

Journal of System Simulation

Volume 34 | Issue 8

Article 20

8-15-2022

Day Ahead Thermal-photovoltaic Economic Dispatch Considering Uncertainty of Photovoltaic Power Generation

Xinghua Liu

1.School of Electrical Engineering, Xi'an University of Technology, Xi'an 710054, China; liuxh@xaut.edu.cn

Chen Geng

1.School of Electrical Engineering, Xi'an University of Technology, Xi'an 710054, China;

Shenghan Xie

1.School of Electrical Engineering, Xi'an University of Technology, Xi'an 710054, China;

Jiaqiang Tian

1.School of Electrical Engineering, Xi'an University of Technology, Xi'an 710054, China;
tjq1992@mail.ustc.edu.cn

See next page for additional authors

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>

 Part of the Artificial Intelligence and Robotics Commons, Computer Engineering Commons, Numerical Analysis and Scientific Computing Commons, Operations Research, Systems Engineering and Industrial Engineering Commons, and the Systems Science Commons

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

Day Ahead Thermal-photovoltaic Economic Dispatch Considering Uncertainty of Photovoltaic Power Generation

Abstract

Abstract: Aiming at the uncertainty and randomness of photovoltaic power generation affected by weather factors, a mathematical model of day ahead thermal-photovoltaic economic dispatch considering seasonal weather factors is established. *The mathematical model takes the operation cost of thermal power units, the cost of photovoltaic power generation, the cost of spinning reserve and the forecast error cost of photovoltaic power generation affected by weather factors as the economic objective function, and the sulfur dioxide emission of thermal power units as the environmental objective function.* In order to improve the accuracy of photovoltaic output prediction, the long short term memory neural network with seasonal weather factors is used to predict the photovoltaic power generation. The model is solved by Cplex, and the effectiveness and feasibility of the proposed model are proved by case simulation.

Keywords

economic dispatch, photovoltaic power generation, prediction error cost, long short term memory neural network

Authors

Xinghua Liu, Chen Geng, Shenghan Xie, Jiaqiang Tian, and Hui Cao

Recommended Citation

Xinghua Liu, Chen Geng, Shenghan Xie, Jiaqiang Tian, Hui Cao. Day Ahead Thermal-photovoltaic Economic Dispatch Considering Uncertainty of Photovoltaic Power Generation[J]. Journal of System Simulation, 2022, 34(8): 1874-1884.

考虑光伏发电不确定性的日前火电-光伏经济调度

刘兴华¹, 耿晨¹, 谢胜寒¹, 田佳强^{1*}, 曹晖²

(1. 西安理工大学 电气工程学院, 陕西 西安 710054; 2. 西安交通大学 电气工程学院, 陕西 西安 710049)

摘要: 针对光伏发电受季节天气因素影响产生的不确定性和随机性的问题, 建立了考虑光伏发电不确定性的日前火电-光伏经济调度的数学模型。以传统火电机组的运行成本、光伏发电成本、旋转备用成本, 以及受到季节天气因素影响的光伏发电预测误差成本为经济目标函数; 以火电机组的二氧化硫排放为环保目标函数。为提高光伏出力预测的准确性, 采用加入季节天气因素的长短时记忆神经网络对于光伏发电进行预测, 通过Cplex对所构建的模型进行求解, 结果表明了所提模型的有效性和可行性。

关键词: 经济调度; 光伏发电; 预测误差成本; 长短时记忆神经网络

中图分类号: TM7; TP391.9 文献标志码: A 文章编号: 1004-731X(2022)08-1874-11

DOI: 10.16182/j.issn1004731x.joss.21-0336

Day Ahead Thermal-photovoltaic Economic Dispatch Considering Uncertainty of Photovoltaic Power Generation

Liu Xinghua¹, Geng Chen¹, Xie Shenghan¹, Tian Jiaqiang^{1*}, Cao Hui²

(1. School of Electrical Engineering, Xi'an University of Technology, Xi'an 710054, China;
2. School of Electrical Engineering, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: Aiming at the uncertainty and randomness of photovoltaic power generation affected by weather factors, a mathematical model of day ahead thermal-photovoltaic economic dispatch considering seasonal weather factors is established. The mathematical model takes the operation cost of thermal power units, the cost of photovoltaic power generation, the cost of spinning reserve and the forecast error cost of photovoltaic power generation affected by weather factors as the economic objective function, and the sulfur dioxide emission of thermal power units as the environmental objective function. In order to improve the accuracy of photovoltaic output prediction, the long short term memory neural network with seasonal weather factors is used to predict the photovoltaic power generation. The model is solved by Cplex, and the effectiveness and feasibility of the proposed model are proved by case simulation.

Keywords: economic dispatch; photovoltaic power generation; prediction error cost; long short term memory neural network

引言

根据国家能源局统计的2020年可再生能源并网运行状况可知, 光伏发电量达2 605亿kw/h, 同比

增长16.1%, 全国光伏平均利用小时数为1 160 h^[1]。虽然光伏发电量和光伏利用小时在不断增加, 但光伏发电的随机性和不确定性仍然给电力系统的调度带来挑战, 因此需要对光伏发电不确定性进

收稿日期: 2021-04-20 修回日期: 2021-05-27

基金项目: 国家自然科学基金(61903296, U2003110); 陕西省教育厅重点实验室项目(20JS110); 陕西省青年科技新星项目(2020KJXX-094)

第一作者: 刘兴华(1984-), 男, 博士, 教授, 研究方向为智能电网运行优化与控制。E-mail: liuxh@xaut.edu.cn

通讯作者: 田佳强(1992-), 男, 博士, 讲师, 研究方向为智能电网储能。E-mail: tjq1992@mail.ustc.edu.cn

行正确的表示, 减少其对电力系统经济调度的影响^[2]。

文献[3]通过太阳辐射度的范围确定光伏发电的大小; 文献[4]考虑到风光互补特性, 将风光联合分布与风电边缘分布和光伏发电边缘分布结合起来, 并利用t-copula函数得到风光的预测功率; 文献[5]通过光伏发电的预测误差表示光伏发电的不确定性; 文献[6]使用自回归滑动平均模型(autoregressive moving average model, ARMA)生成光伏发电的预测值大小, 使用ARMA(1, 1)生成光伏发电的预测误差的大小, 将光伏发电分为预测值和预测误差值2部分, 充分体现出光伏发电的不确定性。但ARMA的预测时序模型建成后, 当预测步长增大时, 预测误差将会增加。因此, 为了更好地预测表示光伏发电, 采用合适的方法对光伏发电的预测值和预测误差进行表示是十分重要的。

神经网络作为一种数学工具, 具有分类、数据挖掘、模式识别、预测等用途^[7]。长短时记忆(long short term memory, LSTM)神经网络是一种能够处理时序列预测问题的改进循环神经网络(recurrent neural network, RNN)模型^[8], 适合于具有不确定性的光伏发电的出力预测。光伏发电的预测与天气因素有关, 并且光伏出力的预测误差并非都是正态分布, 只有在天气较为晴朗时光伏出力的预测误差才接近正态分布^[9]。文献[10]通过实验表明, 使用t-Location Scale函数对光伏发电的预测误差进行拟合, 可以得到不同天气类型下的光伏出力的预测误差概率分布。

本文提出了一种考虑光伏发电不确定性的日前火电-光伏经济调度解决方案。为了模拟光伏发电的不确定性, 采用拉丁超立方抽样生成1 000个光伏发电场景^[11]。

1 经济调度的数学模型

1.1 目标函数

在计及季节天气因素的日前火电-光伏经济调

度中, 光伏发电出力具有优先权, 即在白天时光伏发电作为首选供应电源, 火电机组作为备用机组应对光伏出力的波动和电量的缺额; 在夜晚时光伏不出力, 火电机组作为首选供应电源, 旋转备用机组作为备用机组应对电量的缺额。

计及季节天气因素的日前火电-光伏经济调度的目标函数是最小化经济成本和二氧化硫排放量, 其中, 经济成本包含火电机组成本、旋转备用机组成本、光伏发电成本, 以及光伏发电预测误差造成成本, 光伏发电预测误差造成成本由2部分组成: ①当预测光伏发电出力小于光伏发电实际值时产生的低估预测误差成本; ②当预测光伏发电出力大于光伏发电的实际值时产生的高估预测误差成本。环保成本考虑火电机组运行产生的二氧化硫排放量最小。

经济成本为

$$\begin{aligned} \min C(t) = & \sum_{i=1}^T \sum_{j=1}^{N_i} (C_{g,i,t}(P_{i,t}) + S U_{i,t} + S D_{i,t}) + \\ & \sum_{j=1}^T \sum_{i=1}^{N_j} C_{v,j,t}(P_{j,t}) + \sum_{j=1}^T \sum_{i=1}^{N_j} C_{uv,j,t}(P_{u,j,t}) + \\ & \sum_{j=1}^T \sum_{i=1}^{N_j} C_{ov,j,t}(P_{o,j,t}) + \sum_{k=1}^T \sum_{i=1}^{N_k} C_{r,k,t}(P_{r,k,t}) \end{aligned} \quad (1)$$

式中: T 为总调度时间, 取值为24; N_i 为火电机组的总台数; N_j 为光伏电站的总数; N_k 为旋转备用机组的总台数; $C(t)$ 为 t 时刻总经济成本; $C_{g,i,t}$ 为第*i*台火电机组在*t*时刻的成本; $P_{i,t}$ 为第*i*台火电机组在*t*时刻的功率; $SU_{i,t}$ 为第*i*台火电机组在*t*时刻的启动成本; $SD_{i,t}$ 为第*i*台火电机组在*t*时刻的停机成本; $C_{v,j,t}$ 为第*j*个光伏电站*t*时刻的用电成本; $P_{j,t}$ 为第*j*个光伏电站*t*时刻的实际使用功率; $C_{uv,j,t}$ 为第*j*个光伏电站*t*时刻的低估预测误差成本; $P_{u,j,t}$ 为第*j*个光伏电站*t*时刻的高估预测误差功率; $C_{ov,j,t}$ 为第*j*个光伏电站*t*时刻的高估预测误差成本; $P_{o,j,t}$ 为第*j*个光伏电站*t*时刻的高估预测误差功率; $C_{r,k,t}$ 为第*k*台旋转备用机组在*t*时刻的旋转备用费用; $P_{k,t}$ 为第*k*台

旋转备用机组在 t 时刻的旋转备用功率。

$$C_{g,i,t}(P_{i,t}) = a_i + b_i P_{i,t} + c_i(P_{i,t})^2 \quad (2)$$

$$C_{v,j,t}(P_{j,t}) = K_{PV,j,t} P_{j,t} \quad (3)$$

$$C_{uv,j,t}(P_{u,j,t}) = K_{PVU,j,t}(P_{j,t} - P_{f,j,t}) \quad (4)$$

$$C_{ov,j,t}(P_{o,j,t}) = K_{PVO,j,t}(P_{f,j,t} - P_{j,t}) \quad (5)$$

$$C_{r,k,t}(P_{r,k,t}) = \rho_k P_{r,k,t} \Delta t \quad (6)$$

式中： a_i 、 b_i 、 c_i 分别为第*i*台火电机组的常数项、一次项、二次项的煤耗系数； $K_{PV,j,t}$ 为第*j*个光伏电站站在*t*时刻的成本系数； $P_{f,j,t}$ 为第*j*个光伏电站站在*t*时刻的预测光伏出力； $K_{PVU,j,t}$ 为第*j*个光伏电站站在*t*时刻的低估预测误差成本系数； $K_{PVO,j,t}$ 为第*j*个光伏电站站在*t*时刻的高估预测误差成本系数； ρ_k 为第*k*台旋转备用机组的系数； Δt 为时间间隔，取60 min。

二氧化硫的排放最小^[12]：

$$\min E(t) = \sum_{t=1}^T \sum_{i=1}^{N_i} (\alpha_i + \beta_i P_{i,t} + \gamma_i(P_{i,t})^2) \quad (7)$$

式中： α_i 、 β_i 、 γ_i 分别为第*i*台火电机组的常数项、一次项、二次项的二氧化硫排放系数。

1.2 约束条件

电力平衡约束表示以光伏、火电机组和旋转备用机组作为电源时，满足系统的负荷需求：

$$\sum_{i=1}^{N_i} P_{i,t} + \sum_{j=1}^{N_j} P_{j,t} + \sum_{k=1}^{N_k} P_{k,t} = P_{L,t} \quad (8)$$

式中： $P_{L,t}$ 为*t*时刻的负荷大小。

火电机组的功率上下限约束：

$$X_{i,t} P_i^{\min} \leq P_{i,t} \leq X_{i,t} P_i^{\max} \quad (9)$$

式中： P_i^{\max} 为第*i*台火电机组的最大输出功率； P_i^{\min} 为第*i*台火电机组的最小输出功率； $X_{i,t}$ 为第*i*台火电机组在*t*时刻的启停状态，若是0则表示机组关闭，1则表示机组运行。

火电机组的最小启停时间的约束：

$$T_{i,t}^{\text{st}} \geq T_i^{\text{st}} \quad (10)$$

$$T_{i,t}^{\text{ed}} \geq T_i^{\text{ed}} \quad (11)$$

式中： $T_{i,t}^{\text{st}}$ 为第*i*台火电机组在*t*时刻的持续开机时长； T_i^{st} 为第*i*台火电机组的最小开机时长； $T_{i,t}^{\text{ed}}$ 为第*i*台火电机组在*t*时刻的持续停机时长； T_i^{ed} 为第

*i*台火电机组的最小停机时长。

火电机组和旋转备用机组的爬坡率约束：

$$P_{i,t} - P_{i,(t-1)} \leq \Delta t R_i^{\text{up}} \quad (12)$$

$$P_{i,(t-1)} - P_{i,t} \leq \Delta t R_i^{\text{dn}} \quad (13)$$

$$P_{k,t} - P_{k,(t-1)} \leq \Delta t R_k^{\text{up}} \quad (14)$$

$$P_{k,(t-1)} - P_{k,t} \leq \Delta t R_k^{\text{dn}} \quad (15)$$

式中： Δt 为计划周期内时间间隔，取60 min； R_i^{up} 、 R_i^{dn} 分别为第*i*台火电机组的爬坡率、降坡率； R_k^{up} 、 R_k^{dn} 分别为第*k*台旋转备用机组的爬坡率、降坡率。

旋转备用约束：

$$\sum_{i=1}^{N_i} X_{i,t} P_i^{\max} + \sum_{k=1}^{N_k} P_{k,t} \geq P_{L,t} + R_t \quad (16)$$

$$\sum_{i=1}^{N_i} X_{i,t} P_i^{\min} + \sum_{k=1}^{N_k} P_{k,t} \leq P_{L,t} + R_t \quad (17)$$

式中： R_t 为系统在*t*时刻系统的旋转备用。

光伏发电的上下限约束：

$$P_{j,t,e}^- \leq P_{j,t,e} \leq P_{j,t,e}^+ \quad (18)$$

$$P_{j,t,e} = P_{f,j,t} - P_{j,t} \quad (19)$$

式中： $P_{j,t,e}$ 为光伏电站站在*t*时刻的输出预测误差； $P_{j,t,e}^-$ 、 $P_{j,t,e}^+$ 分别为光伏发电在*t*时刻的输出预测误差下限和上限。

2 光伏出力的预测

2.1 天气类型聚类分析

根据国家气象局的标准，天气状态可以划分为47种类型^[13]，然而在经济调度中对每一种天气类型下的光伏出力进行预测是十分繁琐的，因此使用k-means聚类法对光伏出力的历史数据进行聚类，具体划分为晴天，阴天和雨天3种类型。同时考虑到不同季节下的天气类型也是不同的，在预测时加入季节影响因素也是十分必要的。

考虑到夜间光伏电站不出力，对06:00—18:00的光伏出力进行预测，共13个出力时刻。使用k-means聚类法进行聚类的步骤如下：首先随机产生晴天、阴天和雨天这3种典型天气类型下06:00—18:00的3个光伏出力曲线作为的初始质心；

其次，以某天的光伏出力曲线中的06:00—18:00光伏出力作为待聚类的对象，计算这条出力曲线与初始质心之间的欧式距离；最后，将待聚类的天气类型分配给与初始质心距离最小的对应的天气类型下，直至初始质心不在变化或者达到迭代次数为止。

具体为

$$d = \sqrt{\sum_{i=1}^{13} (x_i - y_i)^2} \quad (20)$$

式中： i 为小时数； x_i 为待判断天气类型下第*i*小时的光伏出力； y_i 为典型天气类型下第*i*小时的光伏出力； d 为两曲线之间的欧式距离大小。

2.2 光伏出力的预测

LSTM神经网络具有特殊的门结构，解决了RNN神经网络中的梯度消失问题^[14]，可以很好地处理时序预测问题，即可以通过学习前面时刻的信息预测下一时刻的信息，因此使用LSTM神经网用来预测光伏出力。LSTM神经网络具体的结构示意图如图1所示^[15]。

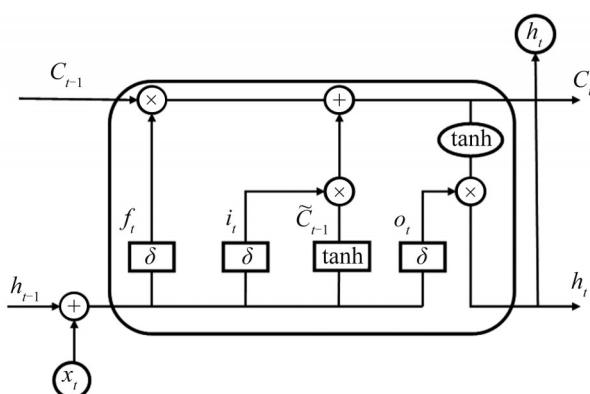


图1 LSTM神经网络结构图
Fig. 1 Structure diagram of LSTM neural network

图1中 x_t 为*t*时刻网络的输入变量； h_{t-1} ， h_t 为*t-1*和*t*时刻的输出状态； C_{t-1} 和 C_t 为*t-1*，*t*时刻的记忆单元状态； f_t 为遗忘门； i_t 为输入门； o_t 为输出门； \tilde{C}_{t-1} 为记忆单元状态； δ 为sigmoid函数。具体的表达式如下^[16]：

$$\begin{cases} f_t = \delta(\mathbf{W}_{h,f}h_{t-1} + \mathbf{W}_{x,f}x_t + \mathbf{b}_f) \\ i_t = \delta(\mathbf{W}_{h,i}h_{t-1} + \mathbf{W}_{x,i}x_t + \mathbf{b}_i) \\ \tilde{C}_{t-1} = \tanh(\mathbf{W}_{h,c}h_{t-1} + \mathbf{W}_{x,c}x_t + \mathbf{b}_c) \\ o_t = \delta(\mathbf{W}_{h,o}h_{t-1} + \mathbf{W}_{x,o}x_t + \mathbf{b}_o) \\ C_t = f_t C_{t-1} + i_t \tilde{C}_{t-1} \\ h_t = o_t \tanh(C_t) \end{cases} \quad (21)$$

式中： $\mathbf{W}_{h,f}$ 、 $\mathbf{W}_{h,i}$ 、 $\mathbf{W}_{h,c}$ 、 $\mathbf{W}_{h,o}$ 分别为 f_t 、 i_t 、 \tilde{C}_{t-1} 、 o_t 的递归权重矩阵； $\mathbf{W}_{x,f}$ 、 $\mathbf{W}_{x,i}$ 、 $\mathbf{W}_{x,c}$ 、 $\mathbf{W}_{x,o}$ 分别为 f_t 、 i_t 、 \tilde{C}_{t-1} 、 o_t 的输入权重矩阵； \mathbf{b}_f 、 \mathbf{b}_i 、 \mathbf{b}_c 、 \mathbf{b}_o 为 f_t 、 i_t 、 \tilde{C}_{t-1} 、 o_t 的偏置矩阵。

图1中遗忘门 f_t 通过sigmoid函数，确定需要保留和舍弃的信息；输入门 i_t 通过sigmoid函数决定需要更新的信息；新的候选值 \tilde{C}_{t-1} 通过tanh函数产生；输出门 o_t 首先通过sigmoid函数得到初始的输出，再将初始输出与经过tanh函数层的*t*时刻的记忆单元状态 C_t 相乘得到最终的输出 h_t ^[17]。

2.3 光伏出力预测误差的拟合和评价

根据文献[10]可知，使用t-Location Scale函数对光伏发电的预测误差进行拟合，可以得到不同天气类型下的光伏出力的预测误差概率分布，因此，使用t-Location Scale函数对光伏发电的预测误差概率分布进行拟合：

$$f(\delta) = \frac{\Gamma((\nu_t+1)/2)}{\sigma_t \sqrt{\nu_t \pi} \Gamma(\nu_t/2)} \left[\frac{\nu_t + ((\delta - \mu_t)/\sigma_t)^2}{\nu_t} \right]^{-((\nu_t+1)/2)} \quad (22)$$

式中： μ_t 为期望； σ_t 为方差； $\nu_t > 0$ 为自由度。

采用平均绝对误差(MAE)和均方根误差(RMES)作为光伏发电预测精度的评价指标分析，MAE反映预测误差的实际情况，RMES来衡量观测值同真值之间的偏差：

$$MAE = \frac{1}{m} \sum_{i=1}^m |x_{o,i} - x_{r,i}| \quad (23)$$

$$RMES = \sqrt{\frac{1}{m} \sum_{i=1}^m (x_{o,i} - x_{r,i})^2} \quad (24)$$

式中： $x_{o,i}$ 为观测值， $x_{r,i}$ 为真值， m 为观测的次数。

2.4 光伏出力的场景生成

为了进一步表示光伏发电的不确定性，对于光伏发电的出力场景进行模拟是十分有必要的，常用的方法有场景数生成法、蒙特卡罗抽样法和拉丁超立方抽样法等，其中拉丁超立方抽样法具有分层抽样、打乱排序的抽样特点^[18]，使场景的生成避免了聚集、重复抽样的缺点，因此本文采用拉丁超立方采样生成1 000个光伏出力的场景。为了缓解计算的压力，使用k-means聚类法，生成10个典型的光伏出力场景进行经济调度仿真实验。

3 模型求解

3.1 多目标优化模型

多目标优化问题由多个目标函数组成^[3]：

$$\text{minimize } f_i(\mathbf{x}), i = 1, 2, \dots, N_{\text{obj}} \quad (25)$$

$$\text{subject to} \begin{cases} g_k(\mathbf{x}) = 0, k = 1, 2, \dots, K \\ h_l(\mathbf{x}) \leq 0, l = 1, 2, \dots, L \end{cases} \quad (26)$$

式中：目标函数 N_{obj} 总数为2，如式(1)和式(7)所示； \mathbf{x} 为由经济调度的最优解组成的输出向量。

3.2 多目标优化模型求解

计及季节天气因素的日前火电-光伏经济调度数学模型是一个多目标优化问题，为了方便求解，通过权重系数将多目标函数转化为单目标函数，并通过CPLEX进行求解。

$$\min f = \theta f_1 + (1 - \theta) f_2 \quad (27)$$

式中： θ 为权重系数，取值范围为0~1； f_1 为第1个目标函数，相当于本文的经济成本目标函数； f_2 为第2个目标函数，相当于本文的二氧化硫排放量目标函数； f 为转化后的目标函数。

3.3 模型求解步骤

考虑光伏发电不确定性的日前火电-光伏经济调度模型，将光伏发电的预测误差成本考虑进系统总成本中，用来表示光伏发电不确定性对经济调度的影响，因此求解该模型的具体步骤如下：

step 1：使用k-means方法对光伏出力历史数据进行聚类分析，分为晴天、阴天和雨天的3种典型的类型，并计算在不同季节下这3种典型天气类型的概率；

step 2：使用考虑季节天气因素的LSTM神经网络对预测日光伏发电06:00—18:00的功率进行预测；

step 3：使用Matlab R2019b的Distribution Fitting工具箱中t-Location Scale函数对光伏发电的预测误差概率函数进行拟合；

step 4：使用拉丁超立方法产生1 000个光伏发电的场景，为了减轻计算的压力，使用k-means聚类法进行场景的削减，产生10个具有代表性的场景；

step 5：在这10个典型的光伏出力场景下，使用Cplex软件对日前火电-光伏电力系统的经济调度模型进行求解。

4 案例分析

以3台火电机组、3台备用机组和1个光伏电站为例，设计不同的案例，对于考虑光伏发电不确定性的日前火电-光伏经济调度数学模型进行仿真验证，其中火电机组和旋转备用机组的数据来自文献[19]，光伏电站的系数和旋转备用的系数来自文献[11]，光伏电站的数据来自上海的某光伏电站，系统负荷数据如表1所示。

表1 系统负荷
Table 1 System load

时间/h	负荷/MW	时间/h	负荷/MW	时间/h	负荷/MW
1	400	9	520	17	490
2	420	10	555	18	520
3	430	11	570	19	530
4	440	12	585	20	540
5	450	13	520	21	560
6	480	14	500	22	540
7	490	15	490	23	500
8	500	16	580	24	405

所设计的案例如下所示:

案例1: 光伏发电具有优先权, 不考虑季节天气因素对于光伏发电进行预测;

案例2: 光伏发电具有优先权, 考虑季节天气因素对于光伏发电进行预测;

案例3: 光伏发电不具有优先权, 考虑季节天气因素对于光伏发电进行预测;

案例4: 光伏发电具有优先权, 不考虑光伏发电的高估预测误差和低估预测误差成本。

4.1 光伏发电的季节天气因素分析

以上海某光伏电站2019年的光伏出力数据为例使用k-means算法进行聚类分析, 得到晴天、阴天、雨天3种典型天气类型的出力曲线, 如图2所示。

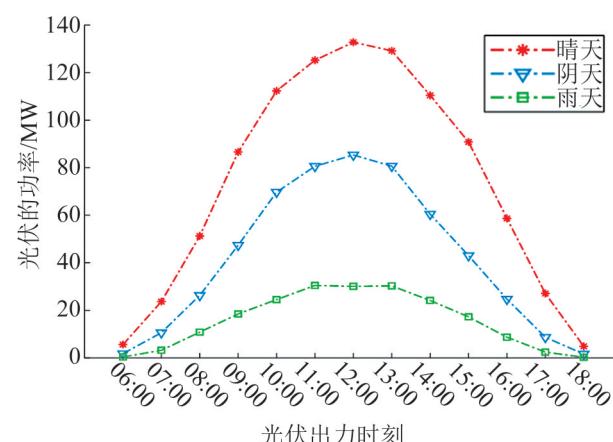


图2 3种典型天气类型出力曲线
Fig. 2 Power curve of 3 typical weather types

上海冬季是从12月到3月中上旬, 春季是从3月中下旬到5月, 夏季是从6月到9月, 秋季是从10月到11月。不同的季节有不同的天气条件, 因此, 对不同的季节天气类型进行聚类, 得到的季节概率数据如表2所示。

表2 3种天气在不同季节的概率
Table 2 Probability of 3 weather in different season

季节	晴天	阴天	雨天
冬季	0.076	0.381	0.543
春季	0.506	0.325	0.169
夏季	0.541	0.320	0.139
秋季	0.065	0.607	0.328

从图2可以发现, 晴天出力曲线在3条曲线中的出力值是最大的, 且在相邻时刻的出力增长速度也是最快的, 而雨天出力曲线的出力值和出力增长速度是最慢的, 作为发电商来讲, 晴天光伏出力是最好的负荷电源之一。

由表2给出的3种典型的天气类型在不同季节出现的概率可得, 冬季雨天的概率0.543是四季雨天概率中最高的; 夏季晴天的概率0.541是四季晴天概率中最高的, 即夏季有多一半天气是晴天; 秋季阴天的概率0.607是四季阴天概率中最高的, 也就是在秋季有超过一半的天气是阴天。

通过聚类获得了季节概率之后, 在预测光伏出力时, 可以将季节概率作为一个判断因子加入光伏发电预测数据中, 即可以通过概率数确定预测数据属于哪个季节哪个天气下, 其有助于提高光伏出力的预测精度。

4.2 案例仿真

4.2.1 基于LSTM神经网络的光伏发电预测

使用LSTM神经网络对光伏发电出力进行预测, 预测的数据来自于上海某光伏电站2019年夏季6—9月3个月的数据, 由于光伏电站夜晚不出力, 因此只对06:00—18:00光伏出力进行预测。训练LSTM神经网络时, 将求解器设置为adam, 并进行400轮数据, 为了防止梯度爆炸, 将梯度阈值设置为1。指定初始学习率0.005, 在200轮训练后通过乘以因子0.2来降低学习率。设置以下2个情形对光伏出力进行预测:

情形1: 使用考虑季节天气因素的LSTM神经网络对夏季晴天的光伏出力进行预测, 预测的数据为6—9月经过k-means聚类得到的所有晴天光伏出力数据、预测日前3天的光伏出力数据、夏季晴天季节概率和预测日前2天季节概率;

情形2: 使用不考虑季节天气因素的LSTM神经网络对夏季晴天的光伏出力进行预测, 预测数据不考虑聚类和季节概率, 采用预测日前的数据进行预测。

以上2种情形得到的光伏预测曲线如图3所示。为了体现使用LSTM神经网络预测光伏出力的优越性，使用BP神经网络进行光伏出力预测对比。BP神经网络的输入层设置为15，隐含层设置为13，输出层设置为1，设置同LSTM神经网络预测光伏出力一样的情形，考虑季节天气因素进行光伏出力的预测和不考虑季节天气因素进行光伏出力的预测，并对预测结果的RMES和MAE 2个指标进行对比，对比结果如表3所示。

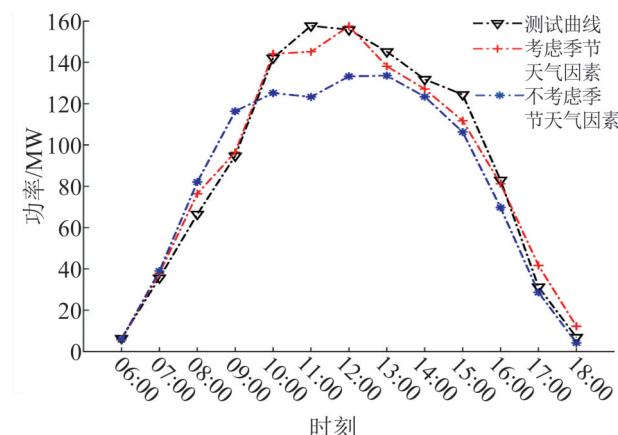


图3 LSTM神经网络预测光伏出力曲线

Fig. 3 Prediction of photovoltaic output curve by LSTM neural network

表3 LSTM神经网络和BP神经网络性能对比
Table 3 Comparison of prediction performance between LSTM neural network and BP neural network

指标	考虑季节天气因素		不考虑季节天气因素	
	LSTM	BP	LSTM	BP
RMES	17.250 3	21.508 4	20.286 3	28.697 5
MAE	0.101 9	0.192 1	0.183 6	0.274 4

由图3可以明显发现考虑季节天气因素情形下得到的光伏出力曲线更接近测试的曲线，而另一情形下光伏出力曲线明显偏离预测值。

同时从表3发现考虑季节天气因素的LSTM神经网络的RMES和MAE分别为17.250 3、0.101 9，是4种情况中最优的性能，其性能指标不仅优于不考虑季节天气因素的LSTM神经网络，而且优于考虑季节天气因素的BP神经网络；而不考虑季节天气因素的BP神经网络其RMES为28.697 5，

MAE为0.274 4，是4种情况中最差的性能值。综合对比下来，采用RMES和MAE性能指标最优的即考虑季节天气因素的LSTM神经网络对于光伏出力进行预测。

4.2.2 季节天气因素对经济调度的影响

案例1不考虑季节天气因素对于光伏发电进行预测生成的1 000个光伏出力场景如图4所示，10个典型光伏出力场景如图5所示；案例2考虑季节天气因素对于光伏发电进行预测得到的1 000个光伏出力场景如图6所示；10个典型光伏出力场景如图7所示。图5和图7中S1~S10分别表示10个典型的光伏出力场景。

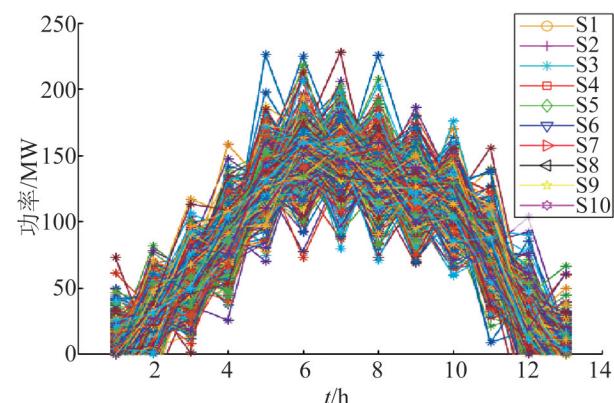


图4 不考虑季节天气因素生成的1 000个光伏出力场景

Fig. 4 1 000 photovoltaic power generation scenarios without considering seasonal weather factors

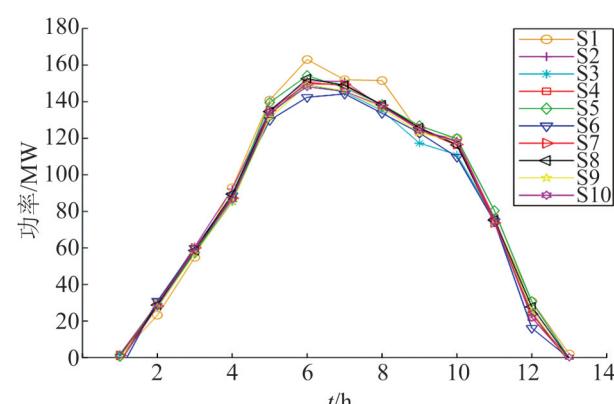


图5 不考虑季节天气因素生成的10个光伏出力场景

Fig. 5 10 photovoltaic power generation scenarios without considering seasonal weather factors

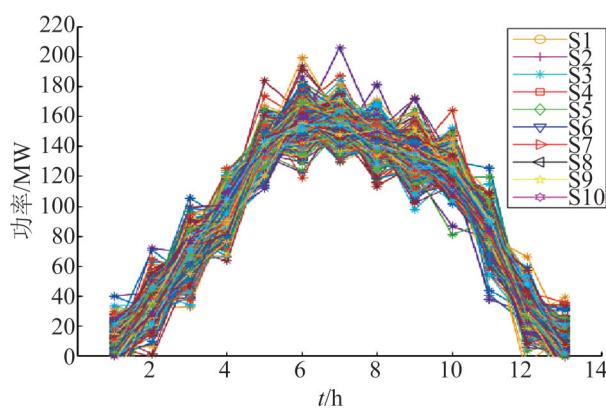


图6 考虑季节天气因素生成的1 000个光伏出力场景
Fig. 6 1 000 photovoltaic power generation scenarios considering seasonal weather factors

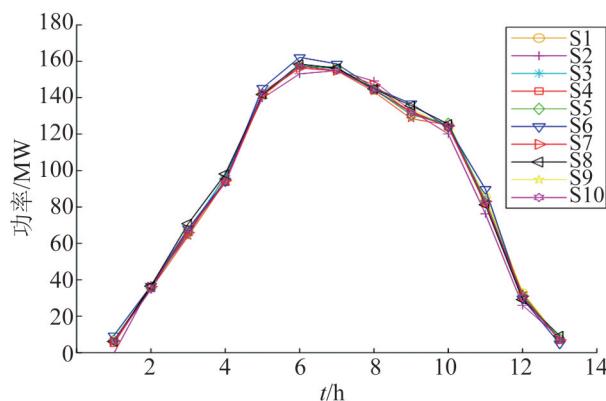


图7 不考虑季节天气因素生成的10个光伏出力场景
Fig. 7 10 photovoltaic power generation scenarios without considering seasonal weather factors

在本文的经济调度中将经济成本和环保成本视为同等重要的目标，因此使用Cplex进行求解多目标函数时，将权重 θ 设为0.5，下文同上，不重复介绍，由此得案例1和案例2的经济调度结果如表4所示。

通过对图4和图6发现，图4的1 000个光伏发电场景的波动范围较大，对比图5和图7发现，图5的10个典型光伏发电出力曲线波动性更大，这是因为在不考虑季节天气因素进行光伏发电预测时得到的预测误差大于考虑季节天气因素的预测误差，因此在使用拉丁超立方采样时产生光伏出力场景波动范围更大。为了提高经济调度的准确性，采用预测误差较小情形下产生的场景进行进一步的调度研究，即图6和图7。

表4 案例1和案例2调度结果
Table 4 Scheduling results of case1 and case2

场景	案例1调度结果	案例2调度结果
1	175 741	175 207
2	184 283	183 719
3	190 547	185 751
4	175 922	182 076
5	189 118	187 374
6	184 227	182 180
7	186 717	181 451
8	173 242	169 967
9	185 728	187 051
10	183 679	170 365

由表4可得，案例1最优调度结果为场景8的173 242，最差调度结果为场景3的190 547；案例2的最佳调度结果为场景8的169 967，最差调度结果为场景5的187 374。通过对比发现，案例2的最优调度结果和最差调度结果均是优于案例1的，因此考虑季节天气因素对光伏出力进行预测，有利于得到更优的经济调度结果，提高经济调度的经济性。

4.2.3 光伏发电优先权对经济调度的影响

为了体现光伏发电优先权对于经济调度的影响，将从只考虑经济成本即只考虑式(1)目标函数，和同时考虑经济成本和二氧化硫排放即考虑式(1)和式(7)2个目标函数，这2个角度对案例2和案例3的结果进行分析。

对于只考虑经济成本得到的案例2和案例3的经济成本费用如表5所示，同时考虑经济成本和二氧化硫排放得到的调度结果如图8所示。

从表5的经济成本费用上可以看出，案例3的经济成本费用均大于案例2，同时通过计算案例2和案例3中10个场景的平均经济成本费用分别为\$ 318 820, \$ 334 380，发现案例2的平均经济成本费用比案例3低\$ 15 560，即从经济成本费用的角度来看，光伏发电具有优先权的经济成本是优于光伏发电不具有优先权的经济成本。

表5 案例2和案例3经济成本费用
Table 5 Economic cost of case2 and case3 \$

场景	案例2	案例3
1	315 421	335 603
2	321 266	337 204
3	323 424	335 442
4	318 108	335 948
5	323 862	335 526
6	320 397	324 865
7	318 940	334 052
8	310 452	335 446
9	325 452	334 981
10	310 896	334 747

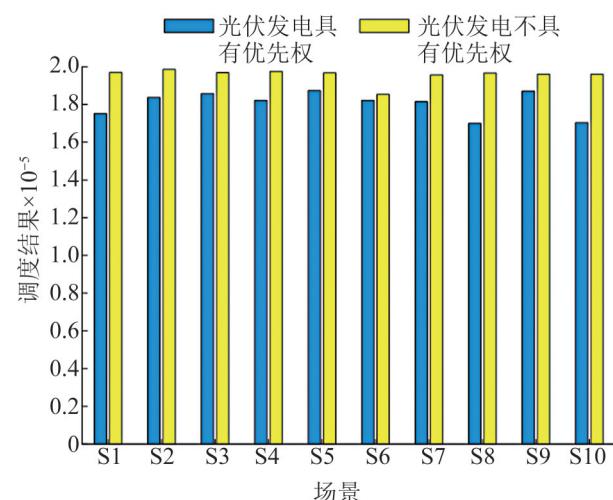


图8 案例2和案例3调度结果

Fig. 8 Scheduling results of case2 and case3

从图8的柱状图可得，在同时考虑经济调度费用和二氧化硫排放的目标下，黄色柱状图均高于蓝色柱状图，即光伏发电具有优先权的调度结果优于光伏发电不具有优先权的调度结果。

综上可得，光伏发电具有优先权比光伏发电不具有优先权发电更能减少经济成本费用，提高系统的经济性能和环保性能，这是因为当光伏发电具有优先权时，会优先使用光伏，火电机组和旋转备用出力将会减少，而火电和旋转备用的发电成本占比大于光伏发电成本占比，因此整体的经济调度费用也会随之减少。

4.2.4 光伏发电预测误差成本对经济调度的影响

将对案例2和案例4的经济调度结果进行对比分析，来反映光伏发电预测误差成本对经济调度结果的影响。图9展示案例2和案例4调度的经济成本费用，表6展示了案例2和案例4同时考虑经济成本和二氧化硫排放的调度结果。

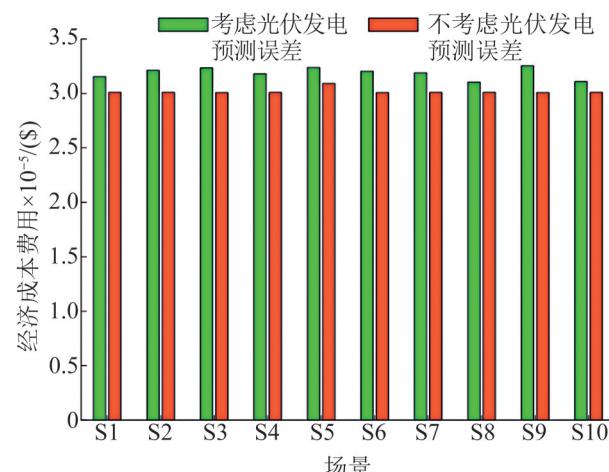


图9 案例2和案例4经济成本费用

Fig. 9 Economic cost of case2 and case4

表6 案例2和案例4的调度结果

Table 6 Scheduling results of case2 and case4

场景	案例2	案例4
1	175 207	161 384
2	183 719	161 407
3	185 751	161 141
4	182 076	161 310
5	187 374	161 301
6	182 180	161 236
7	181 451	161 295
8	169 967	161 357
9	187 051	161 269
10	170 365	161 336

通过表6可以发现案例2的最优结果为场景10的170 365，案例4的最优结果为场景3的161 141，案例2最优结果较案例4最优结果高9 224，并且通过比较发现，案例4的调度结果整体小于案例2的调度结果，即从同时考虑经济成本和二氧化硫排放角度来看，考虑光伏发电预测误差的调度结果是高于不考虑预测误差的结果的。

考虑到光伏发电预测误差成本对经济成本费用产生影响, 因此分析案例2和案例4的经济成本费用。从图9可以发现, 考虑光伏发电预测误差经济成本的绿色柱状图均高于不考虑光伏发电预测误差的橘色柱状体, 即光伏发电预测误差成本在经济成本费用中发挥的作用不可忽视。

综上可得, 无论是在只考虑经济成本目标还是同时考虑经济和环保2个目标进行优化调度时, 考虑光伏发电预测误差成本都是十分必要的, 虽然经济成本费用上较高, 但是考虑到光伏发电的不确定性, 光伏发电预测误差成本的加入, 提高了系统的安全性。

5 结论

本文主要研究了考虑光伏发电不确定性的日前光伏-火电的经济调度, 建立了以火电机组成本、光伏电站成本、光伏出力预测误差成本, 以及旋转备用成本为经济成本目标函数, 以二氧化硫排放量为环保目标函数的双目标经济调度模型。为了方便求解, 使用权重系数法将多目标函数转化为单目标函数进行求解。同时设置考虑季节天气因素和不考虑季节天气因素2种情形, 对BP神经网络和LSTM神经网络预测光伏发电出力的性能进行对比分析, 发现考虑季节天气因素的LSTM神经网络具有最好的性能指标, 因此采用考虑季节天气因素的LSTM神经网络预测光伏出力。分析了考虑季节天气因素、考虑光伏发电优先权和考虑光伏发电预测误差成本对于经济调度的影响, 证明了所提数学模型有效性和可行性。

参考文献:

- [1] 国家能源局. 国家能源局2021年一季度网上新闻发布会文字实录 [EB/OL]. (2021-01-30) [2021-04-12]. http://www.nea.gov.cn/2021-01/30/c_139708580.htm.
National Energy Administration. Transcript of Online News Conference of the National Energy Administration in the First Quarter of 2021[EB/OL]. (2021-01-30) [2021-04-12]. http://www.nea.gov.cn/2021-01/30/c_139708580.htm.
- [2] 舒印彪, 张智刚, 郭剑波, 等. 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, 2017, 37(1): 1-9.
Shu Yinbiao, Zhang Zhigang, Guo Jianbo, et al. Study on Key Factors and Solution of Renewable Energy Accommodation[J]. Proceedings of the CSEE, 2017, 37(1): 1-9.
- [3] Basu M. Economic Environmental Dispatch of Solar-Wind-Hydro-Thermal Power System[J]. Renewable Energy Focus(S1755-0086), 2019, 30: 107-122.
- [4] Yin Y, Liu T, He C. Day-Ahead Stochastic Coordinated Scheduling for Thermal-Hydro-Wind-Photovoltaic Systems [J]. Energy(S0360-5422), 2019, 187: 115944.
- [5] Yu H, Chung C, Wong K P, et al. Probabilistic Load Flow Evaluation with Hybrid Latin Hypercube Sampling and Cholesky Decomposition[J]. IEEE Transactions on Power Systems(S0885-8950), 2009, 24(2): 661-667.
- [6] Wang W, Li C, Liao X, et al. Study on Unit Commitment Problem Considering Pumped Storage and Renewable Energy Via a Novel Binary Artificial Sheep Algorithm [J]. Applied Energy(S0306-2619), 2017, 187: 612-626.
- [7] 冯新扬, 邵超. 跨卷积网络特征融合的SAR图像目标识别[J]. 系统仿真学报, 2021, 33(3): 554-561.
Feng Xinyang, Shao Chao. SAR Image Target Recognition Based on Across Convolution Network Feature Fusion[J]. Journal of System Simulation, 2021, 33(3): 554-561.
- [8] Zhou H, Zhang Y, Yang L, et al. Short-Term Photovoltaic Power Forecasting Based on Long Short Term Memory Neural Network and Attention Mechanism [J]. IEEE Access(S2169-3536), 2019, 7: 78063-78074.
- [9] 赵唯嘉, 张宁, 康重庆, 等. 光伏发电出力的条件预测误差概率分布估计方法[J]. 电力系统自动化, 2015, 39(16): 8-15.
Zhao Weijia, Zhang Ning, Kang Chongqing, et al. A Method of Probabilistic Distribution Estimation of Condition Forecast Error for Photovoltaic Power Generation[J]. Automatic of Electric Power Systems, 2015, 39(16): 8-15.
- [10] 陈瑶琪. 基于典型天气类型计及随机预测误差的光伏发电短期预测研究[J]. 中国电力, 2016, 49(5): 157-162.
Chen Yaoqi. Short-Term Photovoltaic Power Prediction Based on Typical Climate Types and Stochastic Prediction Error[J]. Electric Power, 2016, 49(5): 157-162.
- [11] Thabo G Hlalele, Raj M Naidoo, Ramesh C Bansal, et al. Multi-Objective Stochastic Economic Dispatch with Maximal Renewable Penetration under Renewable Obligation[J]. Applied Energy(S0306-2619), 2020, 270: 115120.

- [12] Kothari D P, Dhillon J S. Power System Optimization [M]. New Delhi: Prentice Hall in India, 2004.
- [13] 中国气象局. 公共气象服务一天气图形符号: GB/T 22164-2017 [S]. 北京: 中国标准出版社, 2017.
China Meteorological Administration. Public Meteorological Service-Weather Graphic Symbols: GB/T 22164-2017 [S]. Beijing: Standards Press of China, 2017.
- [14] 邱瑞东, 何山, 董宁, 等. 基于LSTM-LGB模型的光伏电站辐照强度预测[J]. 安徽大学学报(自然科学版), 2021, 45(3): 66-71.
Qiu Ruidong, He Shan, Dong Ning, et al. Irradiation Intensity Prediction of Photovoltaic Power Station Based on LSTM-LGB Model[J]. Journal of Anhui University (Natural Science Edition), 2021, 45(3): 66-71.
- [15] 宋绍剑, 李博涵. 基于LSTM网络的光伏发电功率短期预测方法的研究[J]. 可再生能源, 2021, 39(5): 594-602.
Song Shaojian, Li Bohan. Short-Term Forecasting Method of Photovoltaic Power Based on LSTM[J]. Renewable Energy Resources, 2021, 39(5): 594-602.
- [16] 李文静, 王潇潇. 基于简化型LSTM神经网络的时间序列预测方法 [J]. 北京工业大学学报, 2021, 47(5): 480-488.
Li Wenjing, Wang Xiaoxiao. Time Series Prediction Method Based on Simplified LSTM Neural Network[J]. Journal of Beijing University of Technology, 2021, 47 (5): 480-488.
- [17] 李秉晨, 于惠钧, 刘靖宇. 基于Kmeans和CEEMD-PE-LSTM的短期光伏发电功率预测[J]. 水电能源科学, 2021, 39(4): 204-208.
Li Bingchen, Yu Huijun, Liu Jingyu. Prediction of Short-Term Photovoltaic Power Generation Based on Kmeans and CEEMD-PE-LSTM[J]. Water Resources and Power, 2021, 39(4): 204-208.
- [18] Zhen S, Panida J. Latin Hypercube Sampling Techniques for Power Systems Reliability Analysis with Renewable Energy Sources[J]. IEEE Transactions on Power Systems (S0885-8950), 2011, 26(4): 2066-2073.
- [19] 王文潇. 水-火-新能源电力系统优化调度研究[D]. 武汉: 华中科技大学, 2018.
Wang Wenxiao. Resource on Optimal Scheduling of Hydro-Thermal-Renewable Power System[D]. Wuhan: Huazhong University of Science and Technology, 2018.