基于自编码-Copula 场景生成技术的水风光短期优化调度方法

李树山[1]，吴慧军[1]，程贤良[1]，郑壹飞[2]，赵志鹏[2]，程春田[3]

（1.中国南方电网电力调度控制中心，广东 广州 510663；2 大连理工大学 电气工程学院 辽宁 大连 110624；3.大连理工大学 水电与水信息研究所，辽宁 大连 116024）

摘　要：【目的】为精准刻画风光出力不确定性与时序相关性特征，提升水风光互补系统调度决策的鲁棒性与适应性，构建了高效可靠的风光场景生成与短期优化调度方法，为水风光互补系统调度决策提供有效工具。【方法】首先，利用自编码器将高维风光历史出力数据降维至低维潜变量空间，在该空间内构建高斯 Copula 模型进行概率建模与抽样；然后，通过解码器将抽样结果升维还原，生成具有时序相关性与统计特征的风光场景集。在此基础上，以系统净负荷峰谷差最小为目标，构建水风光短期随机优化调度模型，并采用线性化技术求解。【结果】①所提自编码-Copula 方法生成场景的有效覆盖率较传统高斯 Copula、C 藤 Copula 方法提升 10.24% 以上，自相关系数分布更贴近历史序列，场景质量显著更优；②典型枯期运行条件下，该调度方法可使系统剩余负荷波动平均降低 11.33%，调峰效果突出；③生成场景分布更紧凑、无异常值,与实际风光出力契合度更高,能更好地适配高预测误差日的调度需求。【结论】所提自编码-Copula 场景生成方法能有效捕捉风光出力的时序相关性与不确定性，基于该方法的水风光短期优化调度模型可提升系统运行稳定性与新能源消纳能力。

关键词：自编码；场景生成；水电；多能互补

中图分类号：TU43　　**文献标识码**：A

随着全球能源结构向低碳化、清洁化方向加速转型，风电、光伏等可再生能源在电力系统中的占比持续攀升。然而，风电和光伏发电具有强随机性、波动性和间歇性，给电力系统的安全稳定运行与优化调度带来了前所未有的压力[1]。我国水电资源丰富，装机容量全球位列第一；且水电启停灵活、爬坡能力强等优势使其具备大规模灵活性支撑能力，因此水风光互补运行成为消纳新能源的关键途径[2]-[3]。在此背景下，如何准确刻画风光出力的不确定性特征，成为提高水风光一体化系统运行可靠性与经济性的关键科学问题。

水风光互补调度的相关研究依据是否考虑不确定性可分为确定性调度和不确定性调度两类。确定性调度建模简单，易于计算，但由于输入的单一场景缺乏代表意义，调度结果难以适应多变的新能源出力情况[4]。不确定性调度主要包括场景生成、区间优化、鲁棒优化以及信息差决策理论等，其中场景生成技术通过构建大量能够反映风光出力多种可能变化情况的确定性场景，将不确定性问题转化为可处理的多场景确定性问题，为电力系统的优化规划与运行决策提供了有力支持[5]。

目前，风光出力场景生成方法主要分为基于抽样、人工智能和时序模型三大类。基于抽样的方法通过概率分布抽样获取离散场景：蒙特卡罗（Monte Carlo，MC）方法存在计算量大、难以捕捉时间序列自相关特征的问题[6]；拉丁超立方抽样（Latin hypercube sampling，LHS）样本效率高且分布均匀，常用于静态场景，却忽略动态场景的时段相关性[7]；而 Copula 函数作为一种能够灵活描述变量间复杂相关结构的工具，不仅弥补了上述抽样方法在相关性刻画上的缺陷，还可有效捕捉多风场间的非线性、非对称相关性，为风光出力场景生成提供了更优的相关性建模思路[8]-[9]。基于人工智能的方法中，生成对抗网络（generative adversarial network，

收稿日期/Received：2025-08-05　　**修回日期**/Revised：2026-06-07

基金项目：国家自然科学基金项目（52239001）。

第一作者：李树山（1985—），男，博士，从事大规模水电系统经济运行方面的研究。E-mail: liss@csg.cn。

通信作者：赵志鹏(1992—)，男，副教授，博士，从事电力系统科学智能(AI4Science)方面的研究。E-mail: zzp@dlut.edu.cn。

GAN）凭借生成器与判别器的对抗训练，以数据驱动模式捕捉风光随机性，但存在场景不可控的弊端[10]；条件生成对抗网络（conditional generative adversarial network，CGAN）虽通过添加标签信息引导生成，却受限于单一条件与弱可解释性，难以实现场景的精细化调控[11]。基于时序模型的方法，如自回归滑动平均模型，基于历史数据进行时间序列预测，但模拟精度不足，无法保证各时间断面的预测误差分布一致性，且在处理多维数据时空相关性及“维数灾”问题时表现欠佳[12]。

尽管 Copula 函数在相关性建模上具有显著优势，但传统 Copula 方法在处理高维风光数据时，仍存在概率建模复杂度高、抽样效率低的问题，难以兼顾场景生成的精度与效率[13]。因此，本文提出了基于自编码-Copula 场景生成技术的水风光短期调度方法。首先，基于数据驱动的建模思路提出了一种创新的新能源出力随机场景生成方法，该方法先通过编码器将高维训练集数据映射至低维隐变量空间，在此空间内开展概率建模与抽样操作，随后借助解码器将数据还原至原始维度，从而生成场景集。其次，以净负荷峰谷差最小为目标，构建水风光短期随机优化调度模型，并通过线性化插值技术对模型进行求解。

1 自编码-Copula 场景生成技术

1.1 高斯 Copula 原理

1.1.1 Copula 函数基本概念

Copula 函数通过 Sklar 定理将联合分布与边缘分布分离，能精确刻画变量间的非线性依赖结构，尤其擅长捕捉尾部相关性等复杂模式[14]-[15]。其通用表达式为：

$$F(x_1,x_2,\cdots,x_n)=C(F_{x_1}(x_1),F_{X_2}(x_2),\cdots,F_{X_n}(x_n))\ 。 \tag{1}$$

式中：$F(x_1,x_2,\cdots,x_n)$ 为 n 个变量的联合分布函数；n 为变量个数；$F_{X_i}(x_i)(i=1,2,...n)$ 为单个变量的边缘分布；$C(\bullet)$ 为 Copula 连接函数。

1.1.2 高斯 Copula 函数

高斯 Copula 函数及其所用的一元标准正态分布的累积分布函数分别为：

$$C(u_1,u_2\cdots,u_n,\boldsymbol{\Sigma})=\boldsymbol{\Phi}_{\boldsymbol{\Sigma}}(\boldsymbol{\Phi}^{-1}(u_1),\cdots,\boldsymbol{\Phi}^{-1}(u_n))$$
$$\boldsymbol{\Phi}(z)=\frac{1}{\sqrt{2\pi}}\int_{-\infty}^{z}\mathrm{e}^{-\frac{t^2}{2}}dt \tag{2}$$

式中：C 为高斯 Copula 函数；n 为变量个数；u_i 为第 i 个变量的边缘累积分布函数值 $(i=1,...,n)$；Σ 为各变量经标准正态分位数变换后的 $n\times n$ 相关系数矩阵；Φ_Σ 为以 Σ 为相关系数矩阵的 n 维正态分布的联合累积分布函数，各分量均服从标准正态分布；Φ 为一元标准正态分布的累积分布函数，Φ^{-1} 为其反函数；z 为 Φ 的自变量；t 为积分变量。

1.2 自编码器原理

自编码器是一种基于神经网络的无监督学习模型，通过编码器-解码器架构实现高维数据的特征提取与重构。在风光出力场景生成中，通过非线性降维有效捕捉风光出力的关键特征，将高维时序数据映射至低维潜空间进行概率建模，显著提升计算效率；解码器能够保持原始数据的时空关联特性，生成的场景既保留实际出力的统计分布，又能覆盖极端运行工况；相比传统生成方法，其数据驱动特性避免了人工假设分布形式的局限性，尤其适用于风光出力这类具有复杂非线性特征的数据建模[16,18]。

1.2.1 编码器

假设输入为风光场景的高维数据 $x\in R^n$（n 为数据维度），编码器通过非线性变换 $f_\theta(x)$ 将其映射到低维的隐空间 $z\in R^m(m<n)$，其数学表达式为：

$$z=f_\theta(x)=\sigma(\boldsymbol{W}x+\boldsymbol{b}) \tag{3}$$

式中：$\boldsymbol{W}$ 为权重矩阵；θ 为编码器参数；$\boldsymbol{b}$ 为偏置向量；σ 为激活函数，如常用的 ReLU 函数 $\sigma(x)=\max(0,x)$。

通过编码器，实现了对高维风光场景数据的降维处理，提取出数据的关键特征。

1.2.2 解码器

解码器将隐空间中的低维表示 z 通过非线性变换 $g_\varphi(z)$ 重构为输出 $\hat{x}\in R^n$，表达式为：

$$\hat{x}=g_\varphi(z)=\sigma'(\boldsymbol{W}'z+\boldsymbol{b}') \tag{4}$$

式中：$\boldsymbol{W}'$ 和 $\boldsymbol{b}'$ 为解码器的权重矩阵和偏置向量；σ' 为激活函数，如 Sigmoid 函数 $\sigma'(x)=1/(1+e^{-x})$。

解码器的作用是在需要时将降维后的数据升维还原，恢复成接近原始的风光场景数据。

1.2.3 损失函数

自编码器的目标是最小化重构误差，通常采用均方误差(MSE)作为损失函数，定义为：

$$L(x,\hat{x})=\frac{1}{N}\sum_{i=1}^{N}|\hat{x}_i-x_i|^2 \tag{5}$$

式中 N 为训练样本的数量。

通过不断调整编码器和解码器的参数（即 θ 和 φ），使得损失函数的值最小化，从而让自编码器

能够准确地学习到风光场景数据的降维和升维映射关系。

1.3 基于自编码-Copula 技术的风光场景生成降维与升维方法

1.3.1 数据预处理

收集风光出力的历史数据，包括风电和光伏的发电量、对应时刻的气象数据（如风速、光照强度、温度等）。对这些数据进行归一化处理，消除量纲影响，将数据映射到[0,1]区间。对于数据序列 x_i，归一化公式为：$x_i^{\text{norm}} = (x_i - x_{\min}) / (x_{\max} - x_{\min})$。

1.3.2 自编码器降维处理

自编码器模型构建：设计自编码器的网络结构。编码器部分由多个全连接层组成，神经元数量逐层递减，从输入层的 n 个（对应原始风光场景数据维度）减少到隐层的 m 个（目标低维度）。例如，中间层可以设置多个过渡层，神经元数量按照一定比例逐渐减少。解码器为编码器的逆结构，神经元数量逐层递增，从隐层 m 个恢复到输出层 n 个。权重矩阵使用 Xavier 初始化方法进行初始化，设置偏置向量初始化数值，以促进模型训练过程中的梯度传播和收敛。

模型训练：将经过预处理的风光实际历史出力数据作为输入，送入自编码器进行训练。选择 Adam 优化算法来最小化损失函数，设置初始学习率数值，并根据训练情况动态调整。在训练迭代过程中，计算每个批次数据的重构误差，基于反向传播算法更新编码器和解码器的参数，不断迭代直至损失函数收敛或达到预设的训练次数。训练完成后，编码器即可将原始高维风光场景数据转换为低维隐空间表示，实现数据降维。

1.3.3 基于高斯 Copula 的场景生成

计算边缘分布函数值：对降维后的数据，根据之前确定的各变量边缘分布函数，计算各变量的边缘分布函数值。

生成场景数据：将计算得到的边缘分布函数值代入高斯 Copula 函数中，计算联合分布函数值，从而生成满足特定相关性结构的风光场景数据。这些数据包含了风光出力在不同条件下的可能组合情况，为后续的升维处理提供数据基础。

1.3.4 自编码器升维还原

从基于高斯 Copula 生成的低维场景数据表示中获取数据。将这些低维表示输入到已经训练好的解码器中，通过解码器的非线性变换，将低维数据升维还原为高维的风光场景数据。此时得到的升维后数据在一定程度上保留了原始数据的特征和相关性，能够满足后续应用的需求。

自编码-Copula 场景生成方法的框架图如图所示。

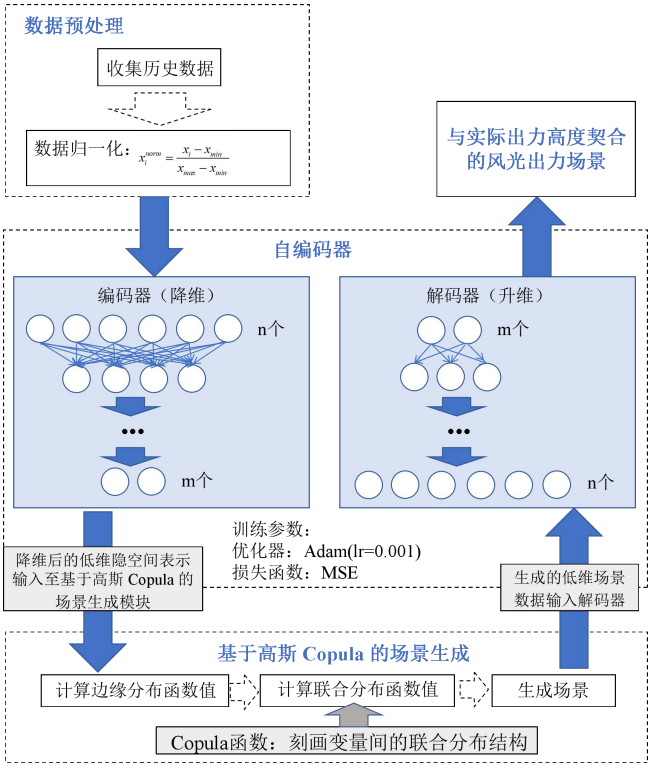


图 1 自编码-Copula 场景生成方法框架图

Fig.1 Framework diagram of the autoencoder-Copula scene generation method

2 基于自编码-Copula 场景生成技术的水电短期调度模型

2.1 目标函数

本模型以剩余负荷峰谷差最小为目标函数，促进电力系统的稳定运行。

$$\min F = \max_{1\le t\le T}(D'_{i,t}) - \min_{1\le t\le T}(D'_{i,t}) \tag{6}$$

$$D'_{i,t} = D_t - \sum_{h=1}^{H} ph_{h,t} - N_{i,t} \tag{7}$$

式中：$D'_{i,t}$ 为第 i 个场景第 t 时段的剩余负荷，MW；D_t 是第 t 时段的负荷，MW；$ph_{h,t}$ 为第 h 个水电站第 t 时段的水电站出力，MW；$N_{i,t}$ 为第 i 个场景第 t 时段的风光联合出力，MW；T 为模型的调度周期，h；H 为水电站的数量。

2.2 约束条件

1）水量平衡约束：

$$qc_{h,t} + \left(v_{h,t+1} - v_{h,t}\right)/T_t = qm_{h,t} \tag{8}$$

式中：$qc_{h,t}$ 为第 h 个水电站在 t 时段内的出库流量，m^3/s；$qm_{h,t}$ 为第 h 个水电站在 t 时段内的入库流量，

m^3/s；$v_{h,t+1}$为 h 水电站在 t 时段的末库容，m^3；$v_{h,t}$为第 h 个水电站在 t 时段初库容，m^3。在各个场景下库容都是唯一的，是所提模型的输出决策，目的是提升调度决策在各个场景下的适应性。

2）梯级间水力联系：

$$qm_{h+1,t} = qc_{h,t} + qj_{h_to_h+1,t} \tag{9}$$

式中：$qj_{h\ to\ h+1,t}$为第 h 个水电站和第 h+1 个水电站间 t 时段内的区间流量，m^3/s。

3）水库流量关系：

$$qc_{h,t} = qd_{h,t} + qz_{h,t} \tag{10}$$

式中：$qd_{h,t}$为第 h 个水电站在 t 时段内的发电流量，m^3/s；$qz_{h,t}$为第 h 个水电站在 t 时段内的弃水流量，m^3/s。

4）出库流量上限约束：

$$qc_{h,t} \le qc_{h,t}^{\max} \tag{11}$$

式中：$qc_{h,t}^{\max}$为第 h 个水电站在 t 时段内的允许的最大出库流量，m^3/s。

5）生态流量约束：

$$qc_{h,t} \ge qc_{h,t}^{\min} \tag{12}$$

式中：$qc_{h,t}^{\min}$为第 h 个水电站在 t 时段内的下泄生态流量要求，m^3/s。

6）发电流量约束：

$$qd_{h,t}^{\min} \le qd_{h,t} \le qd_{h,t}^{\max} \tag{13}$$

式中：$qd_{h,t}^{\max}$和$qd_{h,t}^{\min}$分别为第 h 个水电站在 t 时段内允许的最小发电流量和最大发电流量，m^3/s。

7）电站出力范围限制：

$$ph_h^{\min} \le ph_{h,t} \le ph_h^{\max} \tag{14}$$

式中：$ph_h^{\max}$和$ph_h^{\min}$分别为第 h 个水电站的装机容量和最小技术出力，MW。

8）水位-库容关系：

$$z_{h,t} = f_h^{zv}\left(v_{h,t}\right) \tag{15}$$

式中：$z_{h,t}$为第 h 个水电站在 t 时段的初始坝上水位，m；$f_h^{zv}(\cdot)$为第 h 个水电站的水位-库容函数关系，是一个非线性的函数。

9）电站出力特性：根据水电站历史实际运行数据，将非线性水电站出力函数拟合为两变量二次多项式的形式[19]。

$$\begin{aligned} ph_{h,t} = f_h^{nvq}(v_{h,t}^{avg}, qd_{h,t}) = \gamma_1 (v_{h,t}^{avg})^2 + \gamma_2 (qd_{h,t})^2 \\ + \gamma_3 v_{h,t}^{avg} qd_{h,t} + \gamma_4 v_{h,t}^{avg} + \gamma_5 qd_{h,t} + \gamma_6 \end{aligned} \tag{16}$$

式中：$v_{h,t}^{avg}$为$v_{h,t}$和$v_{h,t+1}$的平均值；$(\gamma_1,\gamma_2,\gamma_3,...,\gamma_6)$为水电站发电函数$f_h^{nvq}(v_{h,t}^{avg}, qd_{h,t})$的参数。

10)电站水位上下限约束

$$z_{h,t}^{\min} \le z_{h,t} \le z_{h,t}^{\max} \tag{17}$$

式中：$z_{h,t}^{\max}$和$z_{h,t}^{\min}$分别为第 h 个水电站在时段 t 的允许水位最大值和允许水位最小值，m。

11)电站始末水位约束

$$z_{h,1} = z_h^{start} \tag{18}$$

$$z_{h,t+1} = z_h^{end} \tag{19}$$

式中：z_h^{start}和z_h^{end}分别为第 h 个水电站的调度初期水位和调度末期水位，m。

2.3 求解方法

本文参考文献[20]中采用的 SOS2 线性化插值方法对一元非线性函数（公式（16））进行线性化；参考文献[21]中采用三角形二维插值方法对二元非线性函数（公式（17））进行线性化。此时，水风光短期随机优化调度模型已转化为混合整数线性规划模型，可以利用 Gurobi 求解器进行高效求解。

3 案例分析

3.1 研究对象概况

本文以我国某流域水风光多能互补基地为研究对象，验证本文方法的有效性。研究区域聚焦乌江流域，该流域地处我国西南地区，横跨贵州、重庆等地，是长江上游右岸的重要支流，水资源与风光资源禀赋优越。该基地中，梯级水电站群与区域风光资源通过乌江-浙江特高压直流输电工程等外送通道进行打捆外送。该基地的七座梯级水电站的基础信息见表 1。

表 1 梯级水电站基础信息

Tab.1 Basic information on cascade hydropower stations

电站名	死水位/m	正常高水位/m	装机容量/MW	调节性能
HJD	1076.0	1140	600	年调节
DF	936.0	970	695	季调节
SFY	822.0	837	600	日调节
WJD	720.0	760	1250	季调节
GPT	590.0	630	3000	年调节
SL	431.0	440	1050	日调节
ST	353.5	365	1120	日调节

本文聚焦于西南某省份的光伏与风电总出力情况，所采用的数据涵盖 2019—2024 年间每 15 min 的出力过程。借助该数据集里的每日实际风光联合出力数据，运用相关性分析手段，对新能源出力的内在关联及主导模式展开深入解析，从而为后续研究提供理论依据与数据支撑。

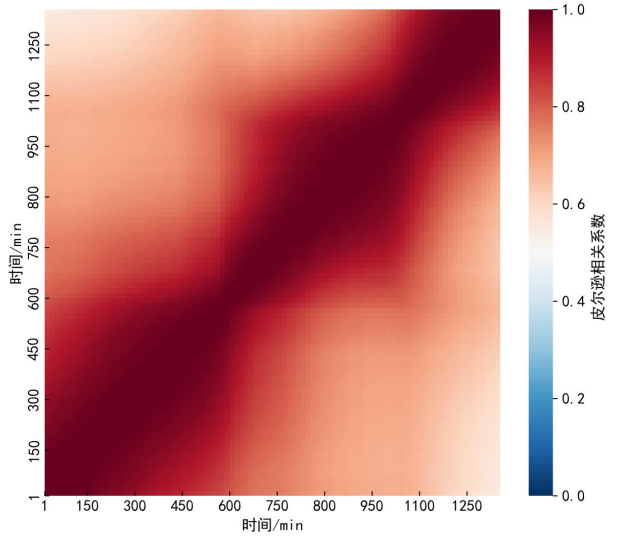


图 2 新能源出力过程的时域皮尔逊相关性热力图

Fig.2 Time-domain Pearson correlation heatmap of renewable energy output

图 2 展示了新能源出力在时域上的统计关联特性，基于一天中不同时段的新能源出力计算皮尔逊相关系数。观测到主对角线两侧呈现显著的强时间自相关性。

关于自编码器的参数设置：自编码器降维处理过程中，权重矩阵使用 Xavier 初始化方法进行初始化，偏置向量初始化为 0；模型训练过程中，选择 Adam 优化算法来最小化损失函数，初始学习率设置为 0.001。

3.2 方法对比

3.2.1 场景生成评价指标

为有效评估生成的风光出力场景集质量，本文构建融合时序关联性与随机特性的场景评估体系，从相关性、分布匹配度、覆盖完备性三个维度，选取自相关系数（autocorrelation coefficient, ACF）、平均欧氏距离（mean Euclidean distance, MED）、有效覆盖率三项指标开展量化分析 。

引入自相关系数作为时序相关性量化工具，用于衡量生成场景集对原始时间序列相关性的还原能力。该指标可刻画变量序列在不同滞时条件下的时间关联强度，其典型特征为：随着滞时的递增，相关系数值呈递减趋势。因此，可通过分析自相关系数的大小及演变规律，衡量风光场景集对时序特征的捕捉效能，公式如下：

$$\hat{\rho}_k=\frac{\sum_{t=1}^{n-k}(r_t-\bar{r})(r_{t+k}-\bar{r})}{\sum_{t=1}^{n}(r_t-\bar{r})^2} \tag{20}$$

式中：r_t 为第 t 月份的出力值；k 为时间间隔数；$\bar{r}$ 为序列均值；$\hat{\rho}_k$ 为时间延迟为 k 的自相关系数。

随机特性体现为在特定时间实际风电光伏出力场景与生成场景集之间的偏离程度。本研究采用基于平均欧式距离度量的评价方法，公式如下：

$$E=\frac{1}{W}\sum_{w=1}^{W}\left\|R_w-\tilde{R}\right\|_2 \tag{21}$$

式中：R_w 为第 w 个场景序列；$\tilde{R}$ 为历史实际序列；$\|\bullet\|_2$ 为两个序列差的 L2 范数；E 为场景集与历史实际序列的欧式距离平均值，其值越小，说明生成场景与历史实际序列的吻合度越高。

为确保生成场景覆盖实际出力的波动范围，提出有效覆盖率指标：覆盖范围越广，实际场景落入生成区间的概率越高，公式如下：

$$\begin{cases} C=\dfrac{\sum_{t=1}^{T}1\left(r_{\min,t}\le\tilde{r}_t\le r_{\max,t}\right)}{\sum_{t=1}^{T}\left(r_{\max,t}-r_{\min,t}\right)} \\ r_{\min,t}=\min\left(\omega_{w,t}\right),w=1,\cdots,W \\ r_{\max,t}=\max\left(\omega_{w,t}\right),w=1,\cdots,W \end{cases} \tag{22}$$

式中：$\omega_{w,t}$ 为第 w 个场景在月份 t 的取值；C 表示覆盖率；$1(\bullet)$是一个二进制变量，若括号内的条件满足则取值为 1，否则取值为 0；$\tilde{r}_t$ 为第 t 月份的历史出力率；$r_{\min,t}$ 和 $r_{\max,t}$ 分别为第 t 月份所有场景出力率的最小值和最大值。

3.2.2 场景生成效果对比

为验证所提方法的有效性，本文选取常规高斯 Copula 方法和 C 藤 Copula 方法进行对比。为分析生成场景集与历史数据在时序相关性特征上的契合度，针对三种方法构建的场景集，分别统计其自相关系数的分布特征。同时，将历史风光出力序列的自相关系数作为参照，通过箱型图可视化呈现差异：红色标记对应历史实测数据的自相关系数，箱型部分则展示生成场景集自相关系数的分布区间，结果见图 3。表 2 中所示为各方法场景集的有效覆盖率和欧氏距离指标的具体值，并计算了各方法相对于自编码-Copula 方法的差异百分比。

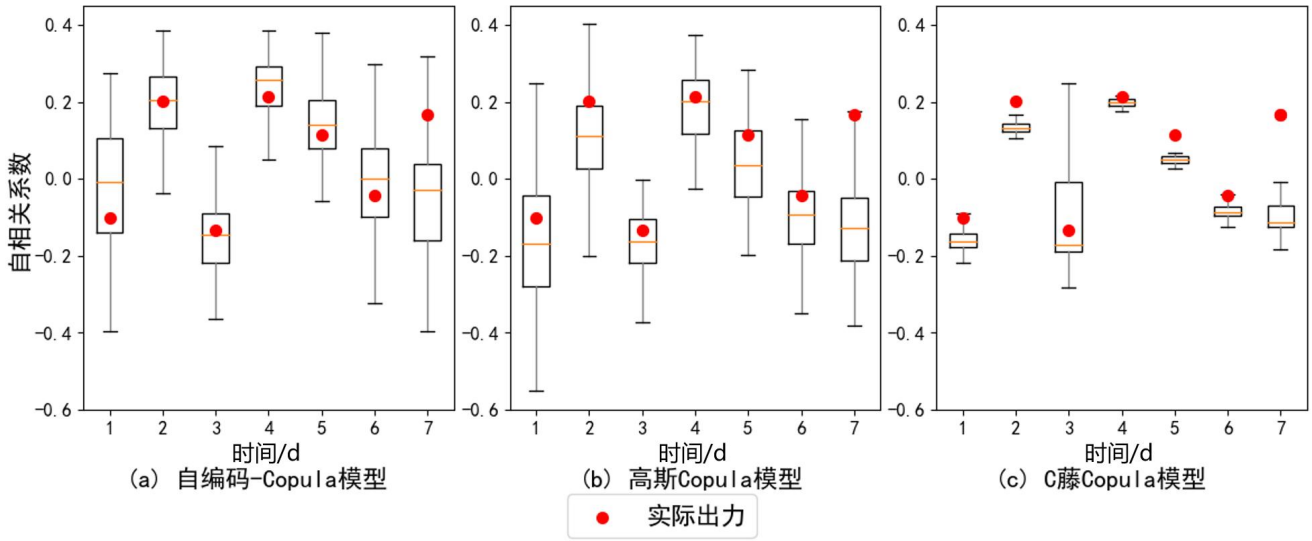


图 3 不同方法生成场景的自相关系数图

Fig.3 Autocorrelation plots for scenes generated using different methods

表 2 不同方法生成场景多指标评估和比较

Tab.2 Multi-criteria evaluation and comparison of scenarios generated by different methods

方法	有效覆盖率	与自编码-Copula 模型的相对偏差/%	欧式距离/MW	与自编码-Copula 模型的相对偏差/%
自编码-Copula 模型	2.05	—	9967	—
高斯 Copula 模型	1.79	12.68	9865	1.03
C 藤 Copula 模型	1.84	10.24	10158	1.91

由表 2 和图 3 可知，相较于其他方法，本文所提自编码-Copula 模型生成的风光出力场景集，其自相关系数分布可更好覆盖对应历史序列的自相关系数，且变化趋势与历史实测数据的自相关系数趋势更相符，说明本文方法可以有效捕捉其周期性变化规律和跨时段依赖关系。此外，自编码-Copula 场景生成方法表现出来的平均欧式距离略高于高斯 Copula 模型，且相较于 C 藤 Copula 模型方法更低，说明其生成的场景对实际风光场景的接近效果较优。其次，本文所提自编码-Copula 场景生成方法表现出来的有效覆盖率更高，说明该方法对风光电出力等序列时间相关性的模拟更精准，生成场景的时间演变规律更贴近实际。而高斯 Copula 方法和 C 藤 Copula 方法则表现出更高的平均欧氏距离和更低的有效覆盖率，说明其场景质量较差，与实际风光场景的差距较大。

新能源出力预测精度与电网稳定运行高度关联，若预测误差过大，电网为保障供电和负荷平衡，需要增加备用容量，这会直接提高运行成本。本研究聚焦预测误差显著的典型日开展分析，这类典型日是从新能源预测出力和实际出力欧式距离最大的前 10%天数里筛选出来的。之后，采用不同方法为这些典型日生成对应的风光联合出力场景，并将生成场景与实际出力、预测出力进行对比，具体结果如图 4 所示。由图 4 可知，本文提出的模型在风光联合出力场景生成上优势明显，其生成的场景集分布紧密，不存在异常值，和实际出力契合度高。相比之下，高斯 Copula 方法与 C 藤 Copula 方法生成的场景集分布较零散，场景的准确性和稳定性欠佳，反映出这两种方法在拟合复杂数据分布时存在不足。

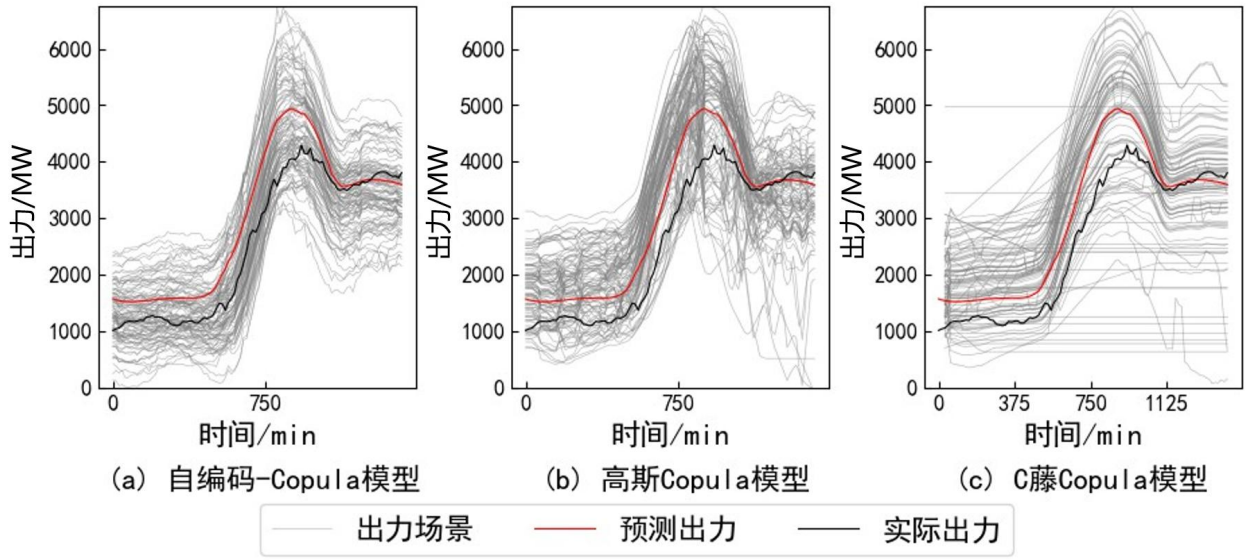


图 4 不同方法在高预测误差日生成的场景集对比

Fig.4 Comparison of scene sets generated by different methods on days with high prediction errors

3.2.3 水电调度效果对比

梯级水电站在枯期需承担电网调峰任务，因此本文以枯期的运行场景展开分析。图 5 呈现了枯期典型月内，3 种方法生成新能源出力场景集，经优化后得到的水电出力在实际新能源出力下的剩余负荷波动情况，纵坐标为剩余负荷波动值，数值越小代表调峰效果越佳。图 6 呈现了枯期典型日不同场景生成方法的模拟调度结果。表 3 则罗列了不同方法对应的剩余负荷波动平均值，以及与本文方法相比的相对差异，用于对比 3 种方法在新能源出力场景下剩余负荷波动表现。

综合图 5 与表 3 分析可知，本文方法在多数情景中，剩余负荷波动均显著低于其他 3 种方法，调峰效果最优，能有效削减剩余负荷波动，有利于增强电力系统调峰调度的稳定性。

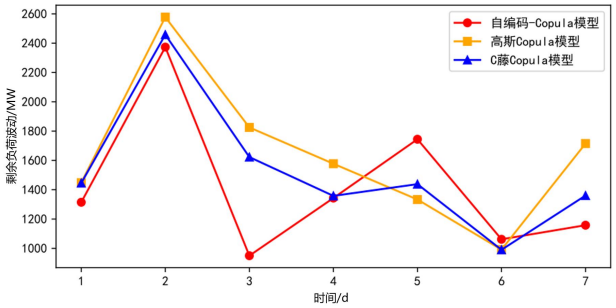


图 5 枯期典型月不同场景生成方法的模拟调度结果

Fig.5 Simulation results of scheduling methods for generating different scenarios during a typical dry season

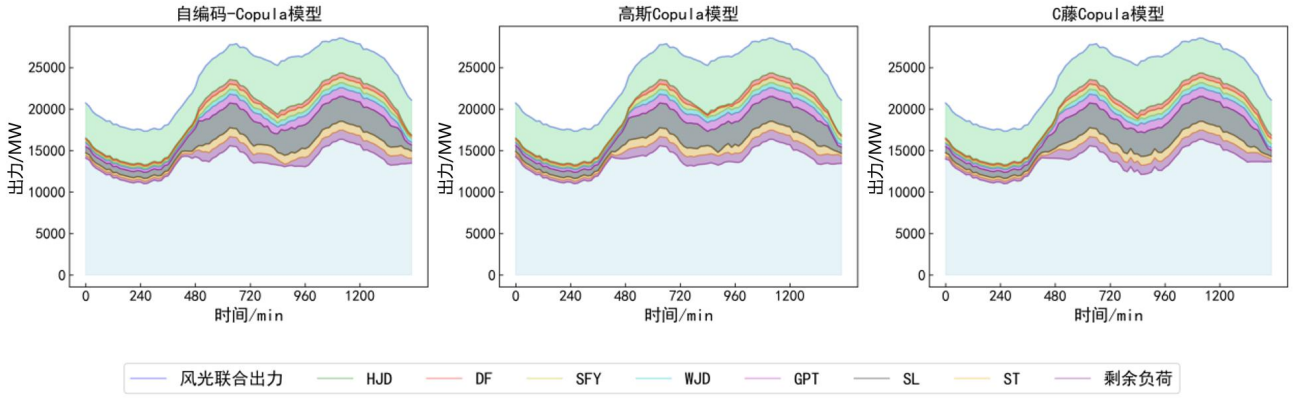


图 6 枯期典型日不同场景生成方法的模拟调度结果

Fig.6 Simulation results of scheduling methods for generating different scenarios on a typical day during the dry season

表 3 不同场景生成方法下的剩余负荷波动情况

Tab.3 Fluctuations in residual load under different generation methods

方法	剩余负荷波动平均值/MW	与自编码-Copula 模型的相对偏差/%
自编码-Copula 模型	1420	—
高斯 Copula 模型	1638	15.35
C 藤 Copula 模型	1524	7.32

4 结论

本文提出了一种基于自编码-Copula 场景生成技术的水风光短期优化调度方法，以我国某流域的水风光一体化运行基地为案例研究，得到如下结论：

1）所提方法通过自编码器降维与高斯 Copula 建模相结合，在低维空间高效捕捉风光出力的时序相关性，生成场景的有效覆盖率较传统方法提升 10.24%以上，自相关系数分布更贴合历史序列，表现出更好的统计一致性与时序还原能力。

2）基于生成场景集构建的随机优化调度模型，在典型枯期运行条件下，可有效降低系统剩余负荷波动，平均降幅达 11.33%，表明该方法能提升水电调峰能力与风光消纳水平。

3）所提框架不依赖于特定风光出力分布假设，适用于高维、非线性相关性建模，可为其他多能源系统的不确定性调度提供参考。

4）案例结果表明，该方法在现有水风光互补系统中具有较好的技术可行性与调度效果，可为实际运行提供决策支持。

参 考 文 献

[1] Pfenninger S. Dealing with multiple decades of hourly wind and PV time series in energy models: A comparison of methods to reduce time resolution and the planning implications of inter-annual variability[J]. Applied Energy, 2017, 197: 1-13.

[2] Lu Jin, Li, Xingpeng. Transmission Expansion Planning for Renewable-Energy-Dominated Power Grids Considering Climate Impact[J]. Journal of Modern Power Systems and Clean Energy, 2024, 12(6): 1737-1748.

[3] 程春田.碳中和下的水电角色重塑及其关键问题[J]. 电力系统自动化，2021, 45(16): 29-36.[Cheng Chuntian. Function remolding of hydropower systems for carbon neutral and its key problems[J]. Automation of Electric Power Systems, 2021, 45(16):29-36.]

[4] Li Fangfang, Qiu Jun. Multi-objective optimization for integrated hydro-photovoltaic power system[J]. Applied Energy, 2016, 167: 377-384.

[5] Hou Wenting，Wei Hua. Data-driven robust day-ahead unit commitment model for hydro/thermal/wind/photovoltaic/nuclear power systems[J]. International Journal of Electrical Power & Energy Systems，2021，125：106427.

[6] 于淼,吴屹潇,田硕硕,等.基于阶梯化概率计算法的风电场送出系统雷击预警[J].科学技术与工程，2025,25(16):6789-6796.[Yu Miao, Wu Yixiao, Tian Shuoshuo, et al. Lightning strike warning in wind farm delivery system based on stepped calculation method[J]. Science Technology and Engineering, 2025 , 25 (16) : 6789-6796.]

[7] 李建林,张梦圆,王茜,等.计及风光不确定性的现货-调频市场联合出清策略[J].电力工程技术,2025,44(3):53-63.[Li Jianlin, Zhang Mengyuan, Wang Qian, et al. Joint clearing strategy in electricity spot market and frequency regulation market considering the uncertainty of wind and solar[J]. Electric Power Engineering Technology, 2025, 44(3): 53-63.]

[8] 刘杰,曹静.基于 Vine-Copula-BiLSTM 的风电机组齿轮箱状态评估[J].太阳能学报,2025,46(4):494-503.[Liu Jie, Cao Jing. Wind turbine gearbox health status assessment based on Vine-Copula-BiLstm[J]. Acta Energiae Solaris Sinica. 2025, 46(4): 494-503.]

[9] 惠振国,艾澜,常鹏霞,等.计及风光出力相关性的风光水储互补系统优化调度[J].水电能源科学,2024,42(8):218-222.[Hui Zhenguo, Ai Lan, Chang Pengxia, et al. Optimal scheduling of wind-solar-water-storage complementary system considering the correlation of wind-solar output[J]. Water Resources and Power, 2024,42(8):218-222.]

[10] 吕朋蓬,卜强生,郭野,等.基于梯度惩罚生成对抗网络的配电网缺失数据修复方法[J].太阳能学报,2025,46(5):185-192.[Lyu Pengpeng, Bu Qiangsheng, Guo Ye, et al. Method for missing data imputation in distribution network based on gradient penalty generative adversarial network[J]. Acta Energiae Solaris Sinica, 2025, 46(5): 185-192.]

[11] 孙浩,万灿,曹照静,等.基于条件生成对抗网络曲线生成的短期负荷概率预测[J].电力系统自化,2023,47(23):189-199.[Sun Hao, Wan Can, Cao Zhaojing,

et al. Short-term load probabilistic forecasting based on conditional generative adversarial network curve generation[J]. Automation of Electric Power Systems, 2023, 47(23):189-199.]

[12] 惠杰,刘博嘉,赵树生,等.基于马尔科夫残差修正-自回归滑动平均模型的负荷预测[J].电气技术,2025,26(4):37-43.[Hui Jie, Liu Bojia, Shusheng Zhao, Hu Quandan, Zeng Xianfeng. Load forecasting based on Markov residual correction-autoregressive moving average model[J]. Electrical Engineering, 2025 , 26 (4) : 37 -43 .]

[13] 周月英,高艺桔,石莹怡,等.基于 Copula 函数的粤港澳大湾区干旱遭遇风险分析[J].华北水利水电大学学报(自然科学版),2022,43(4):20-28, 66.[Zhou Yueying, Gao Yiju, Shi Yingyi, et al. Drought encounter risk analysis in Guangdong-Hong Kong-Macao Greater Bay Area based on Copula function [J]. Journal of North China University of Water Resources and Electric Power (Natural Science Edition), 2022, 43(4): 20-28, 66.]

[14] 牟长兴,张俊涛,程春田,等.考虑时空相关性的流域水风光多能互补系统高维不确定性场景生成方法[J].电网技术,2024,48(9):3614-3623.[Mu Changxing, Zhang Juntao, Cheng Chuntian, et al. High-dimensional uncertainty scenario generation method for hydro-wind-solar multi-energy complementary system considering spatio-temporal correlation[J]. Power System Technology, 2024, 48(9): 3614-3623.]

[15] 唐逸.北盘江流域水风光多能互补短期优化调度模型研究[D].武汉:华中科技大学,2024.[Tang Yi. Research on Short-term Optimal scheduling model of hydro-wind-solar multi-energy complementation in Beipan River Basin [D]. Wuhan:Huazhong University of Science and Technology, 2024.]

[16] Wang Chenguang, E Sharifnia, Gao Zhi, et al. Generating multivariate load states using a conditional variational autoencoder[J]. Electric Power Systems Research, 2022, 213: 108603.

[17] 刘小峰,李俊锋,柏林.基于 SCADA 参量耦合网络变分图自编码的风电机组异常检测方法[J].太阳能学报,2025,46(5):567-576.[Liu Xiaofeng, Li Junfeng, Bo Lin. Wind turbine anomaly detection method based on SCADA parameter coupling network variational graph autoencoder [J]. Acta Energiae Solaris Sinica, 2025, 46(5): 567-576.]

[18] 袁警特,邱高,刘友波,等.基于变分自编码神经常微分方程的电-气耦合系统长动态稳定快速推演技术[J].中国电机工程学报,2025,45(10):3737-3752.[Yuan Jingte, Qiu Gao, Liu Youbo, et al. Fast long-term dynamic stability deduction technology for integrated electricity-gas system based on variational autoencoder-neural ODE [J]. Proceedings of the CSEE, 2025, 45(10): 3737-3752.]

[19] Zhou Jianzhong, Lu Peng, et al. Short-term hydro-thermal-wind complementary scheduling considering uncertainty of wind power using an enhanced multi-objective bee colony optimization algorithm[J]. Energy Conversion and Management, 2016, 123: 116-129.

[20] 于志辉,赵志鹏,王进,等.面向灵活调节与低碳经济运行的风光水火多源多目标短期调度[J].电网技术, 2025, 49(8): 3104-3115..[Yu Zhihui, Zhao Zhipeng, Wang Jin, et al. Short-term multi-objective scheduling of wind-solar-hydro-thermal multi-power for flexible adjustment and low-carbon economic operation[J]. Power System Technology, 2025, 49(8): 3104-3115.]

[21] 刘本希,王海东,张俊涛,等.大规模新能源并网下水电顶峰能力解析量化与优化调配方法[J].电网技术,2025,49(3):945-954.[Liu Benxi, Wang Haidong, Zhang Juntao, et al. A quantitative analysis and optimal allocation of hydropower peaking capacity in the context of large-scale new energy grid integration[J]. Power System Technology, 2025, 49(3): 945-954.]

Short-term Optimal Scheduling Method for Hydropower-Wind-PV Systems Based on Auto-Encoding-Copula Scenario Generation Technology

LI Shushan[1]，WU Huijun[1]，CHENG Xianliang[1]，ZHENG Yifei[2]，ZHAO Zhipeng[2]，CHENG Chuntian[3]

(1. Electric Power Dispatching Control Center, China Southern Power Grid Company Limited, Guangzhou 510663, China；2.School of Electrical Engineering, Dalian University of Technology, Dalian 116024, China; 3. Institute of Hydropower & Hydro informatics, Dalian University of Technology, Dalian 116024, China)

Abstract: 【**Objective**】To accurately characterize the uncertainty and temporal correlation of wind and photovoltaic power outputs and to enhance the robustness and adaptability of scheduling decisions for hydro-wind-solar complementary systems, an efficient and reliable method for wind-PV scenario generation and short-term optimal scheduling was developed, providing an effective tool for scheduling decision-making in hydro-wind-solar complementary systems. 【**Methods**】Firstly, an autoencoder is adopted to reduce high-dimensional historical wind and photovoltaic output data to a low-dimensional latent variable space, where a Gaussian Copula model is established for probabilistic modeling and sampling. Then, the sampled results are reconstructed to the original dimension via a decoder to generate a wind and photovoltaic scenario set with temporal correlation and statistical characteristics. On this basis, a short-term stochastic optimal scheduling model for hydro-wind-solar systems is constructed with the objective of minimizing the peak-valley difference of the system net load, and is solved using linearization techniques. 【**Results**】(1) The effective coverage rate of scenarios generated by the proposed autoencoder-Copula method is increased by more than 10.24% compared with the traditional Gaussian Copula and C-vine Copula methods, and the autocorrelation coefficient distribution is closer to the historical sequence, indicating significantly better scenario quality;(2) Under typical dry-season operating conditions, the proposed scheduling method reduces the average fluctuation of the system residual load by 11.33%, presenting remarkable peak-shaving performance;(3) The generated scenarios are more concentrated without outliers, highly consistent with the actual wind and photovoltaic outputs, and better adapt to the scheduling demand of days with high prediction errors. 【**Conclusions**】The proposed autoencoder-Copula scenario generation method can effectively capture the temporal correlation and uncertainty of wind and photovoltaic outputs. The short-term optimal scheduling model for hydro-wind-solar systems based on this method can enhance the system operation stability and renewable energy accommodation capacity, providing an effective tool for scheduling decisions of hydro-wind-solar complementary systems.
Keywords: Auto-encoding; scenario generation; hydropower; multi-energy complementarity