

DOI: 10.12158/j.2096-3203.2026.03.012

考虑新能源的暂态稳定约束多目标最优潮流建模及求解

刘颂凯^{1,2}, 时良志^{1,2}, 胡畔^{1,2,3}, 高坤⁴, 杨超^{1,2}, 万明^{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. 国网湖南省电力有限公司常德供电分公司, 湖南 常德 415130)

摘要:为应对风电和光伏不确定性给电网安全稳定运行带来的影响,同时弥补传统单目标最优潮流模型的不足,文中提出一种考虑风光不确定性的暂态稳定约束多目标最优潮流(transient stability constrained multi-objective optimal power flow, TSCMOOPF)模型及求解方法。首先,采用基于人工神经网络(artificial neural network, ANN)、深度神经网络(deep neural network, DNN)和超驱动区域失活正则化长短期记忆(surprisal-driven zoneout long short-term memory, SZLSTM)网络的集成学习方法,构建风光出力预测模型,以提高预测精度并提升模型鲁棒性。其次,综合考虑系统经济性和稳定性,建立包含有功网损最小化、燃料成本最小化和优化电压稳定指标的多目标函数,构建TSCMOOPF模型。然后,设计改进的参考向量引导进化算法(reference vector guided evolutionary algorithm, RVEA)对该模型进行求解。最后,基于改进的IEEE 39节点系统进行仿真实验。结果表明:所提集成学习方法在风光出力预测中表现优异,多目标优化模型在保证暂态稳定性的同时,可显著降低有功网损和燃料成本,并且改进后的RVEA收敛性和多样性均优于传统多目标算法。

关键词:不确定性;暂态稳定约束;多目标最优潮流;集成学习;人工神经网络;长短期记忆网络

中图分类号: TM712

文献标志码: A

文章编号: 2096-3203(2026)03-0105-11

0 引言

暂态稳定约束最优潮流(transient stability constrained optimal power flow, TSCOPF)通过寻找电力系统的稳态运行点,在满足系统的各类运行约束(如潮流平衡、有功输出约束、母线电压约束等)的同时,优化特定性能指标使其达到最优。近年来,以风能、太阳能为代表的可再生能源飞速发展,在许多国家和地区的装机容量和发电量中均占据重要地位。然而,风能和太阳能固有的间歇性和波动性,导致其发电出力存在显著不确定性,从而对电网的稳定运行构成严峻考验,如系统稳定风险增大、抵御故障及扰动的能力下降、系统成本提高等^[1-5]。此外,传统的最优潮流(optimal power flow, OPF)的目标主要是燃料成本最小化,或是为多个目标选择适当的权重因子,将多目标问题转换为单目标问题。但权重因子的选择依赖于决策者的主观判断,容易导致某些重要目标被忽视。而多目标优化可实现不同性能指标间的协调平衡,从而获得更全面的优化结果。因此,在大规模风光接入的背景下研究考虑暂态稳定约束的多目标最优潮流(transient stability constrained multi-objective optimal power flow, TSCMOOPF)问题,具有重要的理论价值和实践意义^[6-7]。

针对风光不确定性,常用的处理方法包括场景优化法^[8-9]、鲁棒优化法^[10-11]和概率潮流法^[12-13]。场景优化法的基本思想是通过离散化技术将连续的不确定性转化为一组有限场景,从而在多场景框架下进行系统运行分析与优化。文献[8]采用蒙特卡洛法生成风光出力场景,并通过 k -means聚类 and 同步回代消除技术进行场景削减,但聚类算法对初始聚类中心的选择敏感性较高。文献[9]利用核密度估计方法构建大量场景,其局限性在于对带宽参数选择的依赖性较强。鲁棒优化法通过不确定参数的范围边界描述风光不确定性,在不确定性集合中寻求最优解,以增强系统的稳定性和可靠性。文献[10]构建基于 Wasserstein 距离的风光出力预测误差模糊集的两阶段分布式鲁棒优化模型,但该模型在高维空间下的计算负担显著增加。文献[11]采用矩不确定性方法构建不确定集,虽有效降低了计算负担,但对样本质量的依赖性较强。概率潮流法则是通过概率统计描述并分析系统的随机特性。文献[12]利用半不变量法计算概率潮流,缺点是在处理高维、强非线性系统时,所需的计算量急剧增加。文献[13]提出改进三点估计法,通过增加一组正态分布尾部点提高计算的准确度,但同时也增加了运算负担。综上所述,现有方法在风光出力不确定性表征时,依赖于人工设定的参数,缺乏自适应能力,且难以有效捕捉风光出力序列中的非平稳突变特性;此外,在面对高维非线性系统时,现有

收稿日期: 2025-07-01; 修回日期: 2025-09-23

基金项目: 国家自然科学基金资助项目(52407118)

方法常面临计算精度与效率失衡的问题,难以在实际应用中取得理想效果。

针对多目标优化问题,文献[14]通过权重因子将3个目标函数转化为单目标函数,但权重因子的选取具有较强的主观性。文献[15]利用模糊熵权法实现多目标的权衡优化,但其计算过程相对复杂。文献[16]采用非劣性排序复合回溯搜索算法求解多目标优化问题,但该算法的计算负担大且算法性能对参数设置的依赖性较强。文献[17]提出一种非支配排序碰撞体优化技术,用于处理多目标OPF,并通过模糊决策方法选择最佳折中解,但其计算复杂度较高,无法实现快速求解。综上所述,现有的多目标优化方法存在计算复杂、主观性强、解的多样性不足等问题,难以有效应对复杂工程中的优化需求。

基于上述研究现状,文中针对风光接入带来的不确定性问题,以及如何同时保证系统运行的安全性和经济性展开研究,提出考虑风光不确定性的TSCMOOPF模型和求解方法,旨在权衡多个目标后优化发电策略。文中主要的创新点在于:(1)利用基于人工神经网络(artificial neural network, ANN)^[18-19]、深度神经网络(deep neural network, DNN)^[20]和超驱动区域失活正则化长短期记忆(surprisal-driven zoneout long short-term memory, SZLSTM)网络^[21-22]的集成学习方法预测风光出力;(2)同时优化有功网损、燃料成本和电压稳定指标,建立考虑新能源的TSCMOOPF新模型;(3)设计一种改进的基于参考向量引导进化算法(reference vector guided evolutionary algorithm, RVEA)以实现所提模型的高效求解。

1 新能源出力不确定性建模

随着新能源的大规模接入,风光等可再生能源出力的间歇性与随机性为电力系统的安全稳定运行带来了不确定因素^[23-25]。为了计及新型电力系统中风光出力的不确定性,开展风光出力的不确定性建模研究具有重要意义。

1.1 SZLSTM 模型

为解决传统的长短期记忆(long short-term memory, LSTM)网络预测时可能存在的过拟合问题,在LSTM中引入超驱动区域失活(surprisal-driven zoneout, SZ)正则化, SZLSTM的网络结构如图1所示。

遗忘门决定上一时刻记忆单元 c_{t-1} 中需要被丢弃的信息,取值范围为[0,1],0表示完全丢弃,1表

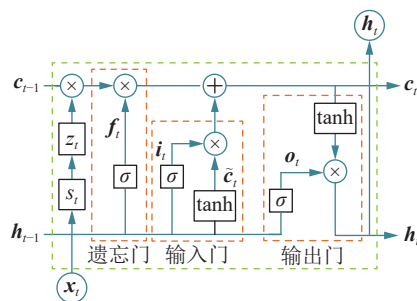


图1 SZLSTM 结构

Fig.1 SZLSTM structure

示完全保留;输入门决定当前时刻候选记忆单元 \tilde{c}_t 中需要写入当前时刻中间记忆状态 c_t 的信息。表达式为:

$$f_t = \sigma(L_{xf}x_t + L_{hf}h_{t-1} + V_f s_t + p_f) \quad (1)$$

$$i_t = \sigma(L_{xi}x_t + L_{hi}h_{t-1} + V_i s_t + p_i) \quad (2)$$

$$\tilde{c}_t = \tanh(L_{xc}x_t + L_{hc}h_{t-1} + p_c) \quad (3)$$

$$c'_t = f_t \otimes c_{t-1} + i_t \otimes \tilde{c}_t \quad (4)$$

式中: x_t 为当前时刻输入数据; h_{t-1} 为上一时刻隐含状态; f_t 、 i_t 分别为当前时刻遗忘门、输入门的输出量; L_{xf} 、 L_{hf} 、 L_{xi} 、 L_{hi} 分别为 x_t 、 h_{t-1} 到遗忘门、输入门的权重矩阵; L_{xc} 、 L_{hc} 分别为 x_t 、 h_{t-1} 到候选记忆单元的权重矩阵; V_f 、 V_i 分别为遗忘门、输入门正则化权重矩阵; p_f 、 p_i 、 p_c 分别为遗忘门、输入门、候选记忆单元的偏置向量; s_t 为遗忘门的正则化系数; $\sigma(\cdot)$ 为将输出映射到的[0,1]的Sigmoid激活函数; \otimes 为点乘运算。

通过Zoneout系数 z_t 控制 c_{t-1} 与 c'_t 之间的融合比例,得到当前时刻记忆单元 c_t ,表达式为:

$$z_t = \sigma(L_{st}s_t + p_z) \quad (5)$$

$$c_t = z_t \otimes c_{t-1} + (1 - z_t) \otimes \tilde{c}_t \quad (6)$$

式中: L_{st} 为Zoneout系数 z_t 的权重矩阵; p_z 为Zoneout系数 z_t 的偏置向量。

输出门决定当前时刻输出 o_t ,并计算得到当前时刻隐含输出 h_t ,表达式为:

$$o_t = \sigma(L_{xo}x_t + L_{ho}h_{t-1} + V_o s_t + p_o) \quad (7)$$

$$h_t = \tanh(c_t) \otimes o_t \quad (8)$$

式中: o_t 为当前时刻输出数据; L_{xo} 、 L_{ho} 分别为 x_t 、 h_{t-1} 到输出门的权重矩阵; V_o 为输出门正则化权重矩阵; p_o 为输出门的偏置向量。

1.2 集成学习预测模型

风光出力具有显著的时序依赖性,为有效处理不同场景下风光数据的依赖性,文中采用多模型集成学习的方法构建预测模型。其中,ANN和DNN模型用于捕捉风光出力与气象因素(如温度、风速、湿度等)之间的非线性关系,SZLSTM模型则专门

用于处理风光出力的时序特性。通过继承多个模型的预测结果,可有效提升预测的准确性和鲁棒性。该集成学习的系统结构如图2所示。

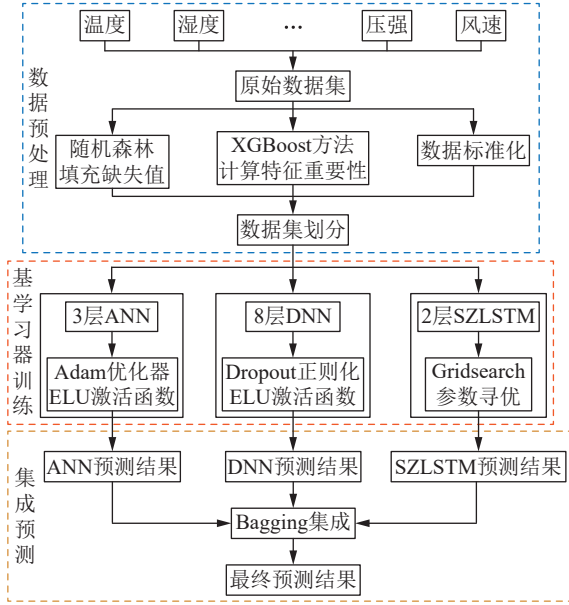


图2 集成学习系统结构

Fig.2 Ensemble learning system architecture

利用集成学习预测风光出力的具体步骤如下。

(1) 数据收集: 选取西藏某地区风电-光伏电站2024年5月8日至2024年8月8日的实测数据,构建包含约17000组风光机组历史出力的数据集,数据采样间隔为15 min。

(2) 数据清洗: 为了提升风光出力预测的准确性,需要对初始数据集进行数据清洗、缺失值填补等处理,以保证样本数据的质量。

(3) 数据标准化: 由于风光出力输入数据的单位和量纲存在差异,需要先对数据进行标准化处理,以便模型更好地学习数据的特征规律。

(4) 模型构建: 构建ANN、DNN和SZLSTM 3个不同的模型作为基模型,通过自助聚合(Bagging)集成学习方法^[26-27]将不同基模型集成,以提升预测效果。

(5) 模型训练与评估: 将数据集划分为训练集和测试集,采用测试集数据评估集成模型的预测性能。选取平均绝对误差(mean absolute error, MAE)、均方根误差(root-mean-square error, RMSE)和残差平方误差 R^2 作为评估指标,验证文中方法的有效性。

2 TSCMOOPF 模型

2.1 目标函数

(1) 有功网损。

电力系统中存在不可避免的有功功率损耗

F_1 ^[28],其表达式为:

$$F_1 = \min \sum_{r=1}^{N_L} G_r (V_i^2 + V_j^2 - 2V_i V_j \cos \delta_{ij}) \quad (9)$$

式中: N_L 为输电线路数; V_i 、 V_j 分别为线路 r 两端节点 i 、节点 j 处的电压幅值; G_r 为线路 r 的转移电导; δ_{ij} 为节点 i 和节点 j 的电压相角差。

(2) 火电机组燃料成本。

在TSCOPF问题中主要考虑的目标函数是火电机组的燃料成本 F_2 ,该成本可用实际有功输出的二次函数来表示:

$$F_2 = \min \sum_{i=1}^{N_B} [\alpha_i^G (P_i^G)^2 + \beta_i^G P_i^G + \gamma_i^G] \quad (10)$$

式中: N_B 为系统节点总数; α_i^G 、 β_i^G 、 γ_i^G 为节点 i 处火力发电机的成本系数; P_i^G 为节点 i 处火力发电机的有功功率。

(3) 电压稳定指标。

电压稳定性是电力系统长期安全稳定运行的核心指标,直接关系到系统的安全性与电能质量。为了使系统的静态电压稳定裕度最大化,增强系统应对风光功率波动引发的电压越限风险的能力,文中在目标函数中引入局部电压稳定指标。该稳定指标是判断系统全局电压稳定状态的重要参考依据^[29],其计算方式为:

$$L_j = \left| 1 - \sum_{i=1}^{N_B} F_{ji} \frac{\dot{V}_i}{\dot{V}_j} \right| \quad (11)$$

式中: L_j 为负荷节点 j 处对应的局部电压稳定指标, $j=1,2,\dots,\alpha_L$,其中 α_L 为负荷节点数; \dot{V}_i 为节点 i 处发电机复电压; \dot{V}_j 为负荷节点 j 处的复电压; F_{ji} 对应式(12)中混合矩阵 \mathbf{H} 的子矩阵中相应元素。

$$\begin{bmatrix} \mathbf{V}_L \\ \mathbf{I}_G \end{bmatrix} = \mathbf{H} \begin{bmatrix} \mathbf{I}_L \\ \mathbf{V}_G \end{bmatrix} = \begin{bmatrix} \mathbf{Z}_{LL} & \mathbf{F}_{LG} \\ \mathbf{K}_{GL} & \mathbf{Y}_{GG} \end{bmatrix} \begin{bmatrix} \mathbf{I}_L \\ \mathbf{V}_G \end{bmatrix} \quad (12)$$

式中: \mathbf{V}_L 、 \mathbf{I}_L 分别为负荷节点处的电压、电流向量; \mathbf{V}_G 、 \mathbf{I}_G 分别为发电机节点处的电压、电流向量; \mathbf{Z}_{LL} 、 \mathbf{F}_{LG} 、 \mathbf{K}_{GL} 、 \mathbf{Y}_{GG} 为混合矩阵 \mathbf{H} 的子矩阵。

将所有负荷节点的最大值定义为系统的电压稳定指标 L ,该值越小表明系统越稳定,表达式为:

$$L = \max \{L_1, L_2, \dots, L_{\alpha_L}\} \quad (13)$$

将局部电压稳定指标作为目标函数 F_3 ,表达式为:

$$F_3 = \min L \quad (14)$$

2.2 等式约束

潮流平衡等式约束可表示为:

$$\begin{cases} P_i^G + \tilde{P}_i^W + \tilde{P}_i^S - P_i^L = \\ V_i \sum_{j=1}^{N_B} V_j (G_{ij} \cos \delta_{ij} + B_{ij} \sin \delta_{ij}) \\ Q_i^G + \tilde{Q}_i^W + \tilde{Q}_i^S - Q_i^L = \\ V_i \sum_{j=1}^{N_B} V_j (G_{ij} \sin \delta_{ij} - B_{ij} \cos \delta_{ij}) \end{cases} \quad (15)$$

式中: \tilde{P}_i^W 、 \tilde{Q}_i^W 分别为节点*i*处风力发电机的不确定有功、无功功率; \tilde{P}_i^S 、 \tilde{Q}_i^S 分别为节点*i*处光伏发电机的不确定有功、无功功率; P_i^L 、 Q_i^L 分别为节点*i*处负荷的有功、无功功率; Q_i^G 为节点*i*处火力发电机的无功功率; G_{ij} 、 B_{ij} 分别为节点*i*和节点*j*之间的电导、电纳。

2.3 不等式约束

为了确保电力系统的安全可靠运行,须遵守由式(16)所示的运行上下限约束。

$$\begin{cases} \underline{V}_i \leq V_i \leq \bar{V}_i \\ \underline{P}_i^G \leq P_i^G \leq \bar{P}_i^G \\ \underline{Q}_i^G \leq Q_i^G \leq \bar{Q}_i^G \\ \underline{T}_i \leq T_i \leq \bar{T}_i \\ \underline{S}_r \leq S_r \leq \bar{S}_r \\ \underline{Q}_{Ci} \leq Q_{Ci} \leq \bar{Q}_{Ci} \end{cases} \quad (16)$$

式中: T_i 为节点*i*处变压器变比, \underline{T}_i 、 \bar{T}_i 分别为该变量的下限和上限; S_r 为线路*r*的传输功率, \underline{S}_r 、 \bar{S}_r 分别为该变量的下限和上限; Q_{Ci} 为节点*i*处无功补偿装置的无功输出, \underline{Q}_{Ci} 、 \bar{Q}_{Ci} 分别为该变量的下限和上限; \underline{V}_i 、 \bar{V}_i 分别为节点*i*处电压幅值的下限和上限; \underline{P}_i^G 、 \bar{P}_i^G 分别为节点*i*处火力发电机有功功率的下限和上限; \underline{Q}_i^G 、 \bar{Q}_i^G 分别为节点*i*处火力发电机无功功率的下限和上限。

此外,风光机组的有功和无功功率输出也存在不等式约束,表示为:

$$\begin{cases} 0 \leq \tilde{P}_i^W \leq \bar{P}_i^W \\ \underline{Q}_i^W \leq \tilde{Q}_i^W \leq \bar{Q}_i^W \\ 0 \leq \tilde{P}_i^S \leq \bar{P}_i^S \\ \underline{Q}_i^S \leq \tilde{Q}_i^S \leq \bar{Q}_i^S \end{cases} \quad (17)$$

2.4 暂态稳定约束

暂态稳定性是指电力系统在受到大规模扰动后,能够在短时间内恢复到稳定运行状态的能力。由于暂态失稳具有不可逆性,且可能引发灾难性后果,因此文中依据电力系统安全运行的“N-1”原则,将暂态稳定约束作为不可松弛的硬性约束,以提升系统的鲁棒性,保障电网运行的动态安全。该约束通过限制故障清除后发电机转子相对功角差的振

荡幅度,进一步确保系统的动态安全性,其数学表述为:

$$\begin{cases} \varphi_{i,0} - \varphi_{COL,t} \leq \bar{\varphi} \\ \varphi_{i,t} - \varphi_{COL,t} \leq \bar{\varphi} \end{cases} \quad (18)$$

$$\varphi_{COL,t} = \frac{\sum_{i=1}^{N_B} M_i \varphi_{i,t}}{\sum_{i=1}^{N_B} M_i} \quad (19)$$

式中: M_i 为节点*i*处发电机的惯性常数; $\varphi_{i,0}$ 为故障清除瞬间节点*i*处发电机的转子角; $\varphi_{i,t}$ 为*t*时刻节点*i*处发电机的转子角; $\varphi_{COL,t}$ 为*t*时刻的惯性中心角度; $\bar{\varphi}$ 为各发电机转子相对惯性中心的角度差极限值,文中取该值为120°以确保暂态稳定。

3 优化模型求解

3.1 改进的 RVEA

考虑到模型的高度非线性与非凸性,需要同时优化多个相互冲突的目标,包含大量等式、不等式和暂态稳定约束,因此文中采用改进的RVEA解决这一具有复杂约束条件的多目标优化问题。在原RVEA中,角度压力参数为固定值,易导致算法前期收敛性不足或后期多样性丢失;且原算法仅对一定比例的个体进行局部搜索,极易导致算法难以跳出局部最优。针对这2个问题,文中引入自适应角度压力参数,并采用增强局部搜索的策略改进原算法。改进后的算法通过自适应调整角度压力和参考向量的更新频率,能够实现Pareto前沿解集的高效搜索,并保证解集的多样性。

(1) 自适应角度压力调整机制。文中提出如式(20)所示的自适应角度压力调整策略,在迭代初期,角度压力 $\alpha(d)$ 保持较低值,允许个体与参考向量间存在较大角度差异,从而促进种群多样性;随着迭代进行, $\alpha(d)$ 呈非线性递增,促使个体向Pareto前沿收敛。

$$\alpha(d) = \alpha_{\min} + (\alpha_{\max} - \alpha_{\min}) \left(\frac{d}{D} \right)^\chi \quad (20)$$

式中: d 为当前迭代次数; D 为总迭代次数; α_{\min} 、 α_{\max} 分别为角度压力的下限、上限,分别取0.5、4; χ 为指数因子,默认取2。

(2) 目标值归一化。为消除多目标尺度差异带来的影响,需要对当前种群的目标函数值进行归一化处理,归一化公式为:

$$C_{\text{Nor},g} = \frac{C_g - P_{\text{ideal}}}{P_{\text{nadir}} - P_{\text{ideal}}} \quad (21)$$

式中: $C_{\text{Nor},g}$ 为当前种群中第*g*个个体归一化后的目标

函数值; C_g 为当前种群中第 g 个个体的原始目标函数值; P_{ideal} 、 P_{nadir} 分别为当前种群中的最优、最劣解。

(3) 角度惩罚距离 (angle penalty distance, APD) 机制。基于归一化目标值与自适应角度压力参数, 构建改进的 APD 为:

$$\zeta_{\text{APD}} = \|\mathbf{f}\| (1 + \alpha(t) \sin \theta) \quad (22)$$

式中: ζ_{APD} 为角度惩罚距离; $\|\mathbf{f}\|$ 为归一化目标向量的范数; θ 为目标向量与参考向量的角度。

(4) 增强局部搜索策略。为避免原算法局部搜索效率不足, 引入自适应扰动步长, 对当前非支配解集中的个体施加高斯扰动, 步长 $\tau(d)$ 迭代递减, 如式 (23) 所示; 此外对于历史存档中连续 3 代未被支配的解, 采用更精细的搜索半径 $\tau_{\text{elite}}(d) = 0.1\tau(d)$ 进行搜索。

$$\tau(d) = \tau_{\text{init}} e^{-\lambda \frac{d}{D}} \quad (23)$$

式中: τ_{init} 为初始步长, 取目标变量范围的 10%; λ 为衰减系数, 取值为 4。

(5) 交叉与变异。对未进行局部搜索的个体采用模拟二进制交叉和多项式变异操作生成新个体。其中, 交叉操作是通过融合 2 个父代个体的特征, 生成新的子代解决方案; 变异操作则是随机改变个体的部分决策变量, 从而增强种群多样性。

3.2 最优调和解

在得到 Pareto 解集后, 确定最优调和解是进行决策的关键。文中使用模糊集理论确定最优调和解, 针对第 p 个解的第 q 个目标函数, 定义其隶属度函数 ω_{pq} 的数学表达式为:

$$\omega_{pq} = \begin{cases} 1 & f_{pq} < f_{q,\min} \\ \frac{f_{q,\max} - f_{pq}}{f_{q,\max} - f_{q,\min}} & f_{q,\min} \leq f_{pq} \leq f_{q,\max} \\ 0 & f_{pq} > f_{q,\max} \end{cases} \quad (24)$$

式中: f_{pq} 为第 p 个解的第 q 个目标函数值; $f_{q,\min}$ 、 $f_{q,\max}$ 分别为第 q 个目标的最小值、最大值。

隶属度函数值越高, 表示该方案相较于其他方案的满意度越高。每个非支配解的归一化隶属度函数 ω_p 可表示为:

$$\omega_p = \frac{\sum_{q=1}^{n_{\text{dim}}} \omega_{pq}}{\sum_{p=1}^{n_{\text{pf}}} \sum_{q=1}^{n_{\text{dim}}} \omega_{pq}} \quad (25)$$

式中: n_{dim} 为目标函数的数量; n_{pf} 为非支配解的个数。归一化隶属度函数值 ω_p 最大的解即为最优调和解。

3.3 模型求解流程

考虑新能源的 TSCMOOPF 模型求解流程如

图 3 所示, 具体步骤如下。

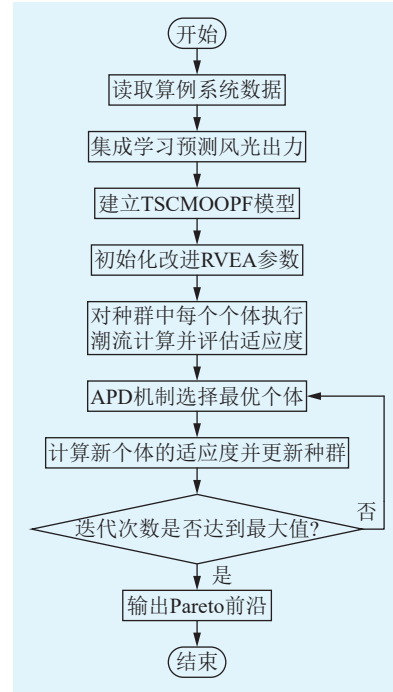


图 3 TSCMOOPF 模型求解流程

Fig.3 Flowchart for solving the TSCMOOPF model

步骤 1: 读取算例系统中的节点、支路、发电机、变压器、负荷及风光机组的预测输出功率数据, 指定控制变量与状态变量的上下界, 选择待优化的目标函数。

步骤 2: 初始化改进 RVEA 算法的参数, 包括种群规模、最大迭代次数、非支配解集大小、角度压力参数等; 根据决策变量的约束条件, 使用拉丁超立方采样方法初始化种群, 并对每个个体执行潮流计算, 评估相应的适应度值。

步骤 3: 计算当前种群中的归一化目标值, 关联参考向量与个体, 基于 APD 机制选择最优个体, 生成新一代种群。

步骤 4: 更新种群后, 若生成的随机数小于局部搜索的概率, 则随机选择一个父代个体并在其当前位置添加一个随机噪声, 噪声大小由决策变量的上下界约束; 若没有进行局部搜索, 则进行交叉和变异操作。

步骤 5: 计算新个体的适应度值并将其添加到新种群中, 根据种群中的支配关系更新非支配解集, 并使用拥挤度距离进行解的筛选。

步骤 6: 重复步骤 3—步骤 5, 直至达到最大迭代次数, 最终输出 Pareto 前沿。

4 算例分析

文中通过引入风电和光伏机组, 对 IEEE 39 节

点系统进行改进。改进的系统如图 4 所示,将系统中节点 32 和节点 34 的常规发电机分别替换成额定容量 725 MW 的风电机组和额定容量 568 MW 的光伏机组,系统的总有功、无功负荷分别为 6 254.23 MW 和 1 486.50 MVar。设置仿真时间为 10 s,仿真步长为 0.01 s。假设在 0.1 s 时,母线 4 附近发生三相短路故障,0.27 s 时切除节点 4 和节点 14 之间的线路后故障清除,分别采用改进 RVEA、多目标粒子群优化(multi-objective particle swarm optimization, MOPSO)和 RVEA 对以下 3 种多目标场景进行仿真验证。场景 1:有功网损与燃料成本最小化;场景 2:燃料成本与电压稳定指标最小化;场景 3:有功网损、燃料成本和电压稳定指标最小化。

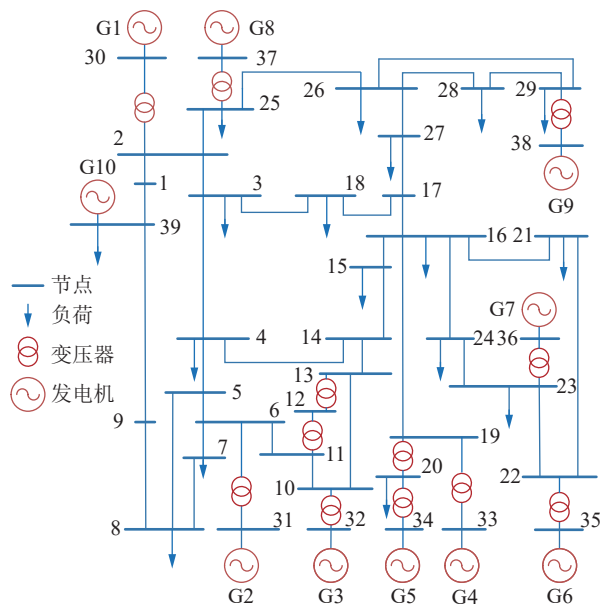


图 4 改进的 39 节点测试系统模型
Fig.4 Improved 39-bus test system model

4.1 风光预测结果

文中采用基于 ANN、DNN 和 SZLSTM 的集成学习方法,处理风光不确定性。基模型的激活函数为修正线性单元(rectified linear unit, ReLU),优化函数为 Adam 函数,迭代次数为 100。

为验证文中所提模型的预测性能,将其与 LSTM、ANN-DNN-LSTM 集成模型开展风电出力预测效果对比,分别采用这 3 种模型对风电出力进行预测。3 种模型在 200 个测试集样本上的预测值与实际值如图 5 所示,文中所提集成模型能够较为精准地捕捉风电输出的总体趋势和波动特征,比 ANN-DNN-LSTM 集成模型预测精度更高,LSTM 模型预测误差则相对最大。

同样使用 3 种模型对光伏电站出力进行预测,预测结果如图 6 所示。由图可知,LSTM 模型的预




图 5 风电出力预测结果

Fig.5 Wind power output prediction results

测曲线波动最大,与实际值偏离较明显;ANN-DNN-LSTM 集成模型的预测结果能够捕捉总体趋势,但在部分采样点出现较大偏差,波动性较强。这主要是因为传统 LSTM 模型缺乏正则化机制,易过拟合;而文中所提 ANN-DNN-SZLSTM 集成模型的预测结果不仅更接近实际值,还表现出较好的稳定性。

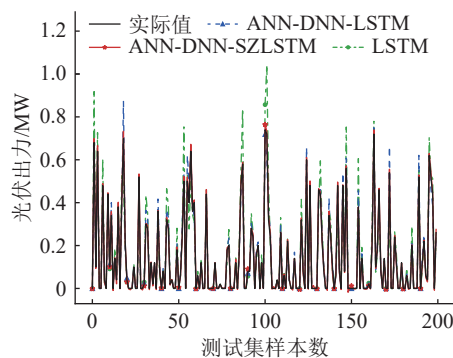


图 6 光伏出力预测结果

Fig.6 Photovoltaic power output prediction results

3 种模型针对光伏出力预测的评估指标结果如表 1 所示。由表可知,LSTM 模型的各项评估指标最差,ANN-DNN-LSTM 集成学习模型效果略优,而文中所提 ANN-DNN-SZLSTM 集成模型的各项评估指标均为最优。该结果进一步验证了通过 SZ 正则化改进后的模型能够有效提升光伏出力的预测精度和稳定性。

表 1 不同模型的评估指标结果

Table 1 Evaluation index results of different models

预测模型	MAE/MW	RMSE/MW	R ²
LSTM	0.187 3	0.369 2	0.85
ANN-DNN-LSTM	0.072 5	0.168 8	0.90
ANN-DNN-SZLSTM	0.049 8	0.119 6	0.92

4.2 模型优化结果

(1) 场景 1。在场景 1 中,使用 3 种算法同时优化有功网损与火电机组的燃料成本。从图 7 中的 Pareto 前沿分布可看出:改进 RVEA 得到的解集在目标空间中呈现显著的权衡特性。当有功网损从

36 MW 增至 50 MW 时, 燃料成本从 264 000 元/h 降至 241 000 元/h。降低网损需以燃料成本上升为代价, 改进 RVEA 则有效平衡了二者的冲突。此外, 与 MOPSO 和原始 RVEA 相比, 改进 RVEA 解集覆盖范围更广且分布均匀性更佳, 算法的收敛性和多样性表现最优。

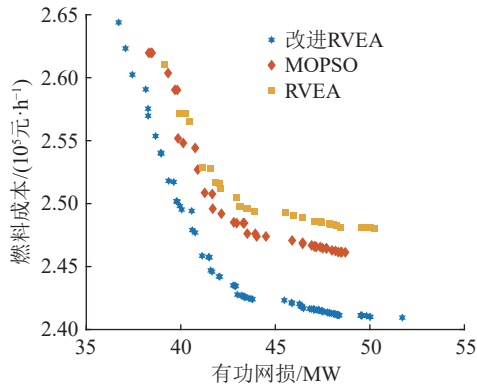


图7 场景1的 Pareto 前沿
Fig.7 Pareto frontier for scenario 1

附录 A 表 A1 中列出了改进的 IEEE 39 节点系统的初始场景数据。初始场景下有功网损为 45.897 2 MW, 燃料成本为 271 177.441 5 元/h; 场景 1 下最优有功网损和燃料成本分别为 43.361 4 MW 和 242 614.423 2 元/h。与初始场景相比, 场景 1 下最优方案的有功网损和燃料成本分别降低了 5.525 0% 和 10.533 0%。

为比较文中所提 TSCMOOPF 模型和未考虑暂态稳定约束的 OPF 模型在含风光接入系统上的暂态稳定性能差异, 在场景 1 中先建立仅考虑静态安全约束的模型, 并使用文中所提算法优化求解得到的 Pareto 解集。其中部分优化方案在相同的故障情况下会出现如图 8 所示的失稳现象: 故障后的发电机功角在短时间内迅速增大, 此时系统处于严重失稳状态。采用文中所提 TSCMOOPF 模型优化后, 各发电机的功角如图 9 所示, 可以看出各发电机转子相对惯性中心的角度差低于极限值 120° , 验证了文中所提方案能够有效保障系统的暂态稳定性。

(2) 场景 2。场景 2 以最小化燃料成本与电压稳定指标为目标函数, 得到的 Pareto 前沿结果如图 10 所示。由图可知, 2 个目标之间呈现显著负相关, 且改进 RVEA 的优化结果略优于其他算法。场景 2 的最优调和结果见附录 A 表 A1, 初始场景下燃料成本和电压稳定指标分别为 271 177.441 5 元/h 和 0.189 5 p.u., 优化后分别降至 250 827.690 8 元/h 和 0.181 2 p.u., 分别降低了 7.504 2% 和 4.379 9%, 该方案的发电机功角如图 11 所示。




图8 场景1的 OPF 优化后的失稳功角图
Fig.8 OPF optimized unstable power angle for scenario 1




图9 场景1的 TSCMOOPF 优化后的功角
Fig.9 TSCMOOPF optimized power angle for scenario 1

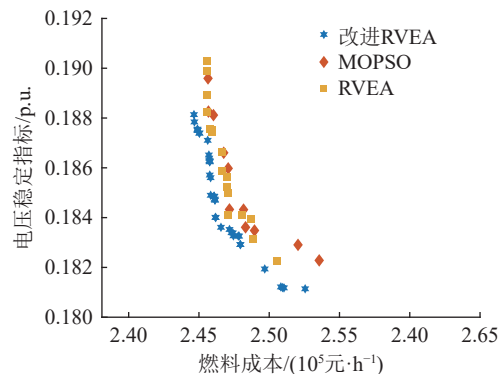


图10 场景2的 Pareto 前沿
Fig.10 Pareto frontier for scenario 2

(3) 场景 3。为进一步验证求解方法的性能及有效性, 场景 3 针对有功网损、火电机组燃料成本和电压稳定指标 3 个目标开展多目标最小化优化, 生成的 Pareto 前沿如图 12 所示。由图可见 3 个优化目标之间呈现复杂的三维权衡关系, 且改进 RVEA 的收敛性和多样性更优。该场景下最优调和解的各项指标结果为: 有功网损 43.066 9 MW、燃料成本 254 221.919 3 元/h、电压稳定指标 0.196 9 p.u.。与初始场景相比, 有功网损和燃料成本分别降低了




图 11 场景 2 的 TSCMOOPF 优化后的功角
Fig.11 TSCMOOPF optimized power angle for scenario 2

6.166 6%、6.252 6%，电压稳定指标上升了 3.905 0%。该方案虽然使电压稳定指标略有上升，但实现了有功网损和燃料成本的大幅降低，并且在所设置的故障情况下，系统能够保持暂态稳定。该方案的发电机功角如图 13 所示，控制变量和目标函数结果见附录 A 表 A1。

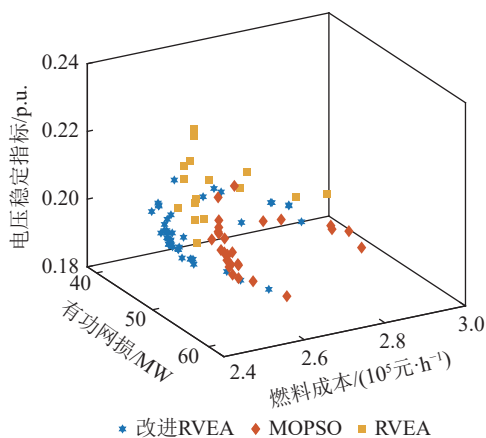


图 12 场景 3 的 Pareto 前沿
Fig.12 Pareto frontier for scenario 3




图 13 场景 3 的 TSCMOOPF 优化后的功角
Fig.13 TSCMOOPF optimized power angle for scenario 3

4.3 多目标优化算法性能比较

为比较 3 种多目标优化算法的性能，文中采用

超体积(hypervolume, HV)指标对 Pareto 最优解集所覆盖的目标空间体积进行计算。HV 指标值越大，表明 Pareto 前沿的收敛性和多样性越好。3 个场景下不同算法 Pareto 前沿的 HV 值如表 2 所示。

表 2 不同算法的 HV 指标对比
Table 2 Comparison of HV indicator of different algorithms

场景	HV值		
	改进RVEA	MOPSO	RVEA
场景1	0.023 2	0.008 8	0.008 4
场景2	0.004 2	0.001 4	0.000 2
场景3	0.005 6	0.002 2	0.001 8

由表 2 可知，在 3 个场景下，改进 RVEA 算法均取得最高的 HV 值，表明其 Pareto 前沿的收敛性和多样性均优于 MOPSO 和 RVEA。在场景 1 中，改进 RVEA 的 HV 值 0.023 2 远高于 MOPSO 的 0.008 8 和 RVEA 的 0.008 4；在场景 2 和场景 3 中，改进 RVEA 的 HV 值分别为 0.004 2、0.005 6，MOPSO 算法的表现次之，而 RVEA 的 HV 值在 3 个场景中均为最低。上述数据表明，相较于传统 RVEA 和 MOPSO 算法，文中所提改进 RVEA 在不同场景下均能生成更高质量的 Pareto 解集，在求解考虑新能源的 TSCMOOPF 问题时具备显著优势。

3 个场景下最优调和解的 29 个负荷节点电压幅值如图 14 所示，由图可知负荷节点的电压幅值均在 0.94~1.06 p.u.之间，进一步证明了文中方法的有效性。




图 14 3 个场景最优调和解的负荷节点电压
Fig.14 Load bus voltage values of the best compromise solution for the three scenarios

5 结论

文中针对风光接入带来的不确定性问题，为兼顾系统运行的安全性与经济性，提出一种考虑风光不确定性的 TSCMOOPF 模型及求解方法。通过改进的 IEEE 39 节点测试系统分析验证，最终得出如

下结论:

(1) 利用基于 ANN、DNN 和 SZLSTM 的集成学习方法预测风光出力, 通过 SZ 正则化改进的 LSTM 得到更准确、可靠的预测结果。

(2) 以有功网损、燃料成本和电压稳定指标为优化目标, 设计 3 个多目标优化场景, 并建立 TSC-MOOPF 新模型, 兼顾系统的环保性、经济性和稳定性。

(3) 使用改进 RVEA 对 3 个不同的多目标场景进行求解, 并以改进的 IEEE 39 节点系统作为测试平台。仿真结果表明, 改进 RVEA 在收敛性与多样性方面均优于传统多目标算法。

当前研究工作聚焦于验证单一高风险预设故障场景下方法的有效性与工程指导意义。虽然模型框架本身具备扩展能力, 但考虑的故障数量增加时, 将不可避免地增加其计算复杂度。未来研究将重点探索高效故障筛选策略和并行计算技术, 以提升模型在多故障场景下的计算效率, 进而为在线辅助决策提供更有力的支撑。

致谢

本文得到梯级水电站运行与控制湖北省重点实验室(三峡大学)开放基金课题(2023KJX06)资助, 谨此致谢!

附录见本刊网络版, 可点击 <https://www.epet-info.com/dlgsj/article/abstract/250301171>, 阅读全文。

参考文献:

- [1] 周孝信, 赵强, 张玉琼, 等. “双碳”目标下我国能源电力系统发展趋势分析: 绿电替代与绿氢替代[J]. *中国电机工程学报*, 2024, 44(17): 6707-6721.
ZHOU Xiaoxin, ZHAO Qiang, ZHANG Yuqiong, et al. Analysis of the development trend of China's energy and power system under the dual carbon target: green electricity substitution and green hydrogen substitution[J]. *Proceedings of the CSEE*, 2024, 44(17): 6707-6721.
- [2] 周孝信, 陈树勇, 鲁宗相, 等. 能源转型中我国新一代电力系统的技术特征[J]. *中国电机工程学报*, 2018, 38(7): 1893-1904.
ZHOU Xiaoxin, CHEN Shuyong, LU Zongxiang, et al. Technology features of the new generation power system in China[J]. *Proceedings of the CSEE*, 2018, 38(7): 1893-1904.
- [3] 甘艳, 黄菁雯, 吴军, 等. 含风电光伏电力系统概率潮流计算改进方法研究[J]. *电力科学与技术学报*, 2023, 38(5): 34-43.
GAN Yan, HUANG Jingwen, WU Jun, et al. Research on probabilistic power flow calculation improvement method of power system including wind and photovoltaic power generation[J]. *Journal of Electric Power Science and Technology*, 2023, 38(5): 34-43.
- [4] 刘哲, 唐成鹏, 周青, 等. 新型电力系统建设环境下的“西电东送”发展研究[J]. *广东电力*, 2023, 36(9): 26-33.
LIU Zhe, TANG Chengpeng, ZHOU Qing, et al. Research on development of west-to-east power transmission under the environment of new power system construction[J]. *Guangdong Electric Power*, 2023, 36(9): 26-33.
- [5] 鲍颜红, 张金龙, 衣立东, 等. 含大规模风电电力系统的安全稳定风险预防控制方法[J]. *电力系统自动化*, 2022, 46(13): 187-194.
BAO Yanhong, ZHANG Jinlong, YI Lidong, et al. Prevention and control method of security and stability risk for power system with large-scale wind power integration[J]. *Automation of Electric Power Systems*, 2022, 46(13): 187-194.
- [6] 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 uncertainties[J]. *Proceedings of the CSU-EPSCA*, 2024, 36(7): 1-10.
- [7] 陈萍, 党喜, 刘龙成, 等. 考虑风光不确定性的暂态稳定约束最优潮流模型研究[J]. *智慧电力*, 2024, 52(3): 17-24.
CHEN Ping, DANG Xi, LIU Longcheng, et al. Transient stability constrained optimal power flow model considering uncertainty of wind and photovoltaic output[J]. *Smart Power*, 2024, 52(3): 17-24.
- [8] 米阳, 赵海辉, 付起欣, 等. 考虑风光不确定与碳交易的区域综合能源系统双层博弈优化运行[J]. *电网技术*, 2023, 47(6): 2174-2184.
MI Yang, ZHAO Haihui, FU Qixin, et al. Two-level game optimal operation of regional integrated energy system considering wind and solar uncertainty and carbon trading[J]. *Power System Technology*, 2023, 47(6): 2174-2184.
- [9] 赵书强, 赵蓬飞, 韦子瑜, 等. 数据驱动下考虑多预测误差带信息的多场景随机优化调度[J]. *电力自动化设备*, 2024, 44(11): 52-59.
ZHAO Shuqiang, ZHAO Pengfei, WEI Ziyu, et al. Multi-scenario stochastic optimal scheduling considering multi-prediction error band information under data-driven[J]. *Electric Power Automation Equipment*, 2024, 44(11): 52-59.
- [10] 孙晶琪, 王愿, 郭晓慧, 等. 考虑环境外部性和风光出力不确定性的虚拟电厂运行优化[J]. *电力系统自动化*, 2022, 46(8): 50-59.
SUN Jingqi, WANG Yuan, GUO Xiaohui, et al. Optimal operation of virtual power plant considering environmental externality and output uncertainty of wind and photovoltaic power[J]. *Automation of Electric Power Systems*, 2022, 46(8): 50-59.
- [11] ALISMAIL F, XIONG P, SINGH C. Optimal wind farm allocation in multi-area power systems using distributionally robust optimization approach[J]. *IEEE Transactions on Power Systems*, 2018, 33(1): 536-544.
- [12] 许礼彬, 廖星星. 计及新能源出力不确定性的配电网概率潮

- 流分析[J]. *江西电力*, 2024, 48(1): 49-52, 67.
- XU Libin, LIAO Xingxing. Probabilistic power flow analysis of distribution network considering uncertainty of new energy output[J]. *Jiangxi Electric Power*, 2024, 48(1): 49-52, 67.
- [13] 赵真, 袁旭峰, 徐玉韬, 等. 一种改进三点估计法的概率潮流计算方法[J]. *南方电网技术*, 2020, 14(11): 43-48.
- ZHAO Zhen, YUAN Xufeng, XU Yutao, et al. An improved three-point estimate method for probability load flow calculation[J]. *Southern Power System Technology*, 2020, 14(11): 43-48.
- [14] 程昭龙, 李鸿奎, 李福建, 等. 考虑风电光伏出力不确定性的多目标最优潮流[J]. *自动化技术与应用*, 2021, 40(10): 11-16.
- CHENG Zhaolong, LI Hongkui, LI Fujian, et al. Multi objective optimal power flow based on wind power photovoltage output uncertainty[J]. *Techniques of Automation and Applications*, 2021, 40(10): 11-16.
- [15] 邱明晋, 陈璟华, 唐俊杰. 含风电场的电力系统多目标最优潮流研究[J]. *黑龙江电力*, 2018, 40(1): 6-12.
- QIU Mingjin, CHEN Jinghua, TANG Junjie. Study on multi-objective optimal power flow of wind power system[J]. *Heilongjiang Electric Power*, 2018, 40(1): 6-12.
- [16] 温泽之, 彭春华, 孙惠娟. 计及风电置信风险成本的多目标最优潮流计算[J]. *电力系统保护与控制*, 2020, 48(24): 36-43.
- WEN Zezhi, PENG Chunhua, SUN Huijuan. Multi-objective optimal power flow calculation considering wind power confidence risk cost[J]. *Power System Protection and Control*, 2020, 48(24): 36-43.
- [17] PULLURI H, RAO K V G, SRIRAM C, et al. Multiobjective optimal power flow solutions using nondominated sorting colliding bodies optimization[J]. *Scientific Reports*, 2024, 14: 26593.
- [18] KIM J, SHIN H J, LEE K, et al. Enhancement of ANN-based wind power forecasting by modification of surface roughness parameterization over complex terrain[J]. *Journal of Environmental Management*, 2024, 362: 121246.
- [19] FINAMORE A R, CALDERARO V, GALDI V, et al. Improving wind power generation forecasts: a hybrid ANN-clustering-PSO approach[J]. *Energies*, 2023, 16(22): 7522.
- [20] BELLETRECHE M, BAILEK N, ABOTALEB M, et al. Hybrid attention-based deep neural networks for short-term wind power forecasting using meteorological data in desert regions[J]. *Scientific Reports*, 2024, 14: 21842.
- [21] 李尊, 张小科, 张少峰, 等. 基于改进 LSTM 的风电功率预测因素分析[J]. *计算机仿真*, 2024, 41(10): 63-68, 143.
- LI Zun, ZHANG Xiaoke, ZHANG Shaofeng, et al. Analysis of wind power prediction based on modified LSTM[J]. *Computer Simulation*, 2024, 41(10): 63-68, 143.
- [22] LIU J G, WANG J B, YU L, et al. Short-term prediction of offshore wind power based on CNN and LSTM[J]. *Journal of Physics: Conference Series*, 2024, 2896(1): 012048.
- [23] 司方远, 张宁, 韩英华, 等. 面向多元灵活资源聚合的区域综合能源系统主动调节能力评估与优化: 关键问题与研究架构[J]. *中国电机工程学报*, 2024, 44(6): 2097-2119.
- SI Fangyuan, ZHANG Ning, HAN Yinghua, et al. Fundamental problems and research framework for assessment and optimization of the functional regulation capacity of the regional integrated energy system under the aggregation of diversified and flexible resources[J]. *Proceedings of the CSEE*, 2024, 44(6): 2097-2119.
- [24] 李欣, 陈英彰, 李涵文, 等. 考虑碳交易的电-热综合能源系统两阶段鲁棒优化低碳经济调度[J]. *电力建设*, 2024, 45(6): 58-69.
- LI Xin, CHEN Yingzhang, LI Hanwen, et al. Two-stage robust optimization of low-carbon economic dispatch for electricity-thermal integrated energy system considering carbon trade[J]. *Electric Power Construction*, 2024, 45(6): 58-69.
- [25] 范宏, 李婷, 严嘉鑫, 等. 基于按需比例分配机制的风光火氢多时间尺度协同规划[J]. *电力工程技术*, 2024, 43(2): 33-43.
- FAN Hong, LI Ting, YAN Jiaxin, et al. Multi-timescale coordinated planning for wind-photovoltaic-thermal-hydrogen based on a demand proportional allocation mechanism[J]. *Electric Power Engineering Technology*, 2024, 43(2): 33-43.
- [26] 汪颖, 陈春林, 肖先勇. 电压暂降源异质堆叠集成学习识别法[J]. *电力系统保护与控制*, 2021, 49(15): 1-8.
- WANG Ying, CHEN Chunlin, XIAO Xianyong. Heterogeneous stacking integrated learning identification method for voltage sag sources[J]. *Power System Protection and Control*, 2021, 49(15): 1-8.
- [27] CHOI S, HUR J, CHOI S, et al. An ensemble learner-based bagging model using past output data for photovoltaic forecasting[J]. *Energies*, 2020, 13(6): 1438.
- [28] 谢开贵, 肖畅. 计及负荷不确定性的无功优化模型与算法[J]. *电力系统保护与控制*, 2011, 39(4): 18-22, 29.
- XIE Kaigui, XIAO Chang. A reactive power optimization model and algorithm considering load uncertainty[J]. *Power System Protection and Control*, 2011, 39(4): 18-22, 29.
- [29] 吴亚宁, 罗毅, 雷成, 等. 基于改进型 PEM 和 L 指标的含风电场电力系统静态电压稳定评估[J]. *中国电力*, 2022, 55(9): 192-203.
- WU Yaning, LUO Yi, LEI Cheng, et al. Steady-state voltage stability evaluation of power system containing wind farm based on improved PEM and L index[J]. *Electric Power*, 2022, 55(9): 192-203.

作者简介:



刘頌凯

刘頌凯(1990),男,博士,副教授,研究方向为电力系统运行优化与控制(E-mail: lskhk2024@163.com);

时良志(2000),男,硕士在读,研究方向为电力系统运行优化与控制;

胡畔(1989),男,博士,高级工程师,从事电力系统稳定分析及控制工作。

Modeling and solution of transient stability constrained multi-objective optimal power flow considering renewable energy

LIU Songkai^{1,2}, SHI Liangzhi^{1,2}, HU Pan^{1,2,3}, GAO Kun⁴, YANG Chao^{1,2}, WAN Ming^{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 Co., Ltd. Research Institute, Wuhan 430077, China;

4. Changde Power Supply Branch of State Grid Hunan Electric Power Co., Ltd., Changde 415130, China)

Abstract: In order to cope with the impact of wind power and photovoltaic uncertainty on the safe and stable operation of the power grid and to make up for the shortcomings of the traditional single-objective optimal power flow model, a transient stability constrained multi-objective optimal power flow (TSCMOOPF) model and a solution method are proposed to take into account the wind and solar uncertainty. Firstly, an ensemble learning method based on artificial neural network (ANN), deep neural network (DNN) and surprisal-driven zoneout long short-term memory (SZLSTM) are adopted to construct a wind and photovoltaic output prediction model to improve the prediction accuracy and robustness. Secondly, considering the economy and stability of the system, a multi-objective function including the minimization of active network loss, the minimization of fuel cost, and the optimization of the voltage stability index is established to construct a TSCMOOPF model. Then, an improved reference vector guided evolutionary algorithm (RVEA) is designed for the solution. Finally, simulation experiments are carried out on the improved IEEE 39-bus system. The results show that the proposed ensemble learning method performs well in wind and photovoltaic output prediction, the multi-objective optimization model ensures transient stability while active network loss and fuel cost are reduced significantly, and the improved RVEA algorithm is better than the traditional multi-objective algorithm in terms of convergence and diversity.

Keywords: uncertainty; transient stability constraints; multi-objective optimal power flow; ensemble learning; artificial neural network; long short-term memory network

(编辑 彭子祎)

(上接第 62 页)

User satisfaction optimization of power wireless sensor networks based on the D3QN algorithm

YANG Jinggang¹, HU Chengbo¹, ZHU Xueqiong¹, WANG Zhen¹, LIU Hong², LI Hui²

(1. State Grid Jiangsu Electric Power Co., Ltd. Research Institute, Nanjing 211103, China;

2. Shanghai Institute of Microsystem and Information Technology, Chinese Academy of Science, Shanghai 200050, China)

Abstract: In power wireless sensor networks (PWSNs), concurrent uplink access by multiple users is constrained by limited spectrum and power resources, while heterogeneous monitoring services exhibit markedly different requirements in terms of reliability and latency. These factors make it challenging for resource scheduling to simultaneously satisfy overall system efficiency and user-perceived quality. In this work, a joint resource allocation mechanism capable of providing differentiated quality-of-service guarantees under heterogeneous service demands is formulated within an uplink orthogonal frequency division multiplexing (OFDM) framework. A quantifiable user-satisfaction function is designed, and the joint optimization of subcarrier and power allocation is modeled as a Markov decision process (MDP). A dueling double deep Q network (D3QN) algorithm is further introduced to dynamically adjust the allocation strategy. In addition, an action-space down-sampling mechanism is proposed to reduce computational complexity and enhance training efficiency. Simulation results demonstrate that the proposed algorithm achieves fast convergence under various node densities and subcarrier configurations, and yields significant improvements in user satisfaction compared with conventional DQN, random allocation, and uniform allocation methods.

Keywords: power wireless sensor network (PWSN); orthogonal frequency division multiplexing (OFDM); user satisfaction; resource allocation; dueling double deep Q-network (D3QN); reinforcement learning

(编辑 方晶)