

可量化风电不确定性风险的暂态稳定约束最优潮流模型

刘颂凯^{1,2}, 秦浩^{1,2}, 胡畔^{1,2,3}, 苏攀^{1,2}, 李鑫⁴, 党喜^{1,2}, 刘亦瞳^{1,2}
(1. 三峡大学电气与新能源学院, 湖北宜昌 443002; 2. 新能源微电网湖北省协同创新中心, 湖北宜昌 443002; 3. 国网湖北省电力有限公司电力科学研究院, 湖北武汉 430077; 4. 国网湖北省电力有限公司, 湖北武汉 430000)

摘要: 为量化风电接入电力系统造成的风险, 在维持系统运行稳定性并兼顾良好经济性的前提下, 提出一种可量化风电不确定性风险的暂态稳定约束最优潮流(TSCOPF)模型。首先, 基于条件风险值(CVaR)量化不确定性造成的弃风弃负荷风险成本; 其次, 将风电风险成本纳入TSCOPF目标函数中, 建立可量化风电不确定性风险的TSCOPF模型; 然后, 针对传统多元“宇宙”优化(MVO)算法易陷入局部最优的缺点, 通过标准化膨胀率修正和引入精英“宇宙”机制对其进行改进, 并利用改进的MVO算法求解TSCOPF模型以获取全局最优解; 最后, 基于IEEE 39节点系统进行算例分析, 结果表明, 所提方法可有效应对不确定性风险, 提升系统暂态稳定性。

关键词: 风险量化; 暂态稳定约束最优潮流; 条件风险值; 多元“宇宙”优化算法

中图分类号: TM712 **文献标志码:** A **DOI:** 10.20204/j.sp.2025.09004

Transient Stability Constrained Optimal Power Flow Model Quantifying Wind Power Uncertainty Risk

LIU Songkai^{1,2}, QIN Hao^{1,2}, HU Pan^{1,2,3}, SU Pan^{1,2}, LI Xin⁴, DANG Xi^{1,2}, LIU Yitong^{1,2}
(1. College of Electrical Engineering and New Energy, China Three Gorges University, Yichang 443002, China;
2. Hubei Provincial Collaborative Innovation Center for New Energy Microgrid, Yichang 443002, China;
3. State Grid Hubei Electric Power Research Institute, Wuhan 430077, China;
4. State Grid Hubei Electric Power Co., Ltd., Wuhan 430000, China)

Abstract: To quantify the risks associated with integrating wind power into the power system while maintaining operational stability and ensuring sound economic efficiency, this paper proposes a transient stability constrained optimal power flow (TSCOPF) model capable of quantifying wind power uncertainty risk. Firstly, the conditional value-at-risk (CVaR) method is employed to quantify the risk costs of wind curtailment and load shedding caused by uncertainty. Secondly, these wind power risk costs are incorporated into the TSCOPF objective function, establishing a TSCOPF model that quantifies the wind power uncertainty risk. Then, to address the limitation of the traditional multi-verse optimizer (MVO) algorithm being prone to local optima, improvements are made through standardized inflation rate correction and the introduction of an elite universe mechanism. The improved MVO algorithm is subsequently utilized to solve the TSCOPF model, obtaining the global optimal solution. Finally, case studies based on the IEEE 39-bus system are conducted. The results demonstrate that the proposed method can effectively mitigate uncertainty risks and enhance system transient stability.

Key words: risk quantification; TSCOPF; CVaR; MVO algorithm

0 引言

在“双碳”目标提出后, 新能源大规模并入电力系统已成为必然趋势。然而, 新能源固有的不确定

性易导致电力系统出现失稳等运行风险, 且系统结构因新能源接入日趋复杂, 分析难度显著增加^[1-3]。因此, 亟需研究如何兼顾新能源接入下电力系统的经济性与安全性。

目前, 最优潮流(Optimal Power Flow, OPF)被广泛采用, 因其既能优化经济效益, 又可指导工作人员及时采取措施维持系统稳定运行^[4-5]。但 OPF 的最优解往往接近系统暂态稳定极限^[6], 一旦发生暂态失稳

基金项目: 国家自然科学基金资助项目(52407118)

Project Supported by the National Natural Science Foundation of China (52407118)

将造成重大经济损失。由此可见,开展暂态稳定约束最优潮流(Transient Stability Constrained Optimal Power Flow, TSCOPF)研究具有重要理论与工程意义。

在现有关于考虑新能源不确定性的 TSCOPF 研究中,处理不确定性的方法包括模糊集理论^[7]、随机规划法^[8]、鲁棒优化法、机会约束规划^[9]等。模糊集理论将不确定的风电功率作为模糊变量,将变量定义为允许在边界值附近进行轻微的波动。随机规划法利用概率分布描述新能源的不确定性,但是不确定的概率分布较难准确得到,存在一定误差。鲁棒优化法通过引入不确定集处理不确定性,寻求一个对于不确定集均能实现的解,但是该方法得到的结果往往过于保守。机会约束规划则通过将模型中的不等式约束转换为概率形式,确保目标函数在给定的置信概率下满足约束条件。然而文献[7-9]所提方法均不能对风电不确定性的风险信息进行量化。

TSCOPF 属于非线性优化类问题,需要进行多次的迭代求解才能找到最优解。在每次迭代中,系统会根据当前的状态和约束条件,调整发电机的出力、节点电压,以逐步逼近最优解。这种迭代求解的过程比较复杂耗时,特别是在计及暂态稳定约束情况下,求解过程会更加复杂。TSCOPF 传统求解算法如二次规划法^[10]、牛顿法^[11]、内点法^[12]等,求解过程均比较复杂,且传统求解算法如果初值的设定不合适,求解结果会不准确。近年来,广泛采用智能算法对该类问题进行求解,采用智能优化算法对于多变量、多约束问题能够更好地找到最优解,常采用的智能算法有遗传算法、粒子群优化(Particle Swarm Optimization, PSO)算法^[13]等,PSO 算法求解较快,但存在求解精度低、易陷入局部最优等缺点。文献[14]采用量子启发式粒子群(Quantum-inspired Particle Swarm Optimization, QPSO)算法求解,但是其在处理大规模等式和不等式约束问题时依然可能会陷入局部最优,因此有必要对优化算法进行改进。

综上,为兼顾新能源不确定性风险的量化与优化求解算法的改进,本文提出一种可量化风电不确定性风险的暂态稳定约束最优潮流(TSCOPF)模型。本文的创新之处在于:建立风电不确定性模型,采用条件风险价值(Conditional Value at Risk, CVaR)量化因风电波动导致的弃风与失负荷风险成本;将风险成本纳入 TSCOPF 目标函数,实现对风险的显式量化;引入改进型多元“宇宙”优化算法(Modified Multi-Verse Optimizer, MMVO),求解该模型以获得(近似)全局最优解。

1 风电风险量化

1.1 风电出力建模

风电出力主要受风速影响^[15-18],因此可基于风速构建风电出力模型,具体步骤如下:

1)通过预测风速值和预测误差计算求得随机风速 v :

$$v = v^{\text{pre}} + \zeta \quad (1)$$

式中: v^{pre} 为风速预测值; ζ 为风速预测误差值。

2)根据风速历史数据,风速预测误差通常服从正态分布,其概率密度函数 $f(\zeta)$ 为:

$$f(\zeta) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(\zeta - \mu)^2}{2\sigma^2}} \quad (2)$$

式中: σ 为风速预测误差标准差; μ 为风速预测误差均值。

由于随着标准差的增大,实际风速与预测风速的偏离程度会更大。计及该影响,对标准差 σ 定义为:

$$\sigma = v^{\text{pre}} \varepsilon\% \quad (3)$$

式中: $\varepsilon\%$ 为一个可调参数,表示标准差相对于预测风速偏离的百分比,量化了偏离程度。

3)基于风速概率密度函数,构建风电出力概率模型 $P_w(v)$:

$$P_w(v) = \begin{cases} 0, v \leq v_1 \text{ or } v > v_3 \\ \frac{P_a v_1^3}{(v_1^3 - v_2^3)} + \frac{P_a v^3}{(v_2^3 - v_1^3)}, v_1 < v \leq v_2 \\ P_a, v_2 < v \leq v_3 \end{cases} \quad (4)$$

式中: v, v_1, v_2, v_3 分别为实际风速、切入风速、额定风速和切出风速; P_a 为风机额定有功功率。

1.2 CVaR

在险价值(Value at Risk, VaR)^[19-21]指在一定置信概率下预计的最小收益值,利用损失函数的分位数评估风险。该方法不仅应用于金融领域,同时在电力市场风险管理中也发挥着重要作用。然而, VaR 具有无法量化概率函数尾部所造成影响的局限性,即极端事件发生的概率,并且其不满足可加性。CVaR^[22]能够有效弥补 VaR 不足,可以更好地量化风险发生的程度,以便工作人员进行及时控制维持电力系统稳定。CVaR 求解步骤如下:

1)考虑决策变量与不确定性因素之间的相互作用,确定损失函数值不超过给定临界值的累积概率分布:

$$\delta(y, a) = \int_{f(y, z) \leq a} p(z) dz \quad (5)$$

式中: a 为临界值; y 为决策变量; z 为随机变量; $\delta(y,a)$ 为损失函数值不超过 a 的概率事件指示函数; $f(y,z)$ 为 y 和 z 构成的损失函数; $p(\cdot)$ 为不确定变量的概率密度函数。

2)对于给定的任一置信概率 β ,通过改变 β 的值可以模拟不同风险规避程度下的结果。当置信概率越大,对应的 VaR 越大,表示风险规避程度越高。 a 存在一个集合,其 VaR 及 CVaR 定义为:

$$\text{VaR}(y) = \min \{a | \delta(y,a) \geq \beta\} \quad (6)$$

$$\text{CVaR}(y) = \frac{1}{1-\beta} \int_{f(y,z) \geq \text{VaR}(y)} f(y,z) p(z) dz \quad (7)$$

3)由于求取 CVaR 时包含 VaR 较难直接求取,引入辅助函数对其进行化简得到近似解。将式(7)改写为:

$$\begin{cases} \text{CVaR}(y) = b + \frac{1}{1-\beta} \int_{f(y,z) \geq \text{VaR}(y)} (f(y,z) - b) p(z) dz \\ (f(y,z) - b) = \max \{0, (f(y,z) - b)\} \end{cases} \quad (8)$$

式中: b 为待优化的辅助参数。

4)由于式(8)积分求解过程比较复杂,一般取随机向量的 N 个样本,将积分转化为样本均值形式,即式(9)所示:

$$\text{CVaR}(y) = b + \frac{1}{1-\beta} (f(y,z) - b) \sum_{n_1=1}^N p_{n_1}(z) \quad (9)$$

式中: N 为某一概率分布下样本的总数; $p_{n_1}(z)$ 为样本 n_1 发生的概率。

1.3 风电风险成本

由于风电出力较难实现精准预测,与实际存在一定误差,可能导致风力发电过剩,从而产生弃风风险成本;或由于负荷侧电力需求不足,导致弃负荷风险成本^[23-24]。因此,引入 CVaR 量化风电出力不确定性带来的风险,并将此风险成本纳入系统的运行成本中。弃风弃负荷风险成本求解步骤如下:

1)弃风成本定义为风机实际出力大于预测值时,受电力系统运行约束影响,多余风电功率无法并网消纳而被削减所造成的经济损失。弃风损失函数 M_{loss1} 为:

$$M_{\text{loss1}} = D_1 \cdot (P_w - P'_w) \quad (10)$$

式中: D_1 为损失函数的系数; P_w 为风机实际出力; P'_w 为预测出力。

进而通过式(9)得到弃风产生的 CVaR:

$$M_{\text{CVaR, loss1}} = \frac{1}{1-\beta_1} \int_{f_{\text{loss1}}(P_w) \geq y_1} f_{\text{loss1}}(P_w) p(P_w) dP_w \quad (11)$$

式中: β_1 为弃风风险的置信概率; y_1 为该损失函数对应的 VaR 值; $f_{\text{loss1}}(P_w)$ 为弃风损失函数。

2)弃负荷成本是由于风力发电预测出力大于实际出力所产生的风险成本,出现用电短缺,需增加火力发电机组出力保障稳定。弃负荷损失函数 M_{loss2} 为:

$$M_{\text{loss2}} = D_2 \cdot (P'_w - P_w) \quad (12)$$

式中: D_2 为负荷损失函数的系数。

弃负荷产生的 CVaR 为:

$$M_{\text{CVaR, loss2}} = \frac{1}{1-\beta_2} \int_{f_{\text{loss2}}(P_w) \geq y_2} f_{\text{loss2}}(P_w) p(P_w) dP_w \quad (13)$$

式中: β_2 为弃负荷风险的置信概率; y_2 为该损失函数对应的 VaR 值; $f_{\text{loss2}}(P_w)$ 为弃负荷损失函数。

因此,由风电不确定性产生的风险成本 M_w 为:

$$M_w = M_{\text{CVaR, loss1}} + M_{\text{CVaR, loss2}} \quad (14)$$

1.4 风电不确定性场景构建

为了对风电风险成本进行量化,需要构建反映系统不确定性的概率场景,本文采用拉丁超立方采样生成场景样本。该方法首先将风速预测误差 ζ 的累积概率区间 $[0,1]$ 均分为 Nt 个子区间,其次在每个子区间内抽取随机数,用于保证采样点在子区间内的随机分布,并通过式(15)将其映射为该区间内的累积概率值。

$$q_{i_1} = (1/Nt)r_{i_1} + (i_1 - 1)/Nt \quad (15)$$

式中: q_{i_1} 为第 i_1 个区间的累积概率值; r_{i_1} 为第 i_1 个区间内生成的随机数, $r_{i_1} \in [0,1]$ 。

将采样点通过逆累积分布函数转换为风速预测误差值。

$$\zeta_{i_2} = F^{-1}(q_{i_2}) \quad (16)$$

式中: F^{-1} 为逆累积分布函数; ζ_{i_2} 为第 i_2 个采样点对应的风速预测误差值。

基于生成的预测误差值,结合预测风速构建实际风速场景:

$$v_{i_3} = v^{\text{pre}} + \zeta_{i_3} \quad (17)$$

式中: v_{i_3} 为第 i_3 个实际风速场景。

为提高计算效率,利用 K-Means 聚类算法对初始场景集合进行聚类,将各聚类簇的中心点提取为典型场景,最终构建具有代表性的典型场景集。基于生成的典型场景集,通过式(4)转换为功率场景,从而计算每个场景下的风电风险成本。

2 TSCOPF 模型

TSCOPF 模型包含目标函数、潮流平衡等式约

束和不等式约束及暂态稳定约束^[25],用以优化电力系统的运行状态。

2.1 目标函数

TSCOPF 模型通常以最小化发电成本或系统损耗作为目标函数。本文构建的目标函数包含常规发电机组的燃料成本及弃风与弃负荷风险成本 2 部分。

目标函数定义为最小化总成本 F ,其表达式为:

$$\min F = \sum_{i_4=1}^{n_G} (c_{i_4} P_{G_{i_4}}^2 + e_{i_4} P_{G_{i_4}} + k_{i_4}) + M_w \quad (18)$$

式中: n_G 为常规发电机组的总数量; $P_{G_{i_4}}$ 为第 i_4 台发电机有功功率; $c_{i_4}, e_{i_4}, k_{i_4}$ 为第 i_4 台发电机组的燃料成本系数; M_w 为风电不确定性产生的风险成本。

2.2 潮流等式约束

根据电压和功率之间的关系,建立节点电压和注入功率之间的潮流方程,以确保每个节点的功率平衡(注入功率等于流出功率)。

$$\begin{cases} P_{G_{i_4}} + P_{W_{i_5}} = P_{D_i} + U_i \sum_{j=1}^n U_j (G_{ij} \cos \theta_{ij} + B_{ij} \sin \theta_{ij}) \\ Q_{G_{i_4}} + Q_{W_{i_5}} = Q_{D_i} + U_i \sum_{j=1}^n U_j (G_{ij} \sin \theta_{ij} - B_{ij} \cos \theta_{ij}) \end{cases} \quad (19)$$

式中: n 为系统节点总数; $P_{W_{i_5}}, P_{D_i}$ 分别为系统第 i_5 个风电场以及第 i 个节点负荷消耗有功功率; $Q_{G_{i_4}}, Q_{W_{i_5}}, Q_{D_i}$ 分别为系统第 i_4 台火力发电机、第 i_5 个风电场以及第 i 个节点负荷消耗无功功率; U_i, U_j 分别为节点 i, j 的电压幅值; θ_{ij} 为节点 i, j 之间的相角差; G_{ij}, B_{ij} 分别为节点导纳的实部和虚部。

2.3 不等式约束

不等式约束包括 2 部分:常规发电机出力约束,确保机组出力处于设定的技术可行区间;支路潮流安全约束,限制线路传输功率不超过其热稳定极限容量。这 2 部分约束共同保障系统在安全边界内稳定运行。

$$\begin{cases} P_{G_{i_4}}^{\min} \leq P_{G_{i_4}} \leq P_{G_{i_4}}^{\max} \\ Q_{G_{i_4}}^{\min} \leq Q_{G_{i_4}} \leq Q_{G_{i_4}}^{\max} \\ U_i^{\min} \leq U_i \leq U_i^{\max} \\ S_{L_{i_6}} \leq S_{L_{i_6}}^{\max} \end{cases} \quad (20)$$

式中: $P_{G_{i_4}}^{\min}, P_{G_{i_4}}^{\max}$ 分别为常规发电机有功功率的下、上限; $Q_{G_{i_4}}^{\min}, Q_{G_{i_4}}^{\max}$ 分别为常规发电机无功功率的下、上限; $U_i^{\min}, U_i^{\max}$ 分别为系统节点电压幅值的下、上限; $S_{L_{i_6}}, S_{L_{i_6}}^{\max}$ 分别为系统第 i_6 条支路的视在功率和视在功率的上限。

2.4 暂态稳定约束

在暂态稳定性评估中,引入暂态稳定性指数 (Transient Stability Index, TSI) 来量化整个暂态过程中发电机转子角的最大偏差,其量值为 I_{TS} 。其计算公式为:

$$I_{TS} = \frac{360 - |\delta_{\max}|}{360 + |\delta_{\max}|} \times 100 \quad (21)$$

式中: $\delta_{\max}$ 为任意 2 台发电机之间的最大功角差。

当 $I_{TS} > 0$, 系统处于暂态稳定状态;当 $I_{TS} < 0$, 系统处于暂态不稳定状态。

本文选用卷积神经网络 (Convolutional Neural Networks, CNN) 和长短期记忆网络 (Long Short-term Memory, LSTM) 组合形成的 CNN-LSTM^[26] 实现暂态稳定约束的快速判断。与传统的暂态稳定约束判断方法相比, CNN-LSTM 模型克服了计算量大且耗时的缺点,更好地满足实时性需求。CNN 能够高效地从电气运行数据中提取空间特征, LSTM 则擅长捕捉时间序列中的相关性。通过将两者结合,使 CNN-LSTM 模型能够充分利用空间特征和时间信息,从而提高暂态稳定性判断的准确性与计算效率。

该混合网络的结构如图 1 所示,由输入层、Conv3×3 卷积层、Pool2×2 池化层、LSTM 层、Dropout 层和全连接层组成,各层均采用 ReLU 激活函数。通过时域仿真构建网络所需的样本集,样本集中每个样本包含发电机有功和无功功率、节点电压幅值及相角、负荷有功功率和无功功率 6 种电气运行特征以及相应 TSI 值,选取每个样本的最小 TSI 值作为其对应 TSI。在离线训练过程中,首先通过 CNN 层对输入的电气运行量进行特征提取和降维处理,采用 ReLU 激活函数引入非线性变换能力;随后, LSTM 层接收经 CNN 处理后的特征序列,捕捉时序相关性,并通过反向传播不断优化网络参数,建立电气运行特征与 TSI 值之间的映射关系。




图1 CNN-LSTM网络结构

Fig.1 CNN-LSTM network structure

在实际应用中,将实时采集的系统运行数据输入训练好的 CNN-LSTM 网络,即可快速获取相应的 TSI 值,以评估系统暂态稳定性。

3 TSCOPF 模型求解

在 TSCOPF 模型中,状态变量表征平衡节点的输出,而控制变量表征平衡节点之外其他节点的输出。通过逐步优化控制变量求解模型,以实现目标函数最小化。基于控制变量求解后,校验其是否满足约束条件,继而计算得到状态变量的值。TSCOPF 模型本质上是一类非线性、多变量、多约束的优化问题,本文利用改进的 MVO 算法求解此模型。

3.1 多元“宇宙”优化算法

多元“宇宙”优化^[27-28](Multi-verse Optimizer, MVO)算法起源于多元“宇宙”理论,模拟粒子通过虫洞从白洞向黑洞传输的行为,借助相关“宇宙”学规则,不断搜索“宇宙”空间,使物质逐渐趋于最优“宇宙”位置。在这个模型中,“宇宙”可以被视为问题的一个可能解;每个个体(变量)在这个“宇宙”中代表解的一个组成部分;膨胀率代表解的适应度,膨胀率越低意味着解的质量越好。

基础 MVO 算法遵循以下规则:

1)白洞拥有很强的斥力,能够释放所有个体;黑洞拥有极高的引力,能够吸引周围的个体,可认为膨胀率高的“宇宙”具有白洞性质,膨胀率低的“宇宙”具有黑洞性质。个体一般从膨胀率高的“宇宙”移动到膨胀率低的“宇宙”。

2)虫洞被视为连接不同“宇宙”的通道。虫洞不受膨胀率影响,个体可以通过虫洞不同的“宇宙”进行传输,每个“宇宙”都存在一定数量的虫洞进行探索。探索任务主要是以履行距离率(Travelling Distance Rate, TDR)寻找局部最优“宇宙”。

MVO 算法通过迭代过程寻找最优解,在每次迭代中,算法依据所有“宇宙”的膨胀率对其进行排序,并通过轮盘赌机制选择特定“宇宙”作为白洞。轮盘赌机制公式为:

$$x_{ij} = \begin{cases} x_{ij}, r_1 \geq R_i^k \\ x_{qj}, r_1 < R_i^k \end{cases} \quad (22)$$

式中: x_{ij} 为第 i 个“宇宙”的第 j 个参数; x_{qj} 为由轮盘赌机制选择的第 q 个“宇宙”的第 j 个参数; R_i^k 为第 i 个“宇宙”在第 k 次迭代时的标准化膨胀率; r_1 为0~1内的随机数。

3.2 MMVO 算法

MVO 算法具有参数少、结构简单等优点,但仍存在易陷入局部最优、种群多样性不足等缺点。因此,本文提出 MMVO 算法,通过标准化膨胀率修正

和引入精英“宇宙”机制对传统 MVO 算法进行改进,以增强其全局搜索能力和收敛性能。

3.2.1 标准化膨胀率修正

标准化膨胀率用于衡量解的质量,其修正过程能够增强个体(解的组成部分)的探索能力,并对“宇宙”(整个解)的位置更新具有关键意义。在基础 MVO 算法中,标准化膨胀率由当前种群的标准化膨胀率和“宇宙”总数决定:

$$R_l^k = \frac{f_l^k}{\sqrt{\sum_{l=1}^L (f_l^k)^2}} \quad (23)$$

式中: f_l^k 为第 l 个“宇宙”在第 k 次迭代时的原始膨胀率; L 为“宇宙”总数。

随着种群规模的增加,MVO 算法中白洞到黑洞转变的概率将急剧降低。因此,需采用最小-最大归一化方法将膨胀率映射至[0,1]区间,以消除种群规模不同对膨胀率的影响,从而提升空间探索效率。最小-最大归一化标准化膨胀率公式为:

$$R_l^k = \frac{f_l^k - f_{\min}^k}{f_{\max}^k - f_{\min}^k + \alpha} \quad (24)$$

式中: $f_{\min}^k, f_{\max}^k$ 分别为第 k 次迭代时的最小和最大膨胀率; α 为一个很小的正数,取0.01。

3.2.2 精英“宇宙”

在迭代过程中,每个“宇宙”的状态都会被记录下来,并且每个“宇宙”都会保留其历史上最好的状态,将该状态称为精英“宇宙”。

虫洞机制在最优“宇宙”与个体“宇宙”之间传输解分量,但当当前求解得到的最优“宇宙”不佳时,算法难以跳出该“宇宙”。因此,采用精英“宇宙”代替当前的最佳“宇宙”继续探索。精英“宇宙”结合了当前“宇宙”的所有优势,提供了理想的搜索范围,增加了种群期望的搜索方向和多样性,并利用 T_{DR}, C_1, C_2 分别约束以下随机向量范围:历史全局最优宇宙位置;个体历史最优位置;随机生成的位置扰动,以此增强种群多样性并强化“宇宙”的开采能力。其位置更新表示为:

$$y_{l,m}^k = \begin{cases} y_{l,m}^k, r_4 \geq W_{EP} \\ \begin{cases} zbest_{l,m}^k + T_{DR} \times zo_{l,m}^k, r_3 < 0.5, r_4 < W_{EP} \\ zbest_{l,m}^k - T_{DR} \times zo_{l,m}^k, r_3 \geq 0.5 \end{cases} \end{cases} \quad (25)$$

$$zo_{l,m}^k = \left[C_1 \times ((B_d^H - B_d^L) \times r_2 + B_d^L) + C_2 \times r_2 \right] - zbest_{l,m}^k \quad (26)$$

式中: $y_{l,m}^k$ 为第 l 个“宇宙”第 k 次迭代时在 m 维度上更新后的位置坐标; $zbest_{l,m}^k, zo_{l,m}^k$ 为第 l 个最佳“宇宙”的变量以及第 k 次迭代时在 m 维度上的前进距

离; C_1, C_2 分别为控制随机位置与全局最优位置对搜索方向的影响程度系数; T_{DR} 为控制虫洞传输范围的关键参数,它随迭代次数动态变化; W_{EP} 为控制虫洞生成概率的参数; B_d^H, B_d^L 分别为第 d 个变量的上限和下限; r_2, r_3, r_4 为 $[0, 1]$ 中的随机数。

4 模型求解流程

4.1 MMVO 算法求解

MMVO 算法求解步骤如下:

- 1) 初始化参数,如搜索空间维度、“宇宙”种群数量、迭代次数等。
- 2) 搜索阶段:计算标准化膨胀率,根据膨胀率对所有“宇宙”进行排序。
- 3) 计算修正后的标准化膨胀率、更新后的 W_{EP} 参数和 T_{DR} 系数。
- 4) 如果 $r_1 < R_l^k$,则执行轮盘赌机制,并通过虫洞传送机制更新个体的位置,见式(22);否则使用精英“宇宙”更新位置进行探索,见式(25)一式(26)。
- 5) 当达到最大迭代次数后,输出最优解。如果未达最大迭代次数,则跳转至步骤2)一步骤4)。

4.2 模型框架

可量化风电不确定性风险的 TSCOPF 模型,其实现流程如图 2 所示。其中, P 为节点注入有功功率, Q 为节点注入无功功率, V 为节点电压幅值, θ 为节点电压相角。




图2 TSCOPF 模型流程

Fig.2 Flowchart of TSCOPF model

模型主要包含以下求解步骤:

- 1) 构建风电出力模型,并采用拉丁超立方抽样

法生成风电出力场景;根据式(10)一式(14)计算得到弃风弃负荷风险成本 CVaR 值。

2) 输入运行参数并初始化 MMVO 算法参数,生成初始“宇宙”;通过 MMVO 算法进行迭代求解,计算个体目标函数值,判断各运行变量是否满足约束条件,其中暂态稳定约束由 CNN-LSTM 模型进行判断;当迭代次数达到预设最大值时停止求解,输出系统最优运行方案。

4.3 模型评价指标

为评估 CNN-LSTM 模型在电力系统暂态稳定判别中的性能,本文采用整体准确率 T_{ac} 、漏警率 T_{sr} 及虚警率 T_{ur} 3 项指标作为评价标准。

$$T_{ac} = \frac{T_p + T_N}{T_p + F_N + F_p + T_N} \quad (27)$$

$$T_{sr} = \frac{T_p}{F_p + T_N} \quad (28)$$

$$T_{ur} = \frac{F_N}{T_p + F_N} \quad (29)$$

式中: T_p 为实际稳定且判别为稳定的数量; T_N 为实际失稳且判别为失稳的数量; F_p 为实际失稳但判别为稳定的数量; F_N 为实际稳定但判别为失稳的数量。

5 算例分析

实验平台采用 Matlab 2018b 及电力系统仿真软件 PSASP,基于改进的 IEEE 39 节点系统(见图 3)验证本文方法的有效性。




图3 IEEE 39节点系统

Fig.3 IEEE 39-bus system

图3中,G1—G10为火力发电机,W1—W3为风电场。在节点4、节点14、节点18分别接入额定容量为150 MW的风电场,各风电场的额定风速、切入风速、切出风速分别为8 m/s,2.5 m/s,20 m/s。弃风与弃负荷损失函数系数分别设置为60 \$/MWh和40 \$/MWh,CVaR风险成本的置信概率设置为0.90。

5.1 置信概率对经济性的影响

通过调整CVaR的置信概率,可评估系统对不确定性风险的承受能力。为说明采用CVaR进行风险量化的效果,表1给出了不同置信概率下对应的成本。

表1 不同置信概率下的成本
Table 1 Costs at different confidence levels \$

置信概率	CVaR 成本	总成本
0.90	17 024	144 260
0.92	172 39	144 312
0.94	17 548	145 107
0.96	18 216	145 893
0.98	19 104	146 102

由表1可知,随着置信概率的提升,系统面临的不确定性风险增加,运行成本相应上升。这是因为电力系统对风电不确定性引起的风险承受能力要求越高,需要配置的资源越多,成本随之增加。同时,置信概率反映了对系统安全性的要求,安全性要求越高,经济性指标值相应降低。

5.2 CNN-LSTM模型训练与性能评估

5.2.1 模型样本集构建及训练

为了模拟严重故障工况,设置故障为三相短路故障,并将总仿真时间设置为20 s。通过调整系统运行工况,使负荷在基准值的80%~120%范围内以5%为步长变化,并同步调整发电机出力以维持功率平衡,从而生成大规模电力系统运行数据。将生成的运行数据与不同预想故障线路进行组合,利用PSASP进行时域仿真构建样本集。随后,将样本数据按80%和20%的比例随机划分为训练集和测试集,采用2.4节所述方法对模型进行训练,以评估其性能。

5.2.2 模型性能评估

为验证CNN-LSTM模型在暂态稳定约束评估中的准确性,在相同样本集输入条件下,将其与CNN、决策树(Decision Tree, DT)、支持向量机(Support Vector Machines, SVM)进行性能对比,结果见表2。

表2 模型性能对比
Table 2 Model performance comparison

模型	T_{ac}	T_{sr}	T_{ur}
CNN-LSTM	99.05	1.62	2.38
CNN	98.23	2.54	2.73
DT	95.32	4.38	5.11
SVM	96.71	3.12	3.85

由表2可知,与其他模型相比,CNN-LSTM模型具有更高的 T_{ac} 指标值以及更低的 T_{sr} 和 T_{ur} 指标值,表明CNN-LSTM在暂态事件分类中具有更高的准确性。

5.3 TSCOPF模型优化效果评估

为了验证本文所提TSCOPF模型在不确定性条件下维持暂态稳定的效果,在节点17与18之间的联络线上施加持续时间0.1 s的三相短路故障,并将总仿真时间设置为20 s。

图4展示了未优化工况下系统发电机功角响应。当系统遭受三相短路故障后,发电机功角持续发散,机组间同步运行能力丧失。机组最大功角差超过360°阈值时,系统完全失稳。图5呈现了TSCOPF优化后的功角响应特性。通过发电机出力优化,系统功角仅经历短暂振荡即趋稳定,证明所提方法可有效提升暂态稳定性能。




图4 优化前功角响应特性

Fig.4 Power angle response characteristics before optimization




图5 优化后功角响应特性

Fig.5 Power angle response characteristics after optimization

5.4 算法收敛性分析

为验证 MMVO 算法的有效性,采用 PSO 算法、标准 MVO 算法及 MMVO 算法分别求解 TSCOPF 模型,对比目标函数收敛特性。各算法参数统一设置为:种群规模 20,最大迭代次数 100。经 20 次独立实验后,优化结果均值对比见图 6。




图6 不同算法优化结果对比

Fig.6 Comparison of optimization results from different algorithms

与其他优化算法相比,MMVO 算法收敛速度更快且收敛精度更高,表明其具有更强的全局寻优能力。

6 结论

为量化风电不确定性风险,本文提出一种基于 CVaR 的 TSCOPF 风险量化模型,增强系统对不确定性的响应能力,并采用 MMVO 算法在 IEEE 39 节点系统中验证有效性,结论如下:

1)提出基于 CVaR 的风电风险成本量化模型,有效降低不确定性导致的暂态失稳风险。

2)MMVO 算法显著提升模型求解效率,平衡了局部与全局寻优能力,使其更加适用于模型的求解。

3)优化结果具备工程指导价值,所生成的调度方案可为运行人员提供关键参考。

当前 CVaR 约束的建模未考虑极端场景耦合效应,下一步将构建多场景鲁棒优化框架;同时需提升高维约束下的求解效率,例如引入并行计算或深度学习代理模型。

参考文献

[1] 边家瑜,周专,于志勇,等.高比例新能源电力系统下基于多尺度的构网型储能配置优化研究[J].可再生能源,2025,43(6): 839-845.
BIAN Jiayu, ZHOU Zhuan, YU Zhiyong, et al. Research on the multi-scale configuration optimization for the grid-forming energy storage during high penetration of renewable energy in power

system[J].Renewable Energy Resources,2025,43(6):839-845.

- [2] 刘金朋,胡国松,彭锦淳,等.多能互补的虚拟电厂低碳-经济-鲁棒优化调度[J].中国电机工程学报,2024,44(24):9718-9731.
LIU Jinpeng, HU Guosong, PENG Jinchun, et al. Low-carbon economic-robust optimization scheduling of multi-energy complementary virtual power plants[J].Proceedings of the CSEE, 2024,44(24):9718-9731.
- [3] 孙靛雨,林泽源,李伟.考虑氢储能的多目标综合能源优化配置方案研究[J].高压电器,2024,60(7):88-96.
SUN Jingyu, LIN Zeyuan, LI Wei. Research on multi-objective comprehensive energy optimization configuration scheme Considering hydrogen storage[J].High Voltage Apparatus, 2024, 60(7):88-96.
- [4] 李林.基于数字孪生的配电网潮流网络模型构建研究[J].电子设计工程,2024,32(1):111-114,119.
LI Lin. Research on power flow network model construction of distribution network based on digital twin[J].Electronic Design Engineering, 2024,32(1):111-114,119.
- [5] 叶清泉,吴明启,吴旭光,等.基于ADMM的多区域直流系统完全分布式最优潮流算法[J].浙江电力,2024,43(2):13-24.
YE Qingquan, WU Mingqi, WU Xuguang, et al. A fully distributed optimal power flow algorithm for multi-regional DC systems based on ADMM[J].Zhejiang Electric Power, 2024,43(2):13-24.
- [6] 郑丽琴,谢东梅,白晓清.基于Predictive Prescriptive框架的鲁棒最优潮流[J].电力自动化设备,2023,43(7):175-181.
ZHENG Liqin, XIE Dongmei, BAI Xiaoqing. Robust optimal trending based on predictive prescriptive framework[J].Power Automation Equipment, 2023,43(7):175-181.
- [7] 李鹏,刘念,胡秦然,等.“新型电力系统数字化关键技术综述”专辑评述[J].电力系统自动化,2024,48(6):1-12.
LI Peng, LIU Njan, HU Qinran, et al. Commentary on special issue of reviews on key technologies for digitalization of new power system[J].2024,48(6):1-12.
- [8] 牛文娟,谈健,陈琛,等.基于决策依赖不确定性的含分布式光伏虚拟电厂调度策略研究[J].电力需求侧管理,2024,26(6):68-74.
NIU Wenjuan, TAN Jian, CHEN Chen, et al. Research on scheduling strategy of virtual power plant with distributed PV based on decision dependent uncertainty[J].Power Demand Side Management, 2024,26(6):68-74.
- [9] 郑志杰,李文升,田浩,等.考虑分布式电源并网的风力发电站最大注入功率[J].电网与清洁能源,2024,40(12):141-146.
ZHENG Zhijie, LI Wensheng, TIAN Hao, et al. Research on the maximum injected power of wind power plants considering grid-connected distributed generation[J].Power System and Clean Energy, 2024,40(12):141-146.
- [10] 张艳丽,王争冕,薛成,等.考虑新能源接入的配电网两阶段有功无功协调降损方法[J].电网与清洁能源,2023,39(12):121-129.
ZHANG Yanli, WANG Zhengmian, XUE Cheng. A two-stage active and reactive power coordinated loss reduction method for distribution networks integrated with new energy[J].Power System and Clean Energy, 2023,39(12):121-129.
- [11] TU X, DESSAINT L A, KAMWA I. Fast approach for transient stability constrained optimal power flow based on dynamic reduction method[J].IET Generation, Transmission & Distribution,

- 2014,8(7): 1293-1305.
- [12] 傅国斌,孙海斌,王海亭,等.含高渗透率新能源电力系统多目标无功优化方法[J].高压电器,2025,61(5):291-301.
FU Guobin, SUN Haibin, WANG Haiting, et al. Multi-objective reactive power optimization method for new energy power systems with high permeability[J]. High Voltage Apparatus, 2025, 61(5): 291-301.
- [13] 黄立芹,林巧锋.融合深度学习与智能优化算法的水电机组区域检修管理系统研究[J].电子设计工程,2024,32(24):152-156,161.
HUANG Liqin, LIN Qiaofeng. Research of regional maintenance management system for hydropower units based on deep learning and intelligent optimization algorithm[J]. Electronic Design Engineering, 2024, 32(24): 152-156, 161.
- [14] POOJA, SOOD S K. Scientometric analysis of quantum-inspired metaheuristic algorithms[J]. Artificial Intelligence Review, 2024, 57(2): 1293-1305.
- [15] 马涛,周飞飞,何迎利,等.基于强化学习的风电消纳随机鲁棒混合优化调度系统[J].电子设计工程,2024,32(15):25-29.
MA Tao, ZHOU Feifei, HE Yingli, et al. Stochastic robust hybrid scheduling system for wind power consumption based on reinforcement learning[J]. Electronic Design Engineering, 2024, 32(15): 25-29.
- [16] 赵峰,张帆,陈小强,等.基于VMD-APSO的风电场混合储能系统容量优化配置[J].高压电器,2023,59(6):120-127.
ZHAO Feng, ZHANG Fan, CHEN Xiaoqiang, et al. Optimal configuration of capacity of wind farm hybrid energy storage system based on VMD-APSO algorithm[J]. High Voltage Apparatus, 2023, 59(6): 120-127.
- [17] 臧海祥,赵勇凯,张越,等.基于低风速功率修正和损失函数改进的超短期风电功率预测[J].电力系统自动化,2024,48(7):248-257.
ZANG Haixiang, ZHAO Yongkai, ZHANG Yue, et al. Ultra-short-term wind power prediction based on power correction under low wind speed and improved loss function[J]. Automation of Electric Power Systems, 2024, 48(7): 248-257.
- [18] 郑云平,亚夏尔·吐尔洪.基于VSG技术的风——光—储系统自适应调频控制策略研究[J].高压电器,2023,59(7):12-19.
ZHENG Yunping, YAXAR·Turgun. Research on adaptive frequency modulation control strategy of wind-PV-storage system based on VSG technology[J]. High Voltage Apparatus, 2023, 59(7): 12-19.
- [19] LI N, DONG J, LIU L, et al. A novel EMD and causal convolutional network integrated with Transformer for ultra short-term wind power forecasting[J]. International Journal of Electrical Power & Energy Systems, 2023, 154: 109470.
- [20] 王辉,王军杰,王腾飞,等.出力不确定下基于CVaR的风电供应链优化决策[J].电力科学与技术学报,2023,38(4):134-142.
WANG Hui, WANG Junjie, WANG Tengfei, et al. Optimal decision of wind power supply chain based on CVaR under uncertainty output[J]. Journal of Electric Power Science and Technology, 2023, 38(4): 134-142.
- [21] 丁红坚,辛诚,李沐阳,等.考虑电力现货市场风险的抽水蓄能电站竞价策略[J].电力建设,2024,45(5):150-158.
DING Hongjian, XIN Cheng, LI MUYANG, et al. Bidding strategies of pumped storage power station considering the risk of electricity spot market[J]. Electric Power Construction, 2024, 45(5): 150-158.
- [22] 徐雨舟,唐忠.含CSPP的区域多能源微网优化调度模型[J].智慧电力,2024,52(10):24-31.
XU Yuzhou, TANG Zhong. Optimal Scheduling model of regional multi-energy microgrid containing concentrating solar power plant[J]. Smart Power, 2024, 52(10): 24-31.
- [23] 青辰,魏震波,刘洋,等.基于双时间尺度模型预测控制的灵活性资源动态调度[J].高压电器,2025,61(5):31-40,52.
QING Chen, WEI Zhenbo, LIU Yang, et al. Dynamic scheduling of flexible resources based on dual-time Scale model predictive control[J]. High Voltage Apparatus, 2025, 61(5): 31-40, 52.
- [24] 李令宇,程浩忠,张衡,等.含高比例新能源电力系统的低碳电源规划方法[J].电测与仪表,2025,62(7):30-37.
LI Lingyu, CHENG Haozhong, ZHANG Heng, et al. Low-carbon power planning method for power system with high proportion of renewable energy[J]. Electrical Measurement & Instrumentation, 2025, 62(7): 30-37.
- [25] 刘颂凯,周倩,杨超,等.计及不确定性的随机暂态稳定约束最优潮流[J].电力系统及其自动化学报,2024,36(7):1-10.
LIU Songkai, ZHOU Qian, YANG Chao, et al. Stochastic transient stability constrained optimal power flow with uncertainty[J]. Proceedings of the CSU-EPSA, 2024, 36(7): 1-10.
- [26] 王亮,辛伟,南锐娟.基于深度学习与特征信号感知的局部放电故障检测算法设计[J].电子设计工程,2024,32(9):42-46.
WANG Liang, XIN Wei, NAN Ruijuan. Design of partial discharge fault detection algorithm based on deep learning and feature signal perception[J]. Electronic Design Engineering, 2024, 32(9): 42-46.
- [27] 李大虎,周泓宇,周悦,等.基于多元“宇宙”优化算法的混合光伏-热电系统MPPT设计[J].中国电力,2023,56(11):197-205.
LI Dahu, ZHOU Hongyu, ZHOU Yue, et al. MPPT design of hybrid photovoltaic-thermal power system based on multiat universe optimization algorithm[J]. China Electric Power, 2023, 56(11): 197-205.
- [28] 李漠发,张志文,胡斯佳,等.基于MVO算法与改进目标函数的电力系统负荷频率控制[J].电力系统保护与控制,2024,52(6):1-14.
LI Mufa, ZHANG Zhiwen, HU Sijia, et al. Power system load frequency control based on MVO algorithm with improved objective function[J]. Power System Protection and Control, 2024, 52(6): 1-14.

(责任编辑 付小平)

收稿日期:2024-11-26; 修改日期:2025-08-01

作者简介:刘颂凯(1990),男,湖北天门人,博士,副教授,主要研究方向为电力系统运行优化与控制。E-mail:lskh2024@163.com

苏攀(1986),男,通信作者,湖北宜昌人,硕士,讲师,主要研究方向为输电线路工程。E-mail:psu2025ctgu@163.com