障利用小时数以内的电量,由电网企业采用统购统销的方式保量保价收购,这

就是说在保障利用小时数之内的电量采用传统计划机制消纳。二是市场化交易。在保障利用小时数之外的电量,则通过可再生能源项目与用户侧直接交易的方式进行消纳,电量和电价都由市场决定,也就是说剩余电量可以通过市场机制进行消纳。当前,中国电力市场建设进入现货交易试点阶段,有几家试点已经向新能源项目试点开放了现货市场。

新能源的优点十分明显,那就是绿色环保,不发生化学反应,不向环境中排放碳和污染物,对气候和生态表现得相当友好。另外,在项目建成之后,由于不需要燃烧煤炭、石油、天然气等化石能源,所以边际成本低,具有相当的市场竞争力。然而,同其优点一样,新能源的缺点也十分突出,那就是出力的波动性、间歇性,导致新能源完全“看天吃饭”。而出力的不确定性对于市场化而言又是致命的。

对于现货合同来说,不但要在电量上履约,而且要在电力上履约,需要完全按照合同约定的曲线进行电量交割。否则,就要接受相应的偏差考核。以山西电力现货市场建设试点为例,它们对于新能源实际出力与短期预测出力的偏差超出50%的部分,按照标杆电价计算超额收益并回收,导致新能源超额回收费用巨大。

对于新能源来说,避免出现偏差的前提是准确执行合同,而合同约定的是市场成交的结果,成交结果要看交易前对于电量电价的申报,而申报电量电价主要依赖的是出力预测,出力预测要依赖天气预报。可天气完全不可控,很难准确预测可再生能源出力。

如果依靠现货市场来实现百分之百消纳新能源,单点功率预测必须达到100%的准确率。否则就会出现两种情况:一是预测高了,实际出力达不到履约要求,新能源企业有可能要花高价购电来执行合同,否则就受到偏差考核。二是预测低了,实际出力超出合同约定额度,超出偏差减免的部分同样要接受考核;当然,如果通过自动发电控制技术来控制功率输出,的确可以精确履约而免受考核,但这样就形成了事实上的弃风弃光,达不到全额消纳可再生能源的目的,背离了发展可再生能源的初衷。

从这个角度来看,通过现货市场来解决弃风弃光问题是有一定局限性的,尽管现货市场为消纳新能源提供了一定的空间,但也因为履约和偏差考核等机制而限制了新能源的随机出力,反而不能实现完全消纳新能源的初衷。

(3) 现货市场——新能源消纳的备选

一般认为,设置电力现货市场的初衷就是为了发展和消纳可再生能源,但

就有关信息和政策来看,依然缺乏明确的信号。比如,2021年4月底国家发展和改革委员会、国家能源局共同印发的《关于进一步做好电力现货市场建设试点工作的通知》,也仅仅是说引导新能源项目10%的预计当期电量通过市场化交易竞争上网,并未明确这些电量必须进入现货市场。

同样,针对清洁能源消纳和避免弃风弃光问题,上述文件中有关部分指出,要在新能源开发布局上统筹优化、在发电侧提升调峰能力、在电网侧提升资源优化配置能力、在用户侧提高绿色电能替代和需求侧响应能力、加快发展储能、推动电力系统全面数字化、构建高效智慧调度运行体系等方面发力。而在这些举措措施当中,并未提及正如火如荼开展试点的电力现货市场机制。

2021年国家发展和改革委员会、国家能源局联合印发的《关于鼓励可再生能源发电企业自建或购买调峰能力增加并网规模的通知》指出,在电网企业承担可再生能源保障性并网责任的基础上,鼓励发电企业通过自建或购买调峰储能能力的方式,多渠道增加可再生能源发电装机并网规模。这也从一个侧面说明,当前困扰可再生能源进一步发展和消纳的主要因素,还不是消纳机制的问题,而是物理调节能力和调节技术不足的问题。

除了功率预测和偏差考核这些技术问题不利于新能源参与现货市场之外,一个更深层的原因就是在当前电力市场上新能源的绿色属性得不到体现。不管是风电、太阳能发电,还是煤电、气电、核电,只要发出来,上了网,进入市场,就都一样了,成为同质化的产品,可再生能源电力体现不出绿色属性,没能附着环保价值,而化石能源也不用背负环境成本。

其实,也正是因为可再生能源的绿色属性在其他市场上体现不出来,才有了不久前开始试点的绿色电力交易,以及前几年就启动了的跨区域省间富余可再生能源电力现货交易等专为消纳新能源而设置的交易专场了。

在现货市场上,新能源难以体现出环保优势,但其先天弱势却体现得淋漓尽致。虽然随着风电和光伏设备制造技术与能力的提高,新能源项目在经历补贴退坡、竞价中标、平价上网之后,与化石能源相比在价格上已经初具竞争力,但由于新能源出力具有波动性、间歇性以及反调峰性的天然短板,使其在现货市场上又重新堕回弱势地位,如经常受到偏差考核,很难竞得高价,承担分摊费用多,获得补偿费用少等。

因此说,如何将绿色环保价值赋予新能源,并将生态补偿成本附着在化石能源身上,并通过市场化交易传导至用户侧?只有确保了这个前提条件,无论

是在中长期市场还是在现货市场,新能源才敢说是具有竞争力的,也才能说市场化机制是可以促进新能源消纳的。

5.5.2 甘肃省需求侧现货市场建设

需求响应是需求侧管理的重要技术手段,是指用户对价格或者激励做出响应,并改变原有用户用电模式。该概念的提出,改变了过去单纯依靠电力供应侧的发展来满足不断增长的电力需求的固定思维,将需求侧作为供给侧电能的补充资源加以利用。为了缓解电网调峰压力,电力部门可以通过采取需求响应措施,引导用户的用电行为,来达到削峰填谷,减少高峰用电。

新一轮电改的开启,为电力系统调峰方式提供了新思路,但参与需求侧管理的相关主体仍面临很多问题,这与我国电力市场放开晚,前期管制较严格有关,因此,当前的电力现货市场还不足以作为最主要的调峰方式,但随着市场化的不断推进,各项保障措施的完善,未来,其必将成为不可或缺的调峰方式之一。但甘肃省作为全国首批8个电力现货交易试点地区之一,是全国范围内电力市场建设的领跑者之一,电力市场建设进程如下:

2017年8月,甘肃省被国家发展和改革委员会和国家能源局确定为全国首批8个电力现货交易试点地区之一。2018年5月,甘肃的现货市场建设方案评审通过。7个月后,甘肃省与山西省一道开启国网系统内的首次电力现货市场模拟试运行。2019年9月和2019年11月分别进行了两次周结算试运行。这一年,甘肃电力现货市场的建设思路是:做好现货市场试运行;不断完善现货市场运营规则及技术支持系统;开展市场主体培训;做好各个市场衔接。2020年3月18日,甘肃电力现货市场开始调电运行,并于4月完成全国首个整月长周期结算试运行,极大提升了全国面临疫情防控严峻形势下开展现货市场建设的信心。2020年8月1日—2021年1月17日,甘肃又进行了5个月长周期结算试运行。在整个2020年间,甘肃电力现货市场的建设思路是:做好现货市场长周期试运行;建立市场化电力电量平衡机制;建立中长期交易合约锁定收益、现货交易全电量集中竞价的交易机制;构建配套机制保障现货市场平稳运行;现货市场具备连续运行条件。2021年5月1日至今,甘肃省再次开展长周期结算试运行。今年甘肃电力现货市场的建设思路是:启动双边市场建设;做好各类中长期与现货,省间与省内市场衔接,现货市场与调峰辅助服务市场融合;形成发用双侧互动、双边集中竞价的现货市场,进一步完善价格机制及相关

配套机制。至此,甘肃省的市场化体系基本建成。

建成现货市场支撑系统二期工程,二季度具备双边现货市场试运行条件。确保年底负荷侧调峰能力提升至 100 万 kW。酒钢自备电厂采用现货模式开展发电权替代,2020 年置换电量 30 亿 kW·h。2020 年 3 月 21 日,甘肃电网需求侧资源辅助服务市场正式投入试运行,为西北首家运营;全年增发新能源 5000 万 kW·h 以上,增加调峰空间 52 万 kW。当前的建设重点为,研究源-网-荷-储各类资源参与现货市场运行机制,通过现货电能量市场与辅助服务市场联合优化出清,建立负荷侧可调节资源参与现货市场运作机制。

5.6 储能项目建设弥补电网调峰缺口

5.6.1 储能技术类型及比较

储能按照能量转换形式的不同,分为机械储能、电磁储能、热储能、电化学储能和化学储能。机械储能主要有抽水蓄能、压缩空气储能和飞轮储能。电磁储能主要有超级电容储能和超导储能。热储能是将热能储存在隔热容器的媒质中,通过储热介质与换热介质的流量控制实现能量充放,光热发电是热储能的典型应用方式。电化学储能主要有铅酸电池(铅碳电池)、锂离子电池、钠硫电池、全钒液流电池等。化学储能是利用电解制氢或合成天然气作为二次能源的载体,主要以氢储能为代表。不同储能技术的性能、经济性 & 主要应用场景如表 5.5 所示。

从技术成熟度来看,抽水蓄能是传统的电力储能方式,建设和运行技术成熟,是国家大规模重点建设的储能设施;锂电池储能技术相对成熟,已实现大规模商业化应用;光热发电建设技术基本成熟,但运行经验偏少,正处于示范应用到大规模建设的快速增长期;压缩空气储能、钠硫电池、液流电池等储能方式,目前处于试验示范阶段,建设成本较高;飞轮储能、超级电容储能与超导储能属于功率型储能方式,主要用于提升电能质量,不适用于电力系统小时级的功率调节;氢储能技术和效益与氢气产业链紧密相关,燃烧发电模式下电解制氢—储存—发电全周期效率约为 30%~40%,且氢气的存储、运输难度较大,安全性要求高,目前处于示范应用阶段。从建设周期来看,锂电池等电化学储能建设

表 5.5 各类储能综合比较

储能种类	效率/%	发展现状	技术成熟度	建设周期	造价成本	循环寿命
机械 储能	抽水蓄能 75~80	目前甘肃省暂无在运抽水蓄能发电机组。中长期规划储备项目 27 个，总装机 3350 万 kW。“十四五”重点实施项目 11 个、1300 万 kW；“十五五”重点实施项目 1 个、140 万千瓦	技术成熟，寿命长，国内投产规模占全球 25%以上，运行经验丰富	建设周期长，约为 5~8 a	造价较高，西北地区约为 6000~7000 元/kW，玉门昌马项目可研预估单位造价 7200 元/kW	50~70 a
	压缩空气 储能 40~65	需要高气密性的洞穴、废弃矿井等空间建造储气室。1978 年世界首座压缩空气储能电站在德国建成。2021 年 9 月中国首座压缩空气储能示范电站在江苏金坛并网投运	具有容量大、寿命长等优点，但造价较高、效率较低、启动时间较长，技术基本成熟，已完成示范验证	建设周期较长，约为 2~3 a	造价较高，约为 6500~7000 元/kW(4~6 h)	30~50 a
	飞轮储能 >85	功率型储能，在电力调频、轨道交通制动能量回收方面有独特优势，但能量保持率较低，储能时长短	处于示范验证阶段	建设周期短，约为 6~12 个月	造价高，分钟级储能时长下单位造价约为 1700~2000 元/kW	20~25 a
电磁 储能	超级电容 储能 >90	功率型储能，将电能直接存储在电场中，没有电能形式的转换，响应快、效率高，储能时间短	处于实验验证阶段	建设周期较短，约为 1~2a	造价高，分钟级储能时长下单位造价约为 9500~13500 元/kW	循环寿命达到 10 万次以上

续表

储能种类	效率/%	发展现状	技术成熟度	建设周期	造价成本	循环寿命
电磁储能						
超导储能	>95	功率型储能,将电能直接存储在磁场中,循环寿命长、响应快、效率高,储能时间短,运行维护复杂	需要利用超导材料和低温环境,处于研究阶段	建设周期长,一般在5 a以上	造价高,分钟级储能时长下单位造价约为6500~7000元/kW	>50 a
热能储能						
光热发电	40~50	光热发电兼具发电与储能属性,储能时间较长。2016年国家发改委批复甘肃省总容量65万kW,目前仅并网3个项目、20万kW。甘肃省批复未建项目6个、45万kW	技术基本成熟,造价较高,现有技术对电网调节适应性有待提升,运行经验偏少	建设周期较长,2~3 a	造价较高,约为1.9万~2.5万元/kW,与储热时长(熔盐用量)密切相关	30~50 a
铅酸电池(铅碳电池)储能	70~80	铅酸电池应用历史较早,但因对环保具有负面影响,应用受到限制。铅碳电池是利用石墨烯等电极材料对铅酸电池的改进	技术成熟,但发展受环保制约	建设周期短,约为6~12个月	造价低于锂电池,约为4800~6000元/kW(4h)	可深度循环4000次,设计寿命15 a
电化学储能						
锂电池储能	85~90	广泛应用于电动汽车、应急电源、电力系统调峰调频等领域,并逐步占据主要市场。甘肃省已建成运行8.675万kW,2022年计划建设75万kW,其中45万kW于2022年6月投运	技术成熟,市场化程度高,安全性有待提升	建设周期短,约为6~12个月	造价较高,约为6000~6800元/kW(4h)。现阶段电池系统成本占比60%~70%,成本具备快速下降的空间	循环次数在7000次以上

续表

储能种类	效率/%	发展现状	技术成熟度	建设周期	造价成本	循环寿命
电化学储能	钠硫电池 储能	钠硫电池无自放电,原材料丰富,常用于负荷调平、移峰和改善电能质量	需要在 300~350℃ 的高温下运行,系统维护难度大,安全隐患大	建设周期短,约为 6~12 个月	造价高,约为 13200 ~ 13800 元/kW	10~15 a
	液流电池 储能	关键材料实现国产化,具备了兆瓦级全钒液流电池系统生产能力,安全性好	受造价制约,处于示范应用阶段	建设周期短,约为 6~12 个月	造价高,约为 17500 ~ 19500 元/kW	循环次数 10000 次以上
化学储能	氢储能	目前氢气来源以化石燃料制氢为主,电解水“绿氢”成本高、占比低。全球众多国家正在大量开展示范应用,电解水制氢设备已实现商品化	受氢产业链、造价等因素制约,处于示范应用阶段	建设周期较长,约为 2~3 a	造价较高,电解制氢成本约 4~5(kW·h)/m ³ 氢气,燃料电池约 10000 元/kW 左右	12~20 a

周期约为 1~2 a,光热发电建设周期约为 2~3 a,能够用于缓解甘肃省“十四五”紧缺的调峰缺口;抽水蓄能建设期一般在 5~8 a,无法满足甘肃省“十四五”期间调峰需求。从建设成本来看,西北地区抽水蓄能电站单位造价约 6000~7000 元/kW,锂电池储能单位造价约 6000~6800 元/kW(4 h)或 3000~3400 (2 h),光热发电单位造价约 19000~25000 元/kW。从资源储量来看,我省中长期抽水蓄能规划储备项目总装机规模为 3350 万 kW,“十四五”重点实施项目总装机规模为 1300 万 kW,规划储备规模大,但属于资源有限型储能;电化学储能电站不受地形资源限制,可视为资源无限型储能;甘肃省光资源丰富,光热发电也可视为资源无限型储能。

5.6.2 新型储能的应用场景

根据接入位置的不同,储能在电力系统的应用可分为电源侧、电网侧、负荷侧,各自承担着不同角色,发挥不同作用。

电源侧储能指接入在常规电厂、风电场、光伏电站等电源厂站计量出口内的储能系统。新能源场站内配置储能,可以平滑场站出力曲线,减小风电、光伏发电输出功率波动性对电网的影响;可就近减少弃风弃光电量,提高新能源发电的效益;提高新能源场站的调峰调压能力,使新能源场站满足《电力系统安全稳定导则》(2019 版)要求,即“新能源应具备一次调频、快速调压、调峰能力”。

电网侧储能指接入公用电网的储能系统,可为电网提供调峰调频、容量备用等服务,有助于提升故障或异常运行下的系统安全性;配置在新能源送出线路关键节点时,可用于降低线路送出阻塞,减少输送压力,提升新能源消纳能力。

用户侧储能根据不同用户类型和用户需求,主要实现削峰填谷、需求侧响应管理、分布式新能源、不间断供电等功能,主要应用于经济发达、峰谷价差大的地区。

5.6.3 甘肃省新型储能发展现状

截至 2021 年年底,甘肃省已投运新型储能共计 8.675 万 kW/27.8 万 kW·h,在建 45 万 kW、待建 30 万 kW,均为电化学储能。

电网侧:2020 年 8 月中能布隆吉储能电站 6 万 kW/24 万 kW·h 储能示范项目投运(该项目属于 2018 年 11 月国家能源局批复的甘肃省磷酸铁锂电池储

能电站示范项目,批复接入电网侧、电源侧和用户侧储能项目共计8个,总规模18.2万kW/72万kW·h)。除此之外,甘肃省在建的电网侧储能电站45万kW/90万kW·h,分别是瓜州慧储新能源有限公司敦煌储能电站(15万kW/30万kW·h)、瓜州睿储新能源有限公司莫高储能电站(15万kW/30万kW·h)、张掖民乐储能电站(15万kW/30万kW·h),均计划于2022年6月投产。待建金昌共享电化学储能项目30万kW/60万kW·h,计划2022年开始建设。

电源侧:2021年6月,东方电气东洞滩储能项目0.675万kW/1万kW·h投运;9月,中广核金光光储项目1万kW/2万kW·h;12月玉门科陆光储示范项目1万kW/0.8万kW·h投运。3个项目均用于充放场站自身弃电量,无电价政策,也未参与辅助服务市场交易。

5.6.4 甘肃省新型储能发展趋势

发展新型储能是响应国家能源政策要求的关键举措。“十四五”以来,国家和地方政府层面密集出台储能相关政策。2021年7月,国家发展和改革委员会、国家能源局印发《关于加快推动新型储能发展的指导意见》(发改能源规〔2021〕1051号),明确到2025年,实现新型储能从商业化初期向规模化发展转变,装机规模达3000万kW以上。同月印发的《关于鼓励可再生能源发电企业自建或购买调峰能力增加并网规模的通知》(发改运行〔2021〕1138号),要求超过保障性并网以外的规模初期按照功率15%的挂钩比例(时长4h以上)配建调峰能力,按照20%以上挂钩比例进行配建的优先并网。甘肃省发展储能可解决新能源大规模发展带来的电网安全运行、新能源消纳及调峰难题,符合国家能源政策导向。

发展新型储能是确保电力安全可靠供应的有效手段。随着新能源的快速规模化发展和用电负荷的增长,在煤电发展受限的情况下,亟须加快建设一定容量的储能设施,确保电力系统的安全稳定运行。

发展新型储能是缓解电网调峰压力、确保新能源高效消纳的必然选择。甘肃省新能源可开发量整体位居全国前列,其中风能技术开发量5.6亿kW(随着低风速风机普及利用,风资源开发量还将进一步提升),全国排名第4,光伏发电技术开发量95亿kW,全国排名第5,开发利用空间巨大。新能源大发时,需要降低省内其他电源出力,为新能源消纳提供空间。“十四五”期间及中长期,随

新能源合理利用率之路

随着新能源规模化发展、新能源弃电率及调峰矛盾日益突出,全省调峰缺口将呈现增大趋势,新能源利用率将随之持续下降。在煤电发展放缓的形势下,为防止新能源弃风弃光问题重现,必须加快推动储能设施的建设,确保新能源高效消纳。

发展新型储能是助推省内产业升级转型,培育经济发展新增长极的重要举措。甘肃省高度重视储能产业,2021年3月,《关于建立全省重点产业链链主企业制度的通知》明确,金川集团为动力电池产业链链主企业,甘肃东方钛业有限公司为磷酸铁锂产业链链主企业。2021年5月,《甘肃省人民政府办公厅关于培育壮大新能源产业链的意见》(甘政办发〔2021〕40号)提出,要鼓励开展储能产业示范,建设一批移动式或固定式商业储能电站。将发展储能作为甘肃省产业高级化的重要抓手之一,推动甘肃省由初级有色金属原材料开采向高端装备制造业方向发展。

第

6

章

新能源时序生产模拟

电力系统是一个实时平衡的动态系统,发电、输电、配电、用电瞬时完成。传统电力系统中发电主要为确定性的火电、水电、燃气发电等,系统运行的不确定性主要来源于负荷,因此传统电力系统以发电跟随负荷波动为主,开展生产模拟。大规模新能源接入后,电力系统中的不确定变量除了负荷以外,还包含波动性新能源,且新能源的年、月、周、日规律特性比负荷特性更加难以准确描述和掌握。当新能源比例较小时,可以将新能源看作负的负荷,采用等效负荷即可很好地开展生产模拟相关研究,但是当新能源比例较大时,新能源的特性将打破等效负荷不确定性的规律,使得已有的典型日、典型周生产模拟技术应用面临挑战,此时,需要将新能源作为一种不确定性电源,开展全时段生产模拟。

6.1 新能源消纳水平评估方法

在以限制新能源出力为原则的新能源消纳能力评估方法中,较为常用的分析方法主要有以下 3 种:典型日分析法、随机生产模拟法以及时序生产模拟法。

6.1.1 典型日分析法

典型日分析法是目前新能源消纳研究中最常见的方法,一般分为两类:一是通过提取最大峰谷差、平均功率等特征数据,对历史曲线进行分类,选取全年典型日去简单实用地进行新能源消纳分析;二是基于简单的加权平均进行选取,基于聚类分析算法等数据挖掘和人工智能技术进行高维度数据的统计分析,进而优化典型日可再生能源出力。其计算方法首先是确定典型日的峰值负荷和谷值负荷,其次利用峰值负荷确定系统中常规机组的启动方式,再次在系统启动方式没有改变的前提下降低传统机组的输出,最后通过低谷值负荷和发电机组的最小技术出力来确定系统的新能源的消纳能力。

6.1.2 随机生产模拟法

随机生产模拟采用服从一定分布的离散型随机变量描述新能源出力、负

荷、常规电源开机方式等的概率特性。通过概率分布间的运算,将随机变量间的不确定性运算,转化为概率场景下的确定性运算。计算新能源消纳功率和限电功率的离散概率分布,实现新能源电力系统的随机生产模拟,进而快速计算消纳电量、限电电量等指标,评估系统新能源消纳能力。目前,随机生产模拟法中对风电场的处理主要为两类,一类是将风电出力视为负值负荷去修正原始负荷得到净负荷;另一类是把风电场等效转化为常规多状态机组参与随机生产模拟。

6.1.3 时序生产模拟法

时序生产模拟是将系统负荷、新能源发电、其他电源发电出力看作随时间变化的时间序列,综合考虑功率平衡、电力备用、机组调峰、电网输送能力、机组爬坡速率等约束条件,以每小时(或者每 15 min)为间隔,进行逐时段的运行模拟,以得到最优的电力电量平衡结果。目前,时序生产模拟法在国内外广泛应用于电力系统调度、发电生产计划、电力平衡及新能源消纳计算。时序生产模拟法根据模拟法时间长短可分为短期时序生产模拟法与中长期时序生产模拟法;短期时序生产模拟法是指模拟时间为数小时到几十小时,可为每日或每周的电力系统运行提供指导;中长期时序生产模拟法是指数月数年,可以模拟不同的装机规模、电网结构等条件下新能源生产情况,为新能源发展规划及电网建设规划提供参考依据。考虑到计算的稳定性和实用性,目前常用的电力系统时序生产模拟主要使用线性规划和混合整数线性规划算法进行求解。

以上 3 种方法具体优缺点对比如表 6.1 所示。通过比较,为切合电网实际情况,综合考虑新能源发电出力的波动性,本项目采用时序生产模拟法。

表 6.1 新能源消纳能力评估方法对比

项目	时序生产模拟法	随机生产模拟法	典型日分析法
新能源数据	时序曲线(以时间分辨率 1 h 为例,全年 8760 个点)	新能源预测出力累积概率分布(数据点数取决于与预测出力状态数)	全年负荷峰谷差最大的新能源出力值
负荷数据	时序曲线(以时间分辨率 1 h 为例,全年 8760 个点)	负荷需求预测累积概率分布(数据点数取决于预测出力状态数)	全年峰谷差最大一天的负荷值

续表

项目	时序生产模拟法	随机生产模拟法	典型日分析法
发电机组	最小/最大技术出力,爬坡率,煤耗特性参数,最小运行/停机时间等	最小/最大技术出力,爬坡率,煤耗特性参数	最小/最大技术出力,煤耗特性参数
初始条件	发电机组初始开始方式	—	—
限制条件	新能源时序曲线难以获取	无法考虑爬坡率、机组启停等问题	计算结果保守,无法提高新能源消纳量
模型计算复杂度	计算复杂度随计算时段、机组数量的增加迅速增加	多项式复杂度,计算复杂度仅与机组数量有关	计算复杂度简单,数据较少,计算时间快

6.2 新能源时序生产模型

6.2.1 基本原理

新能源电力系统时序生产模拟是在实现全年或全月新能源消纳最大的前提下,计算常规机组和新能源机组的发电计划。由于常规机组的运行特性及其机组组合特性等会影响最终的新能源消纳能力,因此新能源时序生产模拟必须充分考虑电力系统中火电、水电机组为代表的各类常规机组的技术特性,包括启停机特性、爬坡特性与最小发电出力特性等。还需要考虑某些类型机组的特殊性,如热电联产机组的热电耦合特性、抽水蓄能机组的抽放水特性等。另外,还需要考虑机组检修计划、电网联络线的交换计划等信息。因此,新能源电力系统时序生产模拟以新能源消纳能力最大为目标,综合考虑系统平衡约束、电网安全约束、备用约束、机组电量约束和运行约束、联络线交换计划、检修计划、新能源功率约束、系统约束、网络拓扑、机组发电能力和电厂运行约束等条件,建立数学优化模型。通过优化求解,得到常规机组和新能源的发电出力计划,特别是新能源限电量和限电率。

6.2.2 目标函数

国务院办公厅早在 2007 年就发布了《节能发电调度方法》，规定在保障电力可靠供应的前提下，按照节能、经济的原则，优先调度可再生发电资源。但由于新能源出力的随机性以及传统电源的调峰能力的限制，新能源利用率十分低下，本节通过分析影响新能源消纳的因素，根据不同电网规模、负荷、电源结构特点确定新能源机组接入规模，以年度最大新能源消纳为目标，建立时序生产模拟仿真模型，最终确定目标函数如式(6.1)所示：

$$f = \max \left(P_1^t - \sum_{j=1}^m P_{j,wa}^t - \sum_{i=1}^n P_{i,f}^t \right) \quad (6.1)$$

式中： P_1^t 表示负荷值， $P_{j,wa}^t$ 表示第 j 个水电机组出力值， $P_{i,f}^t$ 表示第 i 个火电机组出力值。

6.2.3 约束条件

(1) 电力平衡约束

$$P_f + P_{wa} + P_p + P_{wi} - P_t = P_1 \quad (6.2)$$

式中： P_f 表示火电出力值， P_{wa} 表示水电出力值， P_p 表示光伏出力值， P_{wi} 表示风电出力值， P_t 表示外送功率， P_1 表示负荷值。

(2) 系统备用容量约束

系统备用容量包括事故备用、负荷备用、检修备用。另外，由于新能源出力的不确定性，当把新能源出力加入到系统功率平衡时，必然会加大对系统备用容量的需求，如式(6.3)所示：

$$S \geq P_{\max l} \times (l\% + s\%) + P_{\text{pre}} \times w\% + P_r \quad (6.3)$$

式中： S 表示系统需要的备用容量， $P_{\max l}$ 表示预测最大负荷， $l\%$ 表示负荷备用百分比，一般取值为 $2\% \sim 5\%$ ， $s\%$ 表示事故备用百分比，一般取值为 $5\% \sim 10\%$ ， $w\%$ 表示新能源预测出力误差对备用容量的需求， P_{pre} 表示新能源预测功率， P_r 表示为检修备用容量，视情况需要设置。

(3) 火电机组出力约束

火电机组目前是中国发电主要部分，对于消纳新能源起着重要的作用。目前中国火电机组包含背压式机组和抽汽式机组，其电与热的出力如图 6.1 所示。背压式机组电力出力与热出力成正比关系，而抽汽式机组当热出力固定

时,电出力在一定范围内浮动。为满足供热需求,目前参与系统调峰一般为抽汽式机组。




图 6.1 火电机组出力图

(a)背压式机组;(b)抽气式机组

火力发电机组在满足系统发电任务时,还需要承担系统的调峰任务。根据预测的最大负荷并考虑一定的备用容量,确定火电机组开机方式,并综合分析不同容量的火电机组确定各火电机组允许最低技术出力。在做生产模拟时,以新能源消纳优先的原则并考虑各火电机组的爬坡约束,确定在满足负荷需求的前提下各火电机组的出力范围如式(6.4)。

$$P_{\text{down}} \leq P \leq P_{\text{up}} \quad (6.4)$$

式中: P_{down} 表示火电机组最小技术出力, P_{up} 表示额定出力。

(4)火电机组爬坡约束

新能源出力值在较短的时间内可能有较大的变化量,而火电机组出力受到爬坡率的约束无法快速跟踪新能源出力的变化,造成弃风弃光等现象,火电机组爬坡约束按下式确定

$$P_{g< t>} - P_{g< t-1>} \leq P_{g-\text{up}} \quad (6.5)$$

$$P_{g< t-1>} - P_{g< t>} \leq P_{g-\text{down}} \quad (6.6)$$

式中: $P_{g-\text{up}}$ 表示为火电机组向上爬坡率, $P_{g-\text{down}}$ 表示为火电机组向下爬坡率, t 表示为时间, $P_{g< t>}$ 表示为火电机组在 t 时刻的技术出力。

(5)水电机组出力约束

水电出力受季节影响明显,夏季水电大发时期出力可以达到额定功率,而冬季出力则仅有夏季的20%~30%,模型中分夏季和冬季两种运行方式,分别

按照装机容量的一定比例安排水电出力。

$$0 \leq P_{wa} \leq P_{up} \quad (6.7)$$

式中： P_{wa} 表示水电机组出力值， P_{up} 表示额定出力值。

(6)外送功率约束

当某地区新能源出力充足，可考虑将富余电力外送，新能源外送电力受制于外送输电线路的功率约束，如式(6.8)所示：

$$P_{tran} \leq P_{line} \quad (6.8)$$

式中： P_{tran} 表示为外送富余新能源电力， P_{line} 表示为外送线路功率最大值。

(7)新能源出力约束

$$0 \leq P_{wind}(t) \leq P_{wind}^*(t) \quad (6.9)$$

$$0 \leq P_{pv}(t) \leq P_{pv}^*(t) \quad (6.10)$$

式中： $P_{pv}^*(t)$ 表示为光伏额定出力， $P_{wind}^*(t)$ 表示为风电额定出力。

(8)新能源比例约束

若以完全消纳新能源出力为目标，这样就忽视了在非负荷低谷时刻新能源的可消纳空间，该方法计算得出的新能源消纳量较低。如果允许在负荷低谷时段有一定比例的弃新能源，以换取更大的新能源消纳量，这样就充分利用了除去低负荷时段以外大部分时段的调峰裕度，以此计算得出的新能源消纳量将大大提高。

基于时序生产模拟法，通过模拟评估全年 8760 h 的消纳情况，根据负荷曲线制定开机计划并得出各时间段新能源消纳空间，然后结合新能源发电理论出力，得出各水平年在规划容量下的新能源发电量和弃电量，从而得出在一定的指标约束下可消纳的新能源量。此方法的计算过程更贴近系统实际运行情况，同时还可以给出各个时段各类电源工作数据，有利于对新能源消纳的全面评估。

6.3 新能源时序生产模拟计算步骤

新能源时序生产模拟案例计算流程主要分为数据准备、配置电网、案例计算和结果分析 4 个步骤。计算过程考虑了新能源发电出力的波动特性、时序特性、季节特性，以时序生产模拟的方式计算一定电网运行方式约束下的全网新

能源最大消纳能力。时序生产模拟案例计算流程如图 6.2 所示。

6.3.1 数据准备

新能源时序生产模拟计算所需数据包括电源、负荷、联络线、常规机组、新能源场站、断面限额等基础数据。对于随时间变化的序列数据,数据时间分辨率不应小于 60 min。对于风电、光伏发电,需要基于理论发电功率数据形成归一化时序数据,负荷和联络线数据为实际发电出力的时序数据。

6.3.2 配置电网

首先构建电网,根据电网实际情况建立分区聚合模型,并配置分区电网间的输电断面限额及外送联络线,然后配置电源,在电网的基础上,进一步配置各类电源、输电断面和联络线的时序运行参数。

6.3.3 案例计算

需要分别配置案例基本信息、运行方式和全网参数。其中,案例基本信息包括案例名称、优化计算模型选择、计算时间范围和计算步长等信息;运行方式配置是指基于案例计算需求选取各分区电网中负荷、电源、联络线的运行方式,组合形成新的计算案例。全网参数配置需要配置案例的备用容量信息、新能源功率预测误差以及输电断面限额方式。数据配置完成后开始计算。

6.3.4 结果分析

计算结果包括新能源消纳结算结果、负荷计算结果以及综合统计结果等。通过计算结果进一步分析新能源消纳情况(图 6.2)。



图 6.2 时序生产模拟案例计算流程

第

7

章

新能源合理利用率测算

7.1 新能源合理利用率内涵

7.1.1 新能源合理利用率定义

合理利用率作为构建新能源消纳长效机制的主要指标之一,在 2021 年 3 月 30 日国务院新闻办公室中国可再生能源发展有关情况发布会中被首次提出。自此,新能源消纳水平的评估指标经历了从“弃电率”“弃电量”到“利用率”,再到合理利用率的转变过程。其中,弃电率、弃电量衡量阶段只关注清洁能源电力的未利用部分,并未考虑整个能源和电力系统为消纳清洁能源付出的努力的成本。可再生能源利用率则主要指代了风电、光伏发电、水能 3 类新能源电力的利用率,以可再生能源提供的能源量占总能源消耗量的比例来衡量。相较于传统利用率,合理利用率的提出又进一步包含了对经济、环境、成本等其他因素的考量,避免了新能源完全消纳单一目标的实现。

从利用率到合理利用率的转变来看,高新能源渗透率情况下,合理弃电是经济且必要的。利用率管控目标将影响可接纳的新能源发展规模、系统灵活资源需求和电力供应成本,设定过高利用率的消纳目标既不经济,也将限制新能源发展规模。同时,可再生能源的利用量与可再生能源资源的丰富程度、价格等因素有关,分析可再生能源利用率需要进行可再生能源资源潜力的评估分析。因此,从能源供应系统全局出发,新能源消纳水平理论上存在总体最经济的“合理值”。在欧洲等成熟电力市场中,新能源合理利用率被认为是一种和需求侧响应类似的辅助服务,合理弃电通过向电网提供“下调”服务保障能源安全。美国、德国一些国家,通过将弃风相关条款纳入并网协议或购电合同等管理手段和市场规则,使得风力发电企业、电网公司等相关方接受透明条件下的一定合理弃风,合理利用率维持在 95%~99%。

据此,从宏观层面分析,合理利用率是在一定时空条件下,结合电力系统自身特性,满足整个能源系统经济性,并使得全社会用电成本最低的清洁能源消纳水平的经济合理区间,避免了片面追求完全消纳对新能源发展的制约。从电力系统运行角度来说,合理利用率是在规划期内满足系统特定新能源消纳责任权重要求的情况下,寻找系统总成本最小对应的新能源利用率。其在满足新能

源场站经济效益的前提下,兼顾了不同地区的装机规模、负荷水平和电源调节能力,是实现系统整体运行最优的动态调整指标。由于新能源发展规模随利用率控制目标降低而增加,电力供应成本则呈“U 型”曲线变化,因此拐点即对应经济性最优的新能源规模和合理利用率。

7.1.2 影响新能源合理利用率的主要因素

从利用率角度来看,甘肃地区新能源消纳问题与电源调节、电网互联、负荷规模、消纳机制等关键因素呈强相关性。甘肃地区新能源经历了爆发性增长,而本省及外送能源需求增长缓慢,省内用电曲线、外送曲线与新能源发电不匹配,即中午光伏大发时段用电负荷及外送需求较低,晚高峰时段光伏发电能力几乎为零,无法满足负荷高峰时段的负荷及外送需求。此外,中国正在建设全国电力市场,但调峰补偿、价格响应等市场机制尚未建立,发电计划由各地政府制定,各省优先考虑本地电厂多发,接受外来新能源的意愿不强,省间壁垒严重,客观上加剧了风力发电、光伏发电利用率增长缓慢现象。因此,解决新能源消纳问题、提升风力发电、光伏发电利用率的最有效的途径,是从电源、电网、负荷、机制 4 方面综合采取措施。

而合理利用率除与资源等系统固有属性有关外,还受多种因素影响。从经济性角度而言,合理利用率随新能源侧开发成本降低而降低,随系统侧消纳成本降低而增加;从政策机制角度而言,合理利用率随消纳责任权重要求增加而减小;从市场化改革角度而言,中国电力体制改革将使得市场化方式以更低成本、在更大范围内促进新能源的消纳利用,从而进一步提高合理利用率。

(1) 新能源开发及消纳成本

为满足特定的新能源消纳责任权重指标,可以从新能源开发侧和系统消纳侧采取多种措施提升新能源电量占比。从开发侧来看,当系统新能源消纳能力不增加的情况下,可通过增加系统新能源装机的形式增加新能源电量供给,其主要新增成本是增量新能源投资;从系统消纳侧角度而言,可通过电网加强解决网架受阻、建设调峰电源和负荷侧响应解决调峰受阻等方式,降低新能源弃电量,其主要新增成本为各类调峰手段投资及调峰手段运行成本等。为完成消纳责任权重要求的增量全社会购电成本如图 7.1 所示,通过计算比较各类满足新能源消纳责任权重的方案,便可得到使系统总成本最低的合理利用率。




图 7.1 完成消纳责任权重要求的全社会购电成本分析

合理弃电率与合理利用率满足相加为 1 的数量关系。在特定消纳责任权重下，新能源合理弃电率由电源侧开发成本与系统侧消纳成本相对高低决定，其变化趋势如图 7.2 所示，即当电源开发侧成本降低时，系统合理弃电率将增加；当系统侧消纳成本降低时，系统合理弃电率将降低。系统侧消纳成本主要涉及电网及各类调峰电源建设成本，从成本变化趋势来看，除电化学储能外，大部分调峰手段技术成熟度较高、成本变化主要受燃料成本影响，长期呈现上涨趋势；清洁能源随着新能源装备制造技术的快速进步和规模化发展，近年来成本呈快速下降趋势。

(2) 新能源装机和消纳责任权重

“双碳”背景下，可再生能源消纳责任权重目标的实现是提升“十四五”期间新能源消纳水平的首要目标。《关于 2021 年可再生能源电力消纳责任权重及有关事项的通知》的发布明确了甘肃省要逐步到 2030 年完成国家要求的 33.2% 的非水电消纳权重。装机容量的增加有助于目标权重的实现，但对弃风

弃光电量具有一定的负面影响。图 7.3 和图 7.4 定性地给出了最大弃风电量与最小消纳风电电量以及最大弃风率、风电电量保证消纳比例与风电装机之间的关系。当风电装机容量增加,风电出力持续曲线沿纵轴向上抬升,交点 A 移动到交点 A'。曲线移动增加的面积 ΔI 为增加的弃风电量, ΔII 为增加的消纳风电电量。容易看出,当风电装机较小时,最大弃风电量为 0 或较小;随着风电装机的逐渐增大,弃风电量和消纳电量都相应增加。由于交点 A 逐渐向左移动,使得最大弃风电量的增量逐渐增大,而最小消纳风电电量增量越来越小。换句话说,在风电装机规模发展的初期,少量弃风代价所换来的增加消纳风电电量的效益是明显的。随着风电装机规模增加,弃风对于消纳风电的效益逐渐下降,这时需要通过电力外送、负荷削峰填谷、增强常规机组调峰能力等手段来提高消纳风电电量。




图 7.2 合理弃电率变化趋势

(a) 电源侧开发成本降低; (b) 系统侧消纳成本降低




图 7.3 最大弃风电量与最小消纳风电量之间关系示意




图 7.4 最大弃风率、风电电量保证消纳比例与风电装机间的关系

(3) 电力市场化交易

2021 年上半年,甘肃省内交易电量 709.07 亿 $\text{kW} \cdot \text{h}$,同比增长 13.51%。2021 年上半年,跨区跨省外送电量 277.00 亿 $\text{kW} \cdot \text{h}$,同比增长 16.21%。电厂购电均价 228.96 元/ $\text{MW} \cdot \text{h}$,送电均价 258.25 元/ $\text{MW} \cdot \text{h}$,输电均价 29.29 元/ $\text{MW} \cdot \text{h}$ 。省内售电量累计完成 527.34 亿 $\text{kW} \cdot \text{h}$,同比增加 64.09 亿 $\text{kW} \cdot \text{h}$,增长 13.84%;售电到户均价累计完成 446.12 元/ $\text{MW} \cdot \text{h}$,同比降低 0.49 元/ $\text{MW} \cdot \text{h}$ 。从市场化改革角度而言,中国电力体制改革将使得市场化方式以更低成本、在更大范围内促进新能源的消纳利用,从而进一步提高合理利

用率。电力市场化交易是实现电力市场化改革的主要途径,交易电量占比的增加在一定程度上推动了合理利用率的提高。

7.2 新能源合理利用率分析的相关原则与准则

7.2.1 新能源合理利用率分析的主要原则

在含大比例新能源的电力系统中,为消纳占比极小的新能源尖峰电量,需要占用系统大量的调峰资源,降低系统安全稳定性和经济性,若允许放弃一定的新能源电量,可以降低系统总体调峰需求,减少调峰电源建设,避免昂贵的边际消纳成本。因此,探索新能源“合理弃能”问题需满足以下几点原则,在新能源消纳成本和消纳效益中寻找平衡点。

(1)经济性原则

虽然新能源发电的边际成本几乎为 0,但各类解决新能源消纳问题的方案却都需要付出一定的经济性、安全性等方面的代价,新能源发展急需从全社会综合用能成本的角度出发,确定既满足社会清洁能源发展需求,又满足电力系统安全经济运行要求的合理弃电率水平。综合考虑新能源的消纳成本和消纳效益,电力系统规划中 100%消纳新能源不一定是经济的选择。以图 7.5 所示的某风力发电厂年出力占比曲线为例,该电厂全年出力超过 70%的概率仅为 7%左右,超过 70%部分的电量仅占全年发电量的 2.7%。为了消纳这 2.7%且持续时间并不长的电量需要投入大量的灵活性电源或者新建电网,可能不是最经济的选择。因此在电力系统规划中若能找到新能源的合理弃能率,在电网负荷低谷时段对新能源适度弃电,则能够减少或者延缓调峰电源及输电线路建设,在保障新能源基本充分利用的前提下,提高整个电力系统运行的安全性和经济性。

(2)满足最低可再生能源消纳权重原则

现阶段虽然新能源成本快速下降,但受制于较高的初始投资,在仅考虑经济性情况下,新能源的度电成本仍然高于传统化石能源,叠加新能源系统消纳侧成本,总体而言,提高新能源电力消纳责任权重将增加全社会购电成本。同时,在其他条件不变的情况下,提高新能源电力消纳责任权重必然会增加系统

内新能源装机,进而提高系统新能源消纳压力,合理弃电率将有所增加。因此,可再生能源消纳权重与利用率之间负向相关,合理利用率随消纳责任权重要求增加而逐步减小,在利用率的合理性确定中,应满足最低的可再生能源消纳责任权重目标。




图 7.5 新能源出力占比示意

(3)可靠性和安全性原则

可再生能源消纳责任权重目标下,新能源大规模接入电网,高比例新能源的接入不仅加大了电力供应的保障难度,而且增加了电力系统的脆弱性和复杂性。科学地制定新能源合理利用率目标应充分考虑当地资源、负荷、系统电网结构,因地制宜。在新能源无弃能情况下,根据风电和太阳能出力特性在原始负荷曲线上直接扣减风光出力即可得到系统的净负荷曲线,如图 7.6 所示。在无弃能情况下的净负荷曲线最下端增加新能源弃电量后,形成在指定弃能率水平下的净负荷曲线,如图 7.7 所示。由此,合理的利用率的提出允许弃风弃光的存在,平抑了电力负荷的过度波动,有助于电网的平稳运行。应合理规划新能源装机,优化网架结构,从而保障电网的安全运行。合理的新能源利用率为高比例新能源并网优化运行奠定了坚实基础,这有助于增强电力系统调节能力,提升高比例新能源安全运行水平,并充分利用系统的消纳能力,积极提升新能源发展空间。

7.2.2 新能源合理利用率分析的相关准则

系统新能源合理利用率的相关准则主要是需要充分协调利用率、调峰能力、可新增装机 3 者相关关系。通过对新能源弃能现象的分析发现,主要是由两种原因导致:一是网架受阻,即局部电力供应过剩或传输限制引起的风光出力削减,二是调峰受阻,即风电尖峰出力出现在负荷低谷时段等特定工况引起的新能源弃能现象。网架受阻主要通过优化电网结构、改善电网调度运行方式等方法解决。调峰受阻主要通过加强调峰电源建设、需求侧响应等方式来解决。但若通过增加常规机组的调峰深度来实现风电尖峰出力的消纳,将对电力系统的安全和经济运行带来挑战。在运行中考虑合理弃风来提高风电消纳能力是解决上述问题的关键。事实上,利用率可分为运行利用率和规划利用率。大规模新能源并网运行将增加系统中不可控的发电出力并对电力系统规划产生影响。以风电为例,风电的高效利用会减少整个系统的运行成本,减少化石能源消耗,增加节能减排效益。然而为了多消纳风电,可能需要规划建设灵活性较高的调峰电源或者对存量电源进行灵活性改造,若本地负荷消纳能力有限,还需要新建或者扩容输电线路。




图 7.6 无弃能情况下的净负荷曲线

此外,从电源侧看,新能源发电具有一定的容量替代效益,接入后能够节省常规电源装机,然而从负荷侧看,新能源发电相当于负的负荷,与原始负荷叠加后形成的净负荷有所降低,尤其是净负荷低谷降低对调峰电源提出了更高的要求。甚至当光伏发电装机过多时,原本的午高峰可能变成净负荷的低谷。在这种情况下,白天光伏发电能够满足很大一部分的电力需求,电力系统运营商只需调配小部分电力,但到了傍晚,随着晚高峰来临,光伏出力却减少至 0,短短的几个小时内,净负荷将快速上升。在白天净负荷低谷时段适当考虑太阳能弃能,将降低对调峰电源的苛刻要求,提高系统运行经济性。




图 7.7 指定弃能水平下的净负荷曲线

7.3 新能源合理利用率分析计算方法

7.3.1 新能源合理利用率分析计算思路

总体来看,经济性是衡量利用率合理性的主要指标。从全社会综合用能成本的角度出发,确定满足中国可再生能源发展目标的合理弃电率,有利于以最小的全社会成本实现最大化清洁能源消费占比。规划期内的合理弃能率是在满足系统需求的情况下,寻求系统总费用最小对应的新能源弃能率,即为此时的合理利用率。具体做法是在规划中根据风光装机及出力,以及所设置的弃能率水平及时修正净负荷,针对净负荷做常规电源规划和网架规划,通过合理的优化方法得到总成本最优的规划方案及对应的新能源合理弃能率,流程如图 7.8 所示。

合理利用率计算方法流程如图 7.9 所示,具体做法如下。





图 7.8 考虑合理弃能率的电力系统规划流程


- (1)根据新能源消纳责任权重要求,计算新能源发电量。
- (2)调整新能源装机及对应系统侧消纳改造措施,通过时序仿真分析,测算系统新能源发电量及对应利用率。
- (3)如新能源发电量不满足系统消纳责任权重要求,修改新能源装机或系统侧消纳措施,重新计算对应新能源发电量及对应利用率,直至系统新能源发电量满足系统消纳责任权重要求。
- (4)当系统新能源发电量满足系统消纳责任权重要求时,记录此时的新能源利用率,并根据对应新能源装机及对应系统侧消纳措施投入计算此时的全社会购电成本。
- (5)重复步骤,获得弃电率从高到底的新能源利用率及对应全社会购电成本数据。
- (6)绘制全社会购电成本—利用率曲线,系统中总成本最低点对应利用率即为新能源合理利用率,如图 7.10 所示。

7.3.2 新能源合理利用率分析计算模型

根据上述计算思路,在生产时序模拟的基础上加上经济性约束成为合理利用率确定的依据。全社会成本核算主要对电网总运行成本进行分析,全社会成本包括火电和各类新能源发电机组的投资及维护成本、输电线路投资及运行维护成本、燃料成本、环境损失成本和可靠性成本。环境损失成本指在考虑环境对策措施(如采用脱硫脱硝设备)的条件下,火电排放的污染物对环境产生的经



(a) 总流程



(b) 成本和弃电率计算子流程

图 7.9 合理利用率的计算流程




图 7.10 不同弃电率下的全社会购电成本示意

济损失。减排单位污染物所避免的经济损失称作污染物的环境价值。煤炭发电的污染物主要有 SO_2 、 NO 、 CO_2 、 CO 和悬浮颗粒物等。目前，中国的供电可靠性水平还比较低，每年停电事故都造成巨大的经济损失。可靠性价值可以看作单位停电量的经济损失，通常采用度电产值来衡量单位缺供电量所造成的平均经济损失，度电产值是国内生产总值与全社会总用电量之比，由于系统的可靠性问题造成的经济损失非常巨大，所以可靠性成本在输煤输电的比较中不容忽视。

在全社会成本评估中，已有的系统运行模拟方法采用机组组合优化模型和安全约束经济调度模型，可以详细评估输电方案每一时段的燃料成本、环境损失成本、可靠性成本和供电量。获得燃料成本、环境损失成本和可靠性成本之后，再结合系统投资及维护成本，即可获得电力系统运行的全社会成本。其评估框架如图 7.11 所示。




图 7.11 全社会成本评估框架

在明确全社会成本的具体构成后,应着眼于合理利用率的经济性,即考虑全社会成本的增量部分。本模型增量全社会购电成本 S 主要为各类新增成本的年值之和,主要包括增量总投资年值 I 、年增量运行费用 F 和年增量环境成本 E ,具体公式设定为:

$$S = I_c + F_c + E_c \tag{7.1}$$

式中: c 为新能源弃电率。

(1)年增量环境成本评估

环境效益的评估一般以气体污染物排放量、发电燃料耗量和购电总费用最小为指标。合理弃风电最大化地实现节能减排效益。因此,评估风电和光伏发电对电力系统节能减排效的贡献,并分析因接入风电而导致的各方面成本的上升有利于环境成本的全面评估。从运行环节分析高比例新能源并网后所产生的环境成本。风电、光伏、核电和水电运行阶段的发电环境成本基本为 0,运行环节的环境成本主要体现为火电机组的燃煤损耗,以及燃煤导致的 SO_2 、 NO_x 和 CO_2 等污染物排放。以往研究总结得出各类电源生产过程中环境不友好气体排放的数据如表 7.1 所示。

表 7.1 各种发电技术的污染排放数据

电源种类	$\text{NO}_x/(\text{kg}/\text{MW} \cdot \text{h})$	$\text{CO}_2/(\text{kg}/\text{MW} \cdot \text{h})$	$\text{SO}_2/(\text{kg}/\text{MW} \cdot \text{h})$
光伏发电	0	0	0
风能发电	0	0	0
天然气发电	0.008~1.547	49.037	0.464
微型燃气汽轮机	0.619	184.083	0.001
内燃机(燃机)	4.795	170.161	0.023
燃煤发电	0.154~3.094	86.473	0.108~3.945

增量环境成本 E 主要来自火电深度调峰引起的 CO_2 排放增加,本节认为火电深度调峰过程中氮氧化物等排放达标,主要选取 CO_2 进行环境成本分析,增量环境成本为:

$$E_c = (E_e + E_g) \rho_{\text{CO}_2} \tag{7.2}$$

式中: E_e 、 E_g 分别为燃煤机组、燃气机组增量 CO_2 排放; ρ_{CO_2} 为 CO_2 排放征收费用。

(2)增量总投资年值

增量总投资年值主要包括与基准场景相比的增量新能源投资年值、增量电网投资年值、增量火电灵活性改造投资年值和增量调峰电源建设投资年值,即

$$I = \sum_{i=1}^5 I_i \left[\frac{r_i (1 + r_i)^{n_i}}{(1 + r_i)^{n_i} - 1} \right] \quad (7.3)$$

式中: $i=1,2,3,4,5$, 分别表示新能源、电网、火电灵活性改造、储能成本和调峰电源; I_i 、 r_i 和 n_i 分别为投资、提现率和运行年限。

1) 新能源新增装机成本

光伏和风力发电新增装机成本由电站的度电成本进行合计,其具体含义是发电单位基于发电需求进行总体评价产生的所需成本,是在实际发电运行过程中,所产生的成本与发电量之间的比值。在实际的建设过程中,受相关政策及投资多元化需求等多种因素的影响,不同装机规模对应的发电成本各不相同,电站的装机规模设计成了衡量技术水平的一个关键性指标。为了验证其与度电成本之间存在的联系,采用公式(7.4)对其进行分析:

$$L_{\text{COE}} = \frac{\sum_{i=1}^T \frac{C_{\text{pvi}}}{(1+p)^i} + \sum_{i=1}^T \frac{C_{\text{cli}}}{(1+p)^i} + \sum_{i=1}^T \frac{C_{\text{omi}}}{(1+p)^i}}{\sum_{i=1}^T \frac{E_i}{(1+p)^i}} \quad (7.4)$$

式中, L_{COE} 表示度电成本, E_i 表示该系统第 i 年的发电总量, p 为折现率, T 为建设期所需的时限, C_{pvi} 为光伏区或风电区建设所需的投资, C_{cli} 为辅助工程的建筑投资,包括电站的交通、输变电工程以及生活管理设施等主要的建设投资, C_{omi} 是生产期的电站的运营维护成本。

2) 灵活性改造成本

主要体现为火电机组灵活性改造投资建设成本,为便于同年度仿真运行结果相比较,采用等额年金法,火电灵活性改造年化投资成本为:

$$F_1 = \sum_{i=1}^{N_f} C_i^r \frac{I_r (1 + I_r)^n}{(1 + I_r)^n - 1} \quad (7.5)$$

$$C_i^r = C_i^m \lambda_i^r \quad (7.6)$$

式中: F_1 为火电机组灵活性改造年化投资成本; C_i^r 为火电机组 i 的灵活性改造总投资成本; I_r 为利用率; n 为摊销年限; N_f 为火电机组改造数量; λ_i^r 火电机组 i 的单位容量投资改造成本。

3) 储能成本

大规模应用储能技术是提高含可再生能源电网的运行经济性和安全性的有效途径。为了合理评估储能在电网中应用的经济性,采用全生命周期成本方

法,根据抽水蓄能电站、压缩空气储能、铅酸电池、钠硫电池、液流电池、锂离子电池等储能成本和技术特性,选择更经济的抽水蓄能电站,进而测算此储能方式的投资、年费用和度电成本。

初始投资成本是指储能系统工程投建初期一次性投入的固定资金,通常用于主要设备的购置等,计算公式为:

$$C_{\text{In}}=C_P P_{\text{ESS}}+C_E E_{\text{ESS}} \tag{7.7}$$

式中: P_{ESS} 、 E_{ESS} 分别为储能的功率和容量; C_P 、 C_E 分别储能的功率和容量的单位投资。

运行维护成本是指为保障储能系统在寿命期内正常运行而动态投入的资金,通常包括储能系统的试验、安装、损耗、停运、人力、检修和维修等费用,以年为单位,计算公式为:

$$C_{\text{OM}}=K_O P_{\text{ESS}}+K_M Q_{\text{ESS}} \tag{7.8}$$

式中: K_O 为储能的单位功率年运行维护成本系数; K_M 为储能的单位容量年运行维护成本系数; Q_{ESS} 为储能的年发电量。

根据储能电站的全寿命周期成本,结合储能电站的年发电量,可计算储能电站的度电成本,计算公式为:

$$c_{\text{ESS}}=\frac{C_{\text{ESS}}}{Q_{\text{ESS}}}=\frac{C_{\text{In}}+C_{\text{OM}}}{\eta P_{\text{ESS}} H_{\text{ESS}}} \tag{7.9}$$

式中: C_{ESS} 为储能电站的度电成本; η 为储能电站的转换效率; P_{ESS} 为储能电站的装机容量; H_{ESS} 为储能电站的储电年利用小时数(表 7.2)。

表 7.2 储能电站相关参数

比较项目	抽水蓄能	压缩空气	铅酸电池	钠硫电池	液流电池	锂离子 电池
单位功率投资/ (元·kW ⁻¹)	5500	7100	—	—	—	—
单位容量投资/ [元·(kW·h) ⁻¹]	—	—	1200	7000	8000	2000
建设期/a	7	2	1	1	1	1
设备寿命/a	30	30	—	—	—	—
最大充放电次数	—	—	280	2500	12000	3000

续表

比较项目	抽水蓄能	压缩空气	铅酸电池	钠硫电池	液流电池	锂离子电池
单位功率投资/ (元·kW ⁻¹)	5500	7100	—	—	—	—
运行维护费率/%	2.50	2.00	0.50	0.50	0.50	0.50
电能转换效率/%	75	40	80	85	70	90

(3)年增量运行费用

年增量运行费用 F 主要包括增量项目固定运行费用和增量变动运行费用。其中增量固定运行费用与增量项目投资成正比,与设备运行发电状态无关。增量变动运行费用主要由火电机组调峰和启停费用构成,其中火电机组的调峰煤耗增加可由耗煤量和耗气量曲线获得。

$$F = \sum_{i=1}^4 I_i R_i + D_C P_C + D_G P_G \tag{7.10}$$

式中: R_i 为该类电源的固定运行费率; D_C 、 D_G 分别为增量煤耗、气耗; P_C 和 P_G 分别为煤价、气价。

7.4 甘肃省新能源合理利用率

7.4.1 考虑保供需求的新能源合理利用率

极端情况下,如果出现大范围极寒天气,2022—2025 年甘肃电力系统还存在约 659 万~1392 万 kW 调峰缺口。

“十四五”期间,甘肃省新能源并网规模将持续增长,调峰需求显著增加,在现有调峰能力挖掘殆尽的情况下,新建调峰电源是解决调峰缺口,保障系统安全,促进新能源健康发展的首要条件(图 7.12)。

现设定 3 种火电开机方式,测算 2022 年电力电量平衡。方式一:与上年度相同开机水平,优先保消纳;方式二:兼顾保供与保消纳,1 月、11 月、12 月火电全开,其余月份适当调整开机容量;方式三:优先保供,除 1 月、11 月、12 月硬缺口无法解决,保证其余月份没有供电缺口。测算结果表明,开机安排无法兼顾

保供与保消纳(表 7.3)。




图 7.12 晚高峰电力缺口图

表 7.3 2022 年不同火电开机方式下的电力电量平衡分析

	无储能			240 万 kW 储能		
	方式一	方式二	方式三	方式一	方式二	方式三
保供率/%	97.33	99.49	99.65	97.69	99.73	99.83
缺口小时数/h	2725	1004	654	2134	460	356
平均电力 缺口/万 kW	181	94	98	200	108	90
最大电力 缺口/万 kW	624	452	404	474	343	254
电量缺口 /万 kW·h	49	9	6	43	5	3
利用率/%	92.08	89.6	87.52	93.42	92.32	89.23
新能源 发电量/万 kW·h	561	551	533	569	563	544

如果以提高利用率目标,以储能利用小时数大于其盈利小时数(172 h)为前提,则储能容量需求 2022 年达 500 万 kW,2023 年达 1300 万 kW。除 2023 年利用率会降至 90%以外,2022 年及 2024 年利用率接近 95%。此需求高于保供的储能需求,亦可满足保供(图 7.13)。

新能源合理利用率之路




图 7.13 保供率与利用率耦合关系图

如果以保供率 99.5% 为目标,储能容量 2022 年达 240 万 kW,2023 年达 650 万 kW。2023 年利用率降至 86.92%,2022 年及 2024 年利用率超过 90%。

因此,建议 2022—2023 年的储能需求按照 240 万 kW、650 万 kW、650 万 kW 配置。考虑到新能源装机规划及断面限额,建议将储能按照河西 500 万 kW、河东 150 万 kW 配置(表 7.4)。

表 7.4 2022—2024 年考虑保供需求的合理利用率测算

年份	2022 年	2023 年	2024 年
正调峰需求/kW	522	743	847
保消纳 95%,负调峰需求/kW	150	434	242
保供 99.5%,储能配置(按 2 h)/kW	240	650	650
保消纳 95%,储能配置(按 2 h)/kW	500	1300	1300
合理利用率 1(按保供配储能后)/%	92.13	86.92	92.7
合理利用率 2(按保消纳配储能后)/%	94.99	90.26	95
储能可增发电量/亿 kW·h	11.29	49.59	45.73
配储能利用小时数/h	213	190	176
电量缺口/亿 kW·h	19.23	32.83	36.59
储能放电后缺口/亿 kW·h	7.94	0	0

7.4.2 2030 合理利用率及“碳达峰”远景目标分析

按国家能源局《关于征求 2021 年可再生能源电力消纳责任权重和 2022—

2030 年预期目标建议的函》中 2030 年全社会用电量为 2021 年的 1.375 倍,确定甘肃省 2030 年全社会用电量为 2013 亿 kW·h。按建成三大直流,外送电量按 1500 亿 kW·h 考虑。考虑常规机组容量不变,月度最大电量缺口(1 月、12 月)与 2024 年保持相同水平,确定需要新增的新能源装机和抽水蓄能装机。按表 7.5 中测算的几种情况,建议新增 4000 万 kW 风电、4000 万 kW 光伏、1000 万 kW 抽水蓄能,方可满足用电需求,且保证新能源利用率在 77%。通过建设储能设施、开展需求侧响应增加电网调峰能力 700 万 kW 后可提升至 85%(建议将此作为 2030 年合理利用率)。

表 7.5 2030 年碳达峰远景目标测算

抽水蓄能/万 kW	0	500	500	1000	800
新增风电装机(相对 2024)/万 kW	7000	5000	4000	4000	4000
新增光伏装机(相对 2024)/万 kW	7000	5000	4000	4000	4000
月度最大缺口/亿 kW·h	13	4	9	0	3
新能源利用率/%	42	62	69	77	74
新能源发电占比/%	49	64	61	74	69

第

8

章

甘肃省新能源绿色发展 路径规划

8.1 工作思路

围绕构建以新能源为主体的新型电力系统对调度精细化管理的需求,发挥甘肃省在高比例新能源的独特优势,坚持“系统观念、统筹推进,保障安全、最大消纳,绿色发展、有序转型”原则,统筹新能源发展“量”“率”关系,实现量率一体、量率协调,从 5 方面制定新能源消纳 18 项举措,明确目标和责任分工,多措并举、攻坚克难,千方百计地推动新能源消纳,为保安全、保供电、保消纳提供有力支撑,助力新型电力系统构建和能源转型。

8.2 工作目标

坚持“能并尽并”,2022 年服务新能源新增并网 1550 万 kW。

坚持“能发尽发”,2022 年新能源发电量力争完成 550 亿 kW·h,新能源利用率力争完成 90%以上,非水责任权重超过 19.25%。

8.3 消纳措施

建立新能源消纳预警预报体系。滚动开展新能源消纳测算,按季度形成新能源消纳情况预测分析专报,重点把握布局和时序,引导新能源有序发展。针对戈壁、沙漠、荒滩等大基地项目建设,“三涉”(涉冶、涉交、涉建)企业新能源项目建设专题开展新能源消纳情况研究与预判。

开展各类新能源差异化统计分析。针对不同类型的并网新能源项目,建立差异化的新能源市场消纳方案和调度原则。升级新能源有功智能控制系统,提升新能源实时监控水平,优化新能源可视化界面。坚持“日统计、周分析、月通

新能源合理利用率之路

报”，按照分片区、分性质、分项目的原则精细化统计新能源利用率。

推动电化学储能深化应用。按照“集中与分散、自建与共享”原则，不断完善适应大规模储能参与的辅助服务和现货市场机制，研究储能调度策略、加快储能控制系统建设。

加快抽水蓄能规划建设。全力推动玉门昌马抽水蓄能项目核准开工，张掖盘道山、临夏东乡等年内完成(预)可研。

推动各级电网协调发展。持续推进祁韶直流配套电源建设。推动陇东直流核准，尽早开工。携手送、受两端推动陇电入浙和陇电入沪特高压直流工程早日纳规。开展甘川电力互济、陇电入桂以及河西走廊廊道规划等专项研究。协调推动新调增电网项目纳入国家电力规划和国网公司电网规划。

提升祁韶直流输送能力。加快常乐电厂建设进度，力争 2023 年 8 月完成 #1、#2 机组双投，确保祁韶直流达到设计送电能力。

优化电网检修计划。强化电网检修停电计划管理，做好主网设备与新能源联合检修，保障清洁能源消纳和电力电量平衡。

引导火电灵活性改造。编制《“十四五”甘肃电网火电机组调峰能力建设方案》，重点推动火电机组灵活性改造和“火储”联合项目投产，加快连城、甘谷电厂复工复产。

大力挖掘需求侧调节资源。全面梳理潜在泛在资源，开展用户侧负荷响应，建立精准负荷控制机制，实现电网“源荷互动”调节模式。开展甘肃电网需求侧资源辅助服务市场建设，采用浮动价格机制激发用户参与市场的积极性，引导更多用户参与市场交易，进一步释放调峰资源的同时促进地方经济发展。

持续推进省内现货市场建设。完善两级市场、三级调度协同机制。健全统一电力市场体系下三级调度安全校核机制，开展新能源参与中长期市场机制研究，完善中长期市场与现货市场的衔接机制，统筹各类交易有序衔接。优化电力生产组织模式，规范“两级市场”工作衔接流程。促进市场化资源配置与电力供应保障的有机结合，实现经济与安全的双统筹。

积极利用省间现货市场确保新能源消纳。根据省内富余发电能力及电力缺口积极参与省间现货市场，最大化利用省间市场确保省内保供及新能源消纳。

继续做好自备电厂替代工作。加强自备电厂运行管理，挖掘自备电厂调峰能力，提高新能源消纳水平。

加大省间余缺互济力度。推动与新疆、四川签订政府间能源电力合作协议。与西北区域内陕西、宁夏、新疆等周边省份签订电力供应互保协议,扩大互济交易规模。

签订合理外送曲线。依据省内新能源发电特性签订合理的外送曲线,在4~10月外送能力强时加大外送,日内增加午间外送量。

提升风光功率预测精度。制定《新能源功率预测提升工作实施方案》,从管理机制、气象数据、算法模型、数据质量、技术支撑5方面制定提升新能源功率预测的20项举措,明确工作思路和目标,明晰各方职责和完成时限,网厂协同,开展新能源预测机制创新、科技攻关、创新实践和技术支撑,形成“2套主站预测+1套场站上报”的多重预测、多种选优的模式,提高全网预测精度。不断提高新能源中长期电量预测的可用性。将新能源功率预测延长到10d,10d预测准确率应满足风电不低于75%、光伏不低于80%的要求。

推进分布式电源“可观、可测、可控”。落实《服务分布式光伏整县推进调度专业实施方案》,建设全省分布式光伏一体化平台,实现信息监测、统一预测、一体化管理。推进存量分布式电源信息接入。全省统一建设分布式光伏预测预报系统开展集中预测,实现预测结果共享。

研究新能源纳入电力电量平衡标准。研究新能源预测值在不同范围、不同电网备用条件时按照不同的标准纳入电力电量平衡,建立将新能源纳入电力电量平衡的动态调整机制。

加大新能源技术创新研究。紧密结合“双碳”目标下构建以新能源为主的新型电力系统过程中面临的问题与挑战,借助高校及科研院所的科研力量,立足甘肃电网消纳实际,致力于解决多尺度新能源功率预测、日内预测偏差校正、新能源纳入电力电量平衡的技术与标准研究,力争通过科技创新实现新形势下保安全、保供电、保消纳等多目标的最优,助力“双碳”目标实现。

第

9

章

新能源装机容量与 利用率协调的建议

9.1 强化新能源发展统筹规划

实现碳达峰、碳中和,构建以新能源为主体的新型电力系统,事关经济社会发展全局和长期战略,需要坚持电力系统“统一规划、统一调度、统一管理”的体制优势,保证系统安全运行和可靠供电,实现整体效率最优。

一是做好新能源与电网规划的统筹。制定新能源发展专项规划,综合考虑外送通道、资源水平、消纳权重、利用率、投资收益等要素,分区域、分年度细化分解新增指标,进一步明确建设时序,引导新能源项目与配套送出工程同步规划、同步建设、同步投运。

二是加强国家和地方规划的衔接。国家规划是各省级规划编制的重要依据,应在统筹考虑跨省区输电通道、火电灵活性改造、抽水蓄能等关键边界条件基础上,明确全国和各省区发展目标,确保国家和地方规划上下衔接、协调统一。

三是实现不同政策机制效果互认。目前促进新能源消纳的各项政策主要目标一致,只是实现路径不同,虽然已有部分衔接机制出台,但由于分管部委的不同、发展阶段的差异,仍需进一步加强协同配合。如,需明确同一份可再生能源发电量的环境效益不能通过多种渠道重复变现,但绿证和 CCER 两种权证可以互认在绿电消费和碳减排中的作用。再如,碳排放权配额和用能权指标两类配额,由于燃料消耗和碳排放量之间可以相互换算,若开展全国用能权交易,在制度出台时需要考虑两类配额能否按比例进行抵用的问题。

四是推动各项配套措施完整落地。火电灵活性改造、抽水蓄能、电化学储能等提高系统调节能力的配套措施,对保障新能源高水平消纳至关重要,需要明确各省区工作目标,压实各方责任,推动各项措施落实到位。不断提高电网平衡调节能力,保障新能源大规模并网运行。

9.2 适度超前能源基础设施建设与系统研究

“硬”的方面:加强跨省输电通道建设、灵活性调节资源建设、大型风光基地的建设。完善送受端网架,增强省间电力互济,提升电网资源优化配置能力,使电网更能适应新能源的出力特性,优化调度,提升电网对“源—网—荷—储”的协同调度能力,提高系统消纳能力和平衡能力;考虑新能源的同时率和利用率,建设 6 倍于负荷的新能源,与负荷相当的各种类型储能或抽水蓄能。

“软”的方面:加强新能源科技创新引领。推进电网潮流数字化,实时计算每度电的来源及流向,这是激励使用绿电的基础、储能灵活调用的基础。加强负荷基准调控系统建设,需求侧响应高效发挥作用的基础。加强新能源消纳的科技研究。加强自主创新,鼓励龙头企业以“产学研用”一体化模式,加快核心技术部件研发,提升新能源产业链供应链水平,提高装备国产化率和自主安全可控能力。落实绿电消费的责任主体。

9.3 深入推进电力体制改革

中国统一电力市场建设政策导向性强,单纯依靠市场很难达成共识。建议在国家层面建立长效机制,尽快研究制定跨省跨区输电指导意见,合理引导市场主体行为,发挥资源优化配置作用。通过开展发电容量预测,引入招标机制和容量市场,保证系统发电容量充裕性。加快建设全国统一电力市场,完善相关配套政策,发挥市场配置资源的决定性作用。明确保障性收购与市场化交易衔接实施细则。

坚持科技创新与体制机制双轮驱动,发挥市场配置资源作用,充分调动发电侧、需求侧等的灵活调节资源,加快适应新能源消纳的市场体系建设。突破大规模、长周期、高安全、低成本的储能技术。在多日、周、季等更长时间尺度下,探索氢能(新能源直接电解水制氢)储能方式。研究可快速启停的火电机

组,研究未来新型电力系统的负荷备用、旋转备用、停机事故备用容量大小及方式选择。研究一定比例的储能 SOC 容量作为负荷备用实现无火电机组支撑的大规模新能源基地建设。

建立高比例新能源消纳考核机制,保量才能保发展,保率才能高质量发展,基于“量率一体”原则设定合理消纳目标,以全社会效益最大化为目标,分省(区)设置合理的新能源利用率考核指标。考核利用率逐步过渡到考核发电占比。过渡期建议在总的利用率目标下对分省新能源利用率目标按装机占比进行差异化分档管理:装机占比在 25% 的设定为 100%;装机在 25%~30% 的设定为 99%;装机在 30%~40% 的装机占比每增加 1%,设定利用率在 99% 的基础上下降 0.5%,最低不得低于 95%;装机超过 40% 的,设定利用率在 95% 的基础上,装机占比每增加 1%,利用率下降 1%;装机占比超过 50% 的,不考核利用率。

加强电力市场、绿色证书、碳市场的衔接。从政策、进程、机制、价格等方面推动电力市场和碳市场协调发展,完善新能源参与碳市场机制,建立碳价与电价传导机制,设计适应高比例新能源发展的交易模式,将用户对绿色电力的需求转变为用户自主的刚性需求,实现消纳成本的疏导,从经济上保障新型电力系统建设。

培育鼓励多元市场主体、完善市场机制。引导新兴主体参与电力市场,创新交易服务模式,充分激发灵活调节潜力,促进能源互联网的价值创造。对储能灵活使用,鼓励源侧储能全网用,实现储能能充能放。鼓励市场化新能源企业租用储能容量。鼓励负荷聚合商、电动车充电桩聚合商。鼓励绿电制氢。鼓励金融机构参与中长期市场,“金融”手段与“物理”手段相结合。国家层面制定出台需求响应价格政策和市场化机制,深入挖掘负荷侧灵活调节潜力,提高电力系统运行弹性,并进一步形成电、热、气等多能源耦合与协同优化。采用类似于消费互联网、社交互联网的简单化交易场景,创新市场服务机制,提升市场配置效率。

参考书目

- 庄贵阳,周宏春,2021. 碳达峰碳中和的中国之道[M]. 北京:中国财政经济出版社.
- 中国长期低碳发展战略与转型路径研究课题组,清华大学气候变化与可持续发展研究院, 2021. 读懂碳中和[M]. 北京:中信出版社.
- 宋枫,2019. 新能源消纳问题研究[M]. 北京:科学出版社.
- 谢国辉,栾凤奎,李娜娜,等,2018. 新能源消纳影响因素的贡献度评估模型[J]. 中国电力,51(11):125-131.
- 郭明亮,郭爱,邓文丽,等,2019. 铁路牵引用背靠背光伏发电系统及其消纳能力研究[J]. 太阳能学报,40(12):3444-3450.
- 董存,梁志峰,礼晓飞,等,2019. 跨区特高压直流外送优化提升新能源消纳能力研究[J]. 中国电力,52(04):41-50.
- 刘吉臻,曾德良,田亮,等,2015. 新能源电力消纳与燃煤电厂弹性运行控制策略[J]. 中国电机工程学报,35(21):5385-5394.
- 史连军,邵平,张显,等,2017. 新一代电力市场交易平台架构探讨[J]. 电力系统自动化,41(24):67-76.
- 李京虎,2021. 基于常规煤电灵活性改造的电力系统运行优化研究[D]. 太原:山西大学.
- 刘德伟,黄越辉,2011. 西班牙风电高比例消纳研究及启示[J]. 中国能源,33(03):25-28.
- 陈艺华,张伟,张成刚,等,2021. 促进新能源消纳的省间、省内两级电力现货市场运行机制[J]. 电力系统自动化,45(14):104-113.
- 文旭,杨可,毛锐,等,2021. 高水电占比西南电力调峰辅助服务市场构建[J]. 全球能源互联网,4(03):309-319.
- 叶泽,李湘旗,姜飞,等,2021. 考虑最优弃能率的风光火储联合系统分层优化经济调度[J]. 电网技术,45(06):2270-2280.
- 张敏,刘进,林江刚,等,2021. “双碳”背景下屋顶分布式光伏开发环境效益分析[J]. 能源研究与利用,(06):37-41.
- 宋士瞻,王传勇,康文文,等,2018. 考虑多重出力不确定性的风光装机容量优化[J]. 山东大学学报(工学版),48(06):101-108.
- 白建华,辛頌旭,贾德香,等,2010. 中国风电开发消纳及输送相关重大问题研究[J]. 电网与清洁能源,26(01):14-17.

- 王艺博,蔡国伟,郑存龙,等,2016.考虑合理弃风的风电消纳方法研究[J].电测与仪表,53(11):45-50.
- 王耀华,栗楠,元博,等,2017.含大比例新能源的电力系统规划中“合理弃能”问题探讨[J].中国电力,50(11):8-14.
- 董昱,董存,于若英,等,2022.基于线性最优潮流的电力系统新能源承载能力分析[J].中国电力,55(03):1-8.
- 吕泉,王伟,韩水,苑舜,等,2013.基于调峰能力分析的电网弃风情况评估方法[J].电网技术,37(07):1887-1894.
- 王丙乾,董剑敏,关前锋,2018.基于调峰能力分析的电网弃风评估方法及风电弃风影响因素研究[J].南方能源建设,5(02):71-76.
- 沈超,秦潇璘,李永刚,2016.考虑发电侧成本的新能源消纳能力评估[J].电力科学与工程,32(11):1-6.
- 宋士瞻,王传勇,康文文,等,2018.基于时序生产模拟的配电网光伏装机容量规划[J].山东大学学报(工学版),48(05):131-136.
- 张谦,李琥,高松,2010.风电对调峰的影响及其合理利用模式研究[J].南方电网技术,4(06):18-22.
- 刘新东,方科,陈焕远,等,2012.利用合理弃风提高大规模风电消纳能力的理论研究[J].电力系统保护与控制,40(06):35-39.
- 洪麟,2012.风电接入后的辅助服务补偿机制研究[D].北京:华北电力大学.
- 王玫,2013.促进风电利用的调峰辅助服务补偿及交易机制研究[D].北京:华北电力大学.
- 高春杰,2013.大规模风电并网考核与交易机制研究[D].北京:华北电力大学.
- 李丰,张粒子,2013.大规模风电跨省消纳与交易机制的研究[J].电力自动化设备,33(08):119-124.
- 蔡秋娜,2012.辅助服务管理机制与辅助服务市场竞价策略研究[D].广州:华南理工大学.
- 牛韩伟,2016.电网调峰辅助服务交易系统的设计与实现[D].哈尔滨:黑龙江大学.
- 王斌,苏适,邵武,周伟,等,2015.抽水蓄能电站节能效益综合分析系统[J].新型工业化,5(07):8-17,23.
- 国网新源控股有限公司,2007.抽水蓄能电站静态效益评估研究综述[C]//抽水蓄能电站工程建设文集:14-22.
- 陈昆灿,刘峻,江熠,2018.储能电站商业模式初步研究[J].上海节能,(01):13-17.
- 李德智,田世明,王伟福,等,2019.分布式储能的商业模式研究和经济性分析[J].供用电,36(04):86-91.
- 吴敬儒,张建贤,2015.甘肃酒泉风电与抽水蓄能电站协同发展分析[J].开发性金融研究,2

新能源合理利用率之路

- (02):74-77.
- 电池储能电站发展扶持政策研究课题组,2013. 国外电池储能电站发展及其政策扶持[J]. 上海节能,(05):27-29.
- 肖达强,黎舒婷,舒康安,等,2016. 我国抽水蓄能电站的管理体制和运营模式探讨[J]. 电器与能效管理技术,(14):79-84.
- 舒印彪,张智刚,郭剑波,等,2017. 新能源消纳关键因素分析及解决措施研究[J]. 中国电机工程学报, 37(1): 1-8.
- 国际可再生能源署,2020. 可再生能源统计年鉴 2020[R]. 阿布扎比:国际可再生能源署.
- 李琼慧,2017. 新能源消纳机制的欧洲启示[J]. 国家电网,(7):79-82.
- 裴哲义,王彩霞,和青,等,2016. 对中国新能源消纳问题的分析与建议[J]. 中国电力, 49(11): 1-7.
- 熊祥鸿,马丽萍,2014. 欧洲电力市场化改革及对我国的启示[J]. 华东电力,42(12): 2735-2738.
- 解也力,2022. 一图读懂《关于完善能源绿色低碳转型体制机制和政策措施的意见》. <https://baijiahao.baidu.com/s?id=1724873354118762167&wfr=spider&for=pc>. 2022-02-16/2022-05-08.
- 郭剑波,2021. 新型电力系统面临的挑战以及有关机制思考. 中国电力企业管理.
- 张智刚,康重庆,2022. 碳中和目标下构建新型电力系统的挑战与展望[J]. 中国电机工程学报, 42(8): 2806-2818.
- 赵文瑛,2022. 新型电力系统构建的挑战及思考[R]. 全国新能源消纳监测预警中心.
- 全国新能源消纳监测预警中心,2022. 2021 年四季度全国新能源电力消纳评估分析. <https://news.bjx.com.cn/html/20220314/1209966.shtml>. 2022-03-14/2022-05-07.