

基于风光荷预测与 DFT-MP-DBN 建模的主动配电网可靠性评估^{*}

牟晋麟 杨超

(贵州大学电气工程学院 贵阳 550025)

摘要: 随着分布式能源的快速发展,准确预测分布式能源的出力成为了配电网可靠性评估的重要组成部分,为提高配电网可靠性评估准确性,本文提出了一种融合 VMD-QRCNN-BiLSTM 预测与 DFT-MP-DBN 建模的主动配电网可靠性评估方法。首先通过变分模态分解将原始风光荷时间序列分解为固有模态分量,并采用分位数回归卷积神经网络对风光出力以及负荷进行特征提取;而后使用双向长短期记忆相结合建模各变量的时间序列特征,并生成预测值;其次预测值作为动态故障树的输入,并采用连续时间马尔可夫链,并获取状态转移率矩阵;最后采用动态贝叶斯网络刻画状态的时序依赖,并加入观测或控制变量。以 IEEE RBTS Bus 2 系统为例,实验结果表明,所提方法的 SAIFI、SAIDI、AENS 和 ASAI 指标分别为 0.231 次/户/年、3.496 小时/户/年、17.465 kWh/年和 99.943%,显著优于传统方法,验证了其在提高配电网可靠性评估精度和效率方面的有效性。

关键词: 配电网可靠性评估;风光荷预测;DFT-MP-DBN;VMD-QRCNN-BiLSTM

中图分类号: TM73; TN91 文献标识码: A 国家标准学科分类代码: 470.4099

Active distribution network reliability assessment based on wind and light load prediction and DFT-MP-DBN modelling

Mou Jinlin Yang Chao

(Department of Electrical Engineering, Guizhou University, Guiyang 550025, China)

Abstract: With the rapid development of distributed energy resources, accurate prediction of their output has become a critical component in the reliability assessment of distribution networks. To enhance the accuracy of such assessments, this paper proposes a reliability evaluation method for active distribution networks that integrates VMD-QRCNN-BiLSTM-based forecasting with DFT-MP-DBN modeling. First, the original time series data of wind power, solar power, and load are decomposed into intrinsic mode components using Variational Mode Decomposition (VMD). Then, a Quantile Regression Convolutional Neural Network (QRCNN) is employed to extract the temporal features, and a Bidirectional Long Short-Term Memory (BiLSTM) network is used to model each variable and generate accurate forecasts. These predicted values are then input into a Dynamic Fault Tree (DFT), where a Continuous-Time Markov Process (MP) is used to compute the state transition rate matrix. Finally, a Dynamic Bayesian Network (DBN) is applied to capture the temporal dependencies among system states and incorporate observed or control variables. Case studies based on the IEEE RBTS Bus 2 system show that the proposed method achieves superior reliability performance, with SAIFI, SAIDI, AENS, and ASAI values of 0.231 times/customer/year, 3.496 hours/customer/year, 17.465 kWh/year, and 99.943%, respectively—significantly outperforming traditional approaches. These results validate the effectiveness and advantages of the proposed method in improving the precision and efficiency of distribution network reliability assessments.

Keywords: distribution network reliability assessment; scenic load forecast; DFT-MP-DBN; VMD-QRCNN-BiLSTM

0 引言

业已确定可靠性以改善客户服务。配电网的主要贡献是电能从生成单元以指定的电压极限向应用程序传输,并将整个网络保持为可靠^[1]。在电力系统中,配电网承担着将

电力系统包括发电、输电和配电网。电力供应公用事

电能从输电网络传输到不同电压等级用户的重要任务,其可靠性将直接影响用户的用电体验^[2]。因此,研究考虑源荷双边不确定性的配电网可靠性评估策略对新型配电系统的发展意义重大^[3]。

鉴于配电网可靠性评估的必要性,国内外对于其的研究已有不少^[4]。可靠性评估综述主要集中于认识到分配网格中干扰的主要原因,以及有效控制需求增强。评估方法被归类为两个因素:分析和仿真。分析方法在很长一段时间内是技术先进的,可用于实际目的^[5]。文献[6]考虑到随机变量之间的相关性问题,提出了一种考虑分布式发电与负荷之间相关性的配电网可靠性评估方法。文献[7]利用多场景技术生成典型的孤岛内生负荷场景,并提出了考虑孤岛持续时间的孤岛形成概率计算方法。文献[8]建立了风能-太阳能-电池储能元件的时间模型和状态转换模型。基于这些模型,对系统中的非电力元件进行了顺序采样,而对风能-太阳能-电池储能元件进行了非顺序采样。文献[9]提出了一种评估分布式发电配电系统可靠性的新方法,该方法采用顺序蒙特卡洛法,考虑了简化的等效网络。上述参考文献仅通过序列蒙特卡洛法评估了源-荷时间序列变化对配电网可靠性的影响,未考虑序列蒙特卡洛法精度较低的问题,也忽略了根据一天内源-荷特性评估特殊时刻配电网可靠性的问题。

目前已提出概率预测方法,用于预测风光电站输出功率的概率密度函数、置信区间或量化值。在文献[10]中,一种基于高阶马尔科夫链的概率预测方法被用于预测未来15分钟的风光发电量的概率密度函数。在文献[11]中,开发了一种结合极端机器学习和分位数回归(quantile regression, QR)的统计方法来预测风光功率的置信区间。在文献[12]中,采用了加权高斯过程回归方法来预测风光功率的置信区间。在文献[13]中,提出了一种基于QR的卷积神经网络(quantile regression based convolutional neural network, QRCNN)方法,用于预测提前30 min的风光发电量的量化值。

近年来,随着主动配电网中分布式能源的大规模接入,源荷不确定性问题愈发凸显,可靠性评估方法也逐渐从静态模型向动态、概率、智能化方法演进。国外如IEEE、CIRED等机构推动了多状态元件建模、动态失效过程建模和基于人工智能的评估方法研究;国内研究则主要集中于多源异构数据驱动的评估模型构建与多阶段恢复策略建模。然而,现有研究普遍存在以下几点不足:

1)忽视预测模型与评估模型的耦合性。大多评估方法直接使用历史数据或典型日负荷曲线,未能体现源荷预测对可靠性指标的动态影响;

2)动态过程建模精度有限。多数方法仅使用静态故障树或传统马尔可夫过程,难以刻画故障发展演化中的状态依赖性与条件触发逻辑;

3)缺乏高时效性的多源融合模型。当前较少方法能将

非平稳时间序列预测、状态演化建模和不确定性推理有效整合,限制了主动配电网高频扰动下的实时评估能力。

综上所述,本文融合了基于变分模态分解、分位数回归、卷积神经网络结合双向长短时记忆(variational modal decomposition, quantile regression, convolutional neural network com-bined with bidirectional long and short term memory, VMD-QRCNN-BiLSTM)预测模型和动态故障树、马尔可夫过程与动态贝叶斯网络结合(dynamic fault trees and markov processes combined with dynamic Bayesian networks, DFT-MP-DBN)建模框架,实现对源荷演化过程的准确刻画与对系统动态可靠性的多层次建模。该方法在解决非平稳性、多阶段失效演化以及时序依赖关系建模方面具备显著优势,有效填补了当前研究中的空白,具有较强的实际推广意义和理论价值。

1 源荷预测

1.1 VMD 分解

本文首先对原始风光出力以及负荷数据进行变分模态分解^[14](variational modal decomposition, VMD)分解。VMD算法能够将非平稳时序信号分解为若干个具有特定频率特征的本征模态函数,从而实现对原始信号的降噪与模式提取,为后续特征提取与建模提供稳定的数据基础。

VMD是一种自适应的信号分解方法,用于将复杂的输入信号分解为若干个固有模态函数(intrinsic modal function, IMF)。与传统的经验模态分解相比,VMD通过引入变分原理与优化算法,在数学上严格定义了每一个模态的带宽,并实现自适应分解。

给定输入信号 $f(t)$,VMD的目标是将其分解为 n 个具有有限带宽的IMF,每一个IMF对应于一个特定的中心频率 ω_k ,公式如下:

$$f(t) = \sum_{k=1}^n u_k(t) \quad (1)$$

式中: n 表示分解得到的模态函数数量; u_k 表示第 k 个IMF。

为了确保每一个IMF是窄带信号,VMD通过最小化其带宽的总和来达到分解的目的。优化目标函数定义为:

$$\min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_{k=1}^n \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\}^2 \quad (2)$$

式中: $\delta(t)$ 表示冲激函数,用于构建希尔伯特变换的解析信号形式; j 是虚数单位; ∂_t 表示对时间的微分。

引入拉格朗日乘子 $\lambda(t)$ 并使用变分原理构建优化问题的拉格朗日函数:

$$\begin{aligned} \mathcal{L} = & \alpha \sum_{k=1}^n \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \\ & \| f(t) - \sum_{k=1}^n u_k(t) \|_2^2 \end{aligned} \quad (3)$$

通过交替方向乘子法求解,最终得到每一个IMF表示如下:

$$u_k^{n+1}(t) = \text{IFT} \left\{ \frac{\hat{f}(\omega) - \sum_{i \neq k} \hat{u}_i(\omega) + \hat{\lambda}(\omega)}{1 + 2\alpha(\omega - \omega_k^n)^2} \right\} \quad (4)$$

式中: IFT 表示反傅里叶变换, 将频域的结果转换回时域; $\hat{f}(\omega)$ 表示输入信号的频谱; $\hat{u}_i(\omega)$ 表示除了第 k 个 IMF 之外的所有其他 IMF 的频谱; $\hat{\lambda}(\omega)$ 表示拉格朗日乘子的频谱; α 表示调节带宽的参数; ω_k^n 表示当前迭代下第 k 个 IMF 的中心频率。

每一个 IMF 对应的中心频率表示如下:

$$\omega_k^{n+1} = \frac{\int_0^{\infty} \omega |\hat{u}_k(\omega)|^2 d\omega}{\int_0^{\infty} |\hat{u}_k(\omega)|^2 d\omega} \quad (5)$$

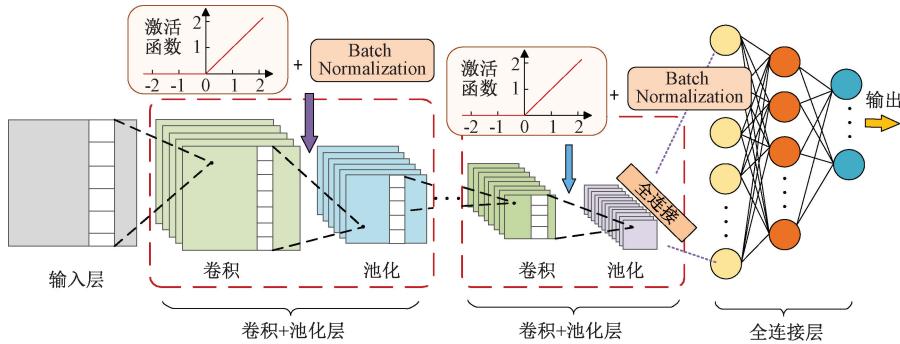


图 1 CNN 结构示意

Fig. 1 Schematic of CNN structure

1) 卷积层

在所提出的模型中, 卷积层的设计是通过卷积运算从 NWP 和历史风光出力以及负荷数据中提取隐藏特征。由于输入数据的维度较高, 因此必须训练相对较多的网络参数。在深度学习过程中, CNN 权重共享程序通过共享卷积核参数来解决这一问题。在这里, 每个卷积核都有一个感受野, 用于从上一层提取局部神经元。然而, 不同层之间的神经元是局部连接的, 如图 1 所示。

卷积层的特征图是通过计算上一层的特征图与卷积核之间的点积得到的, 然后通过激活函数进行非线性化处理, 如式(6)所示。

$$C_j^l = f \left(\sum_{i \in N_j} I_i^{l-1} \otimes w_{i,j}^l + b_j^l \right) \quad (6)$$

式中: $f(\cdot)$ 为激活函数, 通常使用 sigmoid 函数和 ReLU 函数。与 sigmoid 函数相比, ReLU 函数具有更高的收敛率, 本文采用 ReLU 函数作为激活函数; I_i^{l-1} 表示第 $(l-1)$ 层的特征图 i ; \otimes 是卷积运算; N_j 表示特征图的输入集; $w_{i,j}^l$ 表示第 $(l-1)$ 层特征图 i 相对于第 l 层特征图 j 的权重; b_j^l 表示第 $(l-1)$ 层特征图 i 相对于第 l 层特征图 j 的权重; C_j^l 表示第 l 层特征图 j 。

2) 池化层

池化层位于卷积层之后。它用于进一步提取非线性特征和降低输入数据的维度。池化层首先将输入特征图

在风光出力以及负荷预测任务中, VMD 的引入可以显著提高信号分解的准确性与稳定性, 为后续的特征提取与建模提供更好的输入。

1.2 CNN 特征提取

卷积神经网络^[15] (convolutional neural networks, CNN) 作为深度学习中的一种重要结构, 因其在图像处理与特征提取任务中表现出的优异性能而得到广泛应用。在本研究中, 将 CNN 用于从分解后的 IMF 中提取特征, 从而构建多尺度特征的表示向量。

CNN 的结构主要由卷积层、池化层与全连接层构成, 其中卷积层用于提取局部特征, 池化层用于降维与抗干扰, 全连接层用于最终的特征映射与输出, CNN 结构示意如图 1 所示。

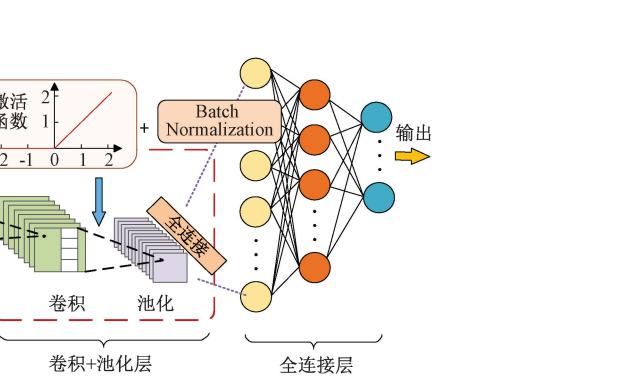


图 1 CNN 结构示意

Fig. 1 Schematic of CNN structure

划分为一组子区域, 然后通过池化函数将这些子区域转换为更小的特征图, 并生成其平均值或最大值作为输出。因此, 池化层可以有效减少 CNN 结构参数的数量和计算复杂度。池化层的特征图计算公式为:

$$P_j^l = f(\beta_j^l \text{down}(C_i^{l-1}) + b_j^l) \quad (7)$$

式中: C_i^{l-1} 表示第 $(l-1)$ 层特征图 i ; β_j^l 表示第 l 层特征图 j 的权重系数; $\text{down}(\cdot)$ 表示池化函数; P_j^l 表示第 l 层特征图 j 。

本文采用最大池化函数, 在池化层结构之后, 输入数据被扁平化为一维向量, 然后输入全连接层。

3) 全连接层

在池化层结构后面添加了几个全连接层。全连接层中的每个神经元都与前一层的所有神经元相连。全连接层神经元的计算公式为:

$$F_j^l = f \left(\sum_{i \in I-1} w_{i,j}^l N_i^{l-1} + b_j^l \right) \quad (8)$$

式中: F_j^l 表示第 l 层特征图 j 。

在本研究中, 为了增强特征提取的精度与鲁棒性, 引入了 QRCNN, 结合 CNN 的特征提取能力与分位数回归的鲁棒性, 实现多尺度特征的高效提取与建模。与传统的 CNN 模型不同, QRCNN 在输出层引入了分位数回归损失函数, 以实现不同置信水平下的概率预测。

引入 QR 的主要目的是为了捕捉数据中潜在的不确定

性信息。分位数回归通过最小化 PinballLoss 函数,使得模型能够在不同置信水平下输出预测结果,PinballLoss 函数表达如下:

$$L_\tau(y, \hat{y}) = \begin{cases} \tau \times (y - \hat{y}), & y \geq \hat{y} \\ (1 - \tau) \times (\hat{y} - y), & y < \hat{y} \end{cases} \quad (9)$$

式中: y 表示真实值; \hat{y} 表示预测值; τ 表示目标分位数。

在完成 VMD 分解后,继续将每个分量序列与相应时刻的气象数据(如光照强度、温度、风速等)皆作为模型输入,以便充分利用环境因素对风光出力以及负荷的影响规律。随后,引入 CNN 作为初级特征提取模块。通过多层卷积层与池化层的操作,CNN 能够自动提取输入数据中

的局部时序变化模式与潜在非线性特征,从而将原始多维时序数据编码为具有代表性的低维特征向量,增强模型对复杂动态特性的建模能力。

1.3 BiLSTM 时序建模

双向长短时记忆网络^[16](bidirectional long short term memory, BiLSTM)是 LSTM 网络的扩展,通过同时考虑前向和后向传播的特征信息,提高对时序数据的捕捉能力。

如图 2 所示为 BiLSTM 存储单元结构,BiLSTM 网络包含两个相反方向的 LSTM 网络:其中之一的前向网络表示从时间序列的起点到终点依次处理数据,捕捉过去的依赖信息;另外一个的后向网络表示从时间序列的终点到起点反向处理数据,捕捉未来的依赖信息。

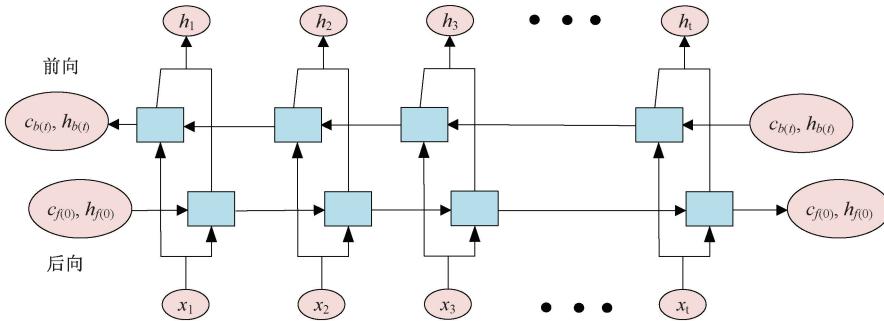


图 2 BiLSTM 存储单元结构

Fig. 2 BiLSTM memory cell structure

在风光出力以及负荷预测中,BiLSTM 能够更好地捕捉时间序列的双向依赖性,避免传统 LSTM 网络中信息丢失或衰减的问题。

给定输入序列 $X = \{x_1, x_2, \dots, x_n\}$, BiLSTM 的输出表达如下:

$$h_t = [\overrightarrow{h}_t, \overleftarrow{h}_t] \quad (10)$$

式中: \overrightarrow{h}_t 表示前向隐藏状态; \overleftarrow{h}_t 表示后向隐藏状态。

CNN 模块输出的特征向量随后被送入 BiLSTM 中进行深层次时序建模。BiLSTM 通过前向与后向两个 LSTM 子网络,能够同时捕捉历史与未来时间步之间的依赖关系,相较于传统单向 LSTM,其在处理具有长期依赖性和复杂动态行为的时间序列任务中表现更为优越。在本研究中,BiLSTM 主要用于构建风光出力以及负荷随时间演化的非线性映射关系,实现对未来功率输出值的高精度点预测。

2 可靠性评估建模

2.1 动态故障树

动态故障树^[17](dynamic fault tree, DFT)除了使用静态故障树的逻辑门,该方法还增加了 4 个动态逻辑门:优先级-AND(priority-AND, PAND)门、功能依赖(function dependency, FDEP)门、序列执行(sequence enforcing,

SQE)门和备用门。动态逻辑门逐一介绍如下:

1)PAND 门。PAND 的输入事件是逻辑门的基本事件或输出事件。PAND 的失效机制是,如果输入事件按从左到右的顺序发生,则输出事件发生。假设一个 PAND 有 3 个输入事件,其图形符号如图 3 所示。当 B 在 A 之前失效、 C 在 A 之前失效或 B 和 C 同时在 A 之前失效时,PAND 的输出事件失效。

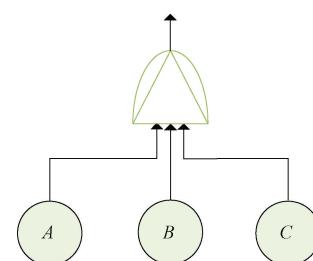


图 3 PAND 门

Fig. 3 PAND gate

2)FDEP 门。FDEP 的输入事件包含一个触发事件和一个或多个相关事件。基本事件或其他逻辑门可用作触发事件。其他逻辑门的输入事件可用作输出事件。假设一个 FDEP 有两个相关事件 A 和 B 以及一个触发事件 Tr ,动态逻辑门如图 4 所示。当 A 或 B 失败或 Tr 失败导

致 A 和 B 失败时,输出事件失败。

3) SEQ 门。虽然 SEQ 和 PAND 都描述了系统的临时特性,但它们在输入事件和失效机制上却有所不同。SEQ 的输入事件中有多个基本事件,而 SEQ 的失效机制是所有基本事件都按一定顺序发生。假设 SEQ 有 n 个基本事件输入,其图形符号如图 5 所示。只有当输入事件按 $1 \sim n$ 的顺序失效时,输出事件才会失效。

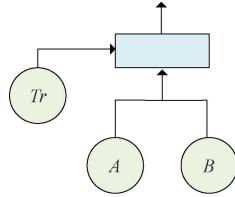


图 4 FDEP 门

Fig. 4 FDEP gate

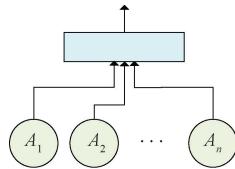


图 5 SEQ 门

Fig. 5 SEQ gate

4) 备用门。备用门由一套备用部件和一个主要部件组成,当主部件发生故障时,转换开关开始使备用部件运行。备用门失灵的条件是所有备用都失灵,备用门中存在休眠因子。根据休眠系数的大小,备用门具有以下状态:冷备用(cold spare, CSP)、热备用(warm spare, WSP)和热备用(hot spare, HSP)。图形符号如图 6 所示。3 个逻辑门的休眠系数分别为 $\alpha=0$ 、 $0 < \alpha < 1$ 和 $\alpha=1$ 。

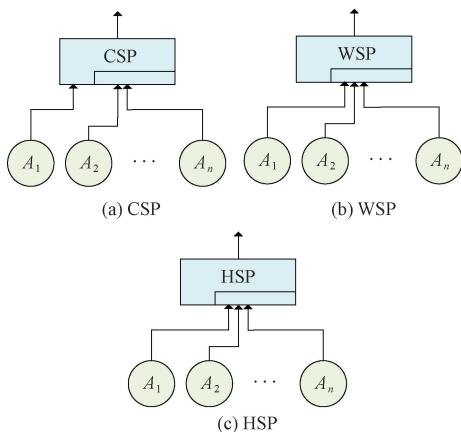


图 6 备用门

Fig. 6 Spare gate

在 CSP 逻辑门中,当系统开始工作时,基本事件进入工作状态,而备用事件处于非工作状态。基本事件失效后,备用事件开始工作,直到所有备用事件失效。WSP 的

输入与 CSP 相同。CSP 在使用前不会失效。但 WSP 在使用前可能已经失效。其有两种故障过程。第一种是备件不会失效,并能在主件失效后继续工作。第二种是暖部件在主部件失效前已经失效。热备件的输入与 WSP 相同。HSP 的基本事件和备用件同时运行。如果基本事件发生故障,备件将成为基本事件。如果所有备件都失效,则系统失效。

2.2 马尔可夫过程

在马尔可夫过程^[18](Markov process, MP)中,随机变量在时间 t_n 的概率与随机变量在时间 T_{N-1} 的值有关,而与 T_{N-1} 之前的过程历史无关,即“无记忆”。马尔可夫过程的研究对象是可修复系统,分析工程系统可靠性的一个基本假设是事件发生的时间服从指数分布,马尔可夫过程中的过渡概率为常数,即齐次马尔可夫过程。随机过程是连续时间和离散状态空间中的齐次马尔可夫过程:

$$P\{X(t+h) = j \mid X(t) = i\} = P\{X(h) = j \mid X(0) = i\} = p_{ij}(h) \quad (11)$$

式中: $X(t)$ 表示随机过程在时间 t 时刻所处的状态; i 与 j 表示随机过程的状态,属于离散状态空间的元素; $p_{ij}(h)$ 表示从状态 i 转移到状态 j 的转移概率函数,明确指出概率只取决于时间间隔 h 。

$$P\{X(t+h) = j \mid X(t) = i\} = p_{ij}(\Delta t) \approx q_{ij}\Delta t \quad (12)$$

$$P\{X(t+\Delta t) = i \mid X(t) = i\} = p_{ii}(\Delta t) \approx 1 - q_{ii}\Delta t \quad (13)$$

式中: $p_{ij}(\Delta t)$ 表示从状态 i 转移到状态 j 的状态转移概率,取决于时间间隔 Δt ; q_{ij} 表示状态转移速率,在齐次连续时间马尔科夫链中表示从状态 i 转移到状态 j 的速率(即单位时间的转移概率)。 $p_{ij}(\Delta t)$ 公式表达如下:

$$p_{ii}(\Delta t) + \sum_{j \neq i} p_{ij}(\Delta t) = 1 \quad (14)$$

式中: $p_{ii}(\Delta t)$ 表示状态在微小时间间隔 Δt 内保持不变的概率。

转换概率可以组成一个矩阵,表示为:

$$P(\Delta t) = \begin{bmatrix} p_{11}\Delta t & p_{12}\Delta t & \cdots & p_{1n}\Delta t \\ p_{21}\Delta t & p_{22}\Delta t & \cdots & p_{2n}\Delta t \\ \vdots & \vdots & & \vdots \\ p_{n1}\Delta t & p_{n2}\Delta t & \cdots & p_{nn}\Delta t \end{bmatrix} \quad (15)$$

将过渡密度矩阵定义为:

$$A = \lim_{\Delta t \rightarrow 0} \frac{p(\Delta t)}{\Delta t} = \begin{bmatrix} -q_{11} & q_{12} & \cdots & q_{1n} \\ q_{21} & -q_{22} & \cdots & q_{2n} \\ \vdots & \vdots & & \vdots \\ q_{n1} & q_{n2} & \cdots & -q_{nn} \end{bmatrix} \quad (16)$$

式中: n 为状态总数。在实际工程应用中,一般期望的是系统平稳运行时处于各种状态的概率,只需求解以下表达式即可。

$$\begin{cases} PA = 0 \\ \sum_{j=1}^n P_j = 1 \end{cases} \quad (17)$$

式中: P 是由各静止状态的概率; P_j 组成的矩阵。得出系统在各种状态下的概率后,就可以得出系统的其他可靠性指标。

2.3 动态贝叶斯网络

动态贝叶斯网络^[19](dynamic Bayesian network, DBN)是一种扩展了时间维度的贝叶斯网络,可用于为动态系统建模。DBN 基于一组以时间为索引的随机变量来表示过程的不同状态。

动态是指正在模拟一个动态系统,而不是指网络会随着时间的推移而变化。DBN 是随机过程的有向以及循环图形。DBN 可通过有向无环图定义如下:

$$P(Z_t | Z_{t-1}) = \prod_{i=1}^N P(Z_t^i | Pa(Z_t^i)) \quad (18)$$

式中: Z_t^i 为时间 t 的第 i 个节点; $Pa(Z_t^i)$ 为是 Z_t^i 的父节点。

配电系统发生突发事件后,会随之发生一系列复杂的事件。每次突发事件都可能以多种不同的方式影响许多不同的用户。一般来说,同样的故障会导致某些客户的用电瞬间中断,而其他用户的用电持续中断时间则有所不同,这取决于系统的切换方式和故障修复所需的时间。配电系统可靠性分析的关键在于准确模拟突发事件发生后的事件序列,以反映不同客户所面临的不同后果。分析仿真模拟的一般事件顺序为以下 6 个步骤。

步骤 1)突发事件,系统发生故障。

步骤 2)重合闸,重合闸装置打开,试图让故障排除。如果故障排除,重合闸装置关闭,系统恢复正常。

步骤 3)自动分段,看到故障电流的自动分段器在系统被重合闸装置断电时打开,试图隔离故障。

步骤 4)锁定,如果故障持续存在,时间过流保护将清除故障。锁定可以是执行重合闸功能的同一设备,也可以是距离故障点更近的另一个设备。

步骤 5)切换,包括自动切换和手动切换。切换用于快速隔离故障,并尽可能多地恢复对客户的供电。这包括上游恢复和下游恢复。

步骤 6)修复,修复故障,使系统恢复到故障前的状态。

3 评价指标与算法流程

3.1 源荷预测评价指标

1)风光出力以及负荷准确性预测的评价标准。本文选择绝对百分误差(MAPE)、平均绝对误差(MAE)和均方根误差(RMSE)作为该评价标准。

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \quad (19)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |(y_i - \hat{y}_i)| \quad (20)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (21)$$

式中: y_i 为实际值; \hat{y}_i 为预测值; n 表示样本总数。

2)概率预测评价指标。本文选择预测区间覆盖率(PICP)用于评价预测区间中实际值的占比,体现预测区间的可靠性。

$$PICP = \frac{1}{n} \sum_{i=1}^n \lambda_i \quad (22)$$

$$\lambda_i = \begin{cases} 1, & Y_i \in [L_i, U_i] \\ 0, & Y_i \notin [L_i, U_i] \end{cases} \quad (23)$$

式中: Y_i 为第 i 个实际值; $[L_i, U_i]$ 为第 i 个预测区间。

预测区间平均宽度(PIAW)作为评价预测区间宽度的大小指标。

$$PIAW = \frac{1}{N} \sum_{i=1}^N (U_i - L_i) \quad (24)$$

连续排序概率评分(CRPS)能够同时衡量可靠性和尖锐度,用于评价概率预测质量:

$$CRPS = \frac{1}{N} \sum_{i=1}^N \int_{-\infty}^{+\infty} [F_i(x) - H(x - y_i)]^2 dx \quad (25)$$

式中: $F_i(x)$ 表示为第 i 个预测概率分布的累积分布函数; $H(x)$ 为实际值对应的 Heaviside 阶跃函数。

3.2 可靠性评估指标

配电网系统的整体可靠性由以下 4 个评价指标组成。

系统平均中断频率指数(SAIFI):

$$SAIFI = \frac{\sum_{j=1}^{N_L} \lambda_j N_j^{cus}}{\sum_{j=1}^{N_L} N_j^{cus}} \quad (26)$$

系统平均中断持续时间指数(SAIDI):

$$SAIDI = \frac{\sum_{j=1}^{N_L} U_j N_j^{cus}}{\sum_{j=1}^{N_L} N_j^{cus}} \quad (27)$$

平均未供应能量指数(AENS):

$$AENS = \frac{\sum_{j=1}^{N_L} P_j U_j}{\sum_{j=1}^{N_L} N_j^{cus}} \quad (28)$$

平均服务可用性指数(ASAI):

$$ASAI = \frac{\sum_{j=1}^{N_L} 8760 N_j^{cus} - \sum_{j=1}^{N_L} U_j N_j^{cus}}{\sum_{j=1}^{N_L} 8760 N_j^{cus}} \quad (29)$$

3.3 算法流程

本文的配电网可靠性评估流程主要由两部分组成分别是源荷预测与可靠性评估建模。

其中源荷预测部分包括 VMD 分解、BiLSTM 时序建

模式;可靠性评估建模包括动态故障树、马尔可夫过程、动态贝叶斯网络。流程步骤如图 7 所示。

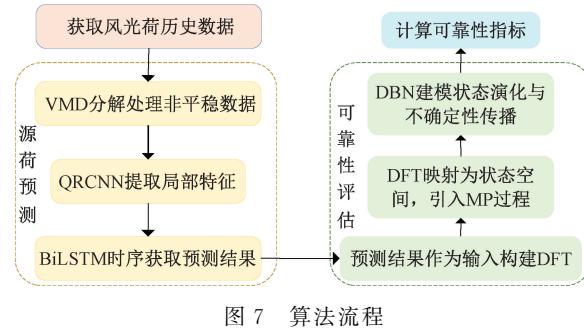


图 7 算法流程

Fig. 7 Algorithm flowchart

4 实验结果与分析

4.1 点预测评价分析

本文算例分析以贵州某城市为例,本文所用数据来源于贵州地区 2022 年 1 月 1 日~12 月 31 日的风速、光照强度与负荷历史实测数据,采样时间间隔为 15 min,数据覆盖不同气候条件与节假日工况,具有代表性和时序复杂性。

为保证模型训练效果,先对原始数据进行归一化处理,并采用滑动时间窗口方式构造样本数据集。整体数据集划分比例为训练集 80%,测试集 20%。采用的评价指标为 MAE、RMSE、MAPE。实验对比 VMD-QRCNN、QRCNN-LSTM、QRCNN-BiLSTM,实验结果如表 1~3 所示。风光出力预测结果通过风速与光照强度功率转换公式可得。

从表 1 可以看出,4 种方法在风电出力预测的 MAE、RMSE 和 MAPE 指标上均表现出逐步优化的趋势。传统的 QRCNN-LSTM 和 QRCNN-BiLSTM 方法已具备较强的时间建模能力,而引入 VMD 进行数据预处理后,VMD-QRCNN 和 VMD-QRCNN-BiLSTM 模型在各项指标上均明显优于未使用 VMD 的模型。特别地,VMD-QRCNN-BiLSTM 方法在 MAE(0.137)、RMSE(0.185) 和 MAPE(8.4%)方面均为最优,表明该方法在处理风电出力中的非平稳性和时序特征时具备更强的建模能力。

表 1 4 种方法风电出力预测结果对比

Table 1 Comparison of the results of the four methods of wind power output prediction

方法	MAE/MW	RMSE/MW	MAPE/%
VMD-QRCNN	0.213	0.297	13.4
QRCNN-LSTM	0.184	0.236	12.9
QRCNN-BiLSTM	0.167	0.246	10.8
VMD-QRCNN-BiLSTM	0.137	0.185	8.4

从表 2 中可以看出,所有模型在光伏出力预测中的误差指标均较风电预测略高,说明光照强度的波动性带来了额外挑战。VMD 的引入在所有模型中均显著降低了误

差,尤其在与 BiLSTM 结合后,VMD-QRCNN-BiLSTM 模型的 MAE 降至 0.143, RMSE 为 0.192, MAPE 为 9.6%,再次验证其在捕捉非线性与长短期依赖方面的优越性。

表 2 4 种方法光伏功率预测结果对比

Table 2 Comparison of PV power prediction results of four methods

方法	MAE/MW	RMSE/MW	MAPE/%
VMD-QRCNN	0.198	0.267	12.8
QRCNN-LSTM	0.171	0.239	11.2
QRCNN-BiLSTM	0.166	0.221	10.5
VMD-QRCNN-BiLSTM	0.143	0.192	9.6

从表 3 中可以看出, QRCNN-BiLSTM 与 VMD-QRCNN-BiLSTM 在准确性指标上接近,但后者仍略胜一筹,表明负荷的时序特性对双向建模更为敏感,同时 VMD 对数据平稳化处理提升了整体鲁棒性。VMD-QRCNN-BiLSTM 的 MAPE 为 9.1%,为 4 种模型中最低,说明该方法对于复杂负荷预测任务具有较强适应性。

表 3 4 种方法负荷预测结果对比

Table 3 Comparison of load forecasting results of four methods

方法	MAE/MW	RMSE/MW	MAPE/%
VMD-QRCNN	0.175	0.223	11.3
QRCNN-LSTM	0.165	0.239	10.8
QRCNN-BiLSTM	0.152	0.214	10.1
VMD-QRCNN-BiLSTM	0.138	0.172	9.1

综上所述,本文所提方法负荷预测的评价指标值均是 4 种方法中的最低值,表明所提方法能够更好地捕捉负荷数据中的时序依赖性和非线性特征,预测精度明显高于其他方法。

4.2 概率预测评价分析

依据所采集风光出力以及负荷数据点,首先通过 VMD 将原始风速和光照强度以及负荷时间序列分解为固有模态分量;其次,通过 QRCNN 对风速和光照强度以及负荷进行特征提取;最后使用 BiLSTM 建模各变量的时间序列特征,并生成预测值。生成风速与光照强度的预测值后通过风光功率转换公式^[20]得到风光出力数据。

为验证所提 VMD-QRCNN-BiLSTM 方法的优越性,本节对比 VMD-QRCNN、QRCNN-LSTM、QRCNN-BiLSTM。为了简化图中表达,将这 4 种方法以 Method1、Method2、Method3、Method4 分别表示 VMD-QRCNN-BiLSTM、VMD-QRCNN、QRCNN-LSTM、QRCNN-BiLSTM。图 8 与图 9、10 所示中的各方法用以上简化方式表达。

风速预测结果比较如图 8 所示,可知,Method1 的概率密度曲线最接近实际值,而 Method1 所指代的是 VMD-

QRCNN-BiLSTM方法,因此可说明所提方法的优越性与有效性。需要继续验证所提方法的有效性,可使用前文所提出概率区间的评价指标。

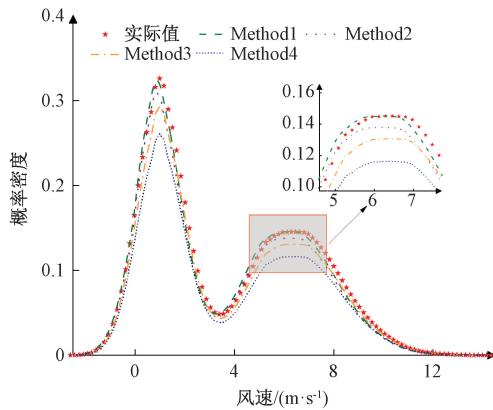


图8 风速概率密度曲线对比

Fig. 8 Comparison of wind speed probability density curves

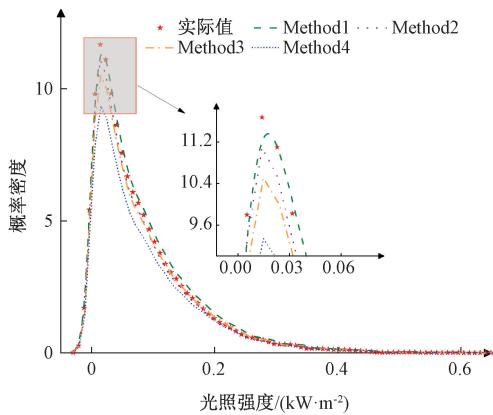


图9 光照强度概率密度曲线对比

Fig. 9 Comparison of probability density curves of light intensity

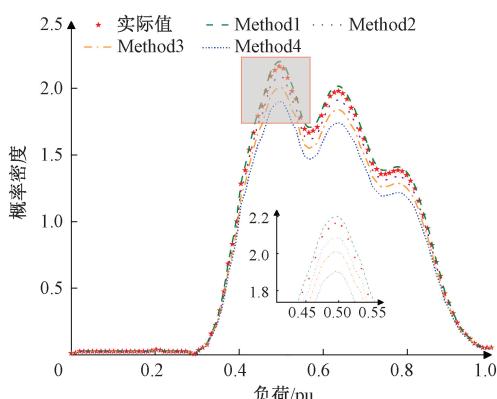


图10 负荷概率密度曲线对比

Fig. 10 Comparison of load probability density curves

看出,VMD-QRCNN-BiLSTM方法区间预测偏差最小, PICP值为97.8%对比其余3种方法最大; PINAW值为0.089对比其余3种方法最小; CRPS值为0.0253对比其余3种方法最小。通过以上评价指标可验证所提方法的优越性与有效性。

表4 不同方法风速区间预测偏差

Table 4 Deviation of wind speed interval prediction by different methods

模型	PICP/%	PINAW	CRPS
VMD-QRCNN	94.4	0.145	0.0495
QRCNN-LSTM	95.7	0.123	0.0428
QRCNN-BiLSTM	96.5	0.118	0.0321
VMD-QRCNN-BiLSTM	97.8	0.089	0.0253

光照强度预测结果比较如图9所示,由图可知, Method1的概率密度曲线最接近实际值,而Method1所指代的是VMD-QRCNN-BiLSTM方法,因此可说明所提方法的优越性与有效性。需继续验证所提方法的有效性,可使用前文所提出概率区间的评价指标。

如表5所示为不同方法光照强度区间预测偏差,其中可以看出,VMD-QRCNN-BiLSTM方法区间预测偏差最小, PICP值为95.9%对比其余3种方法最大; PINAW值为0.116对比其余3种方法最小; CRPS值为0.0276对比其余3种方法最小。通过以上评价指标可验证所提方法的优越性与有效性。

表5 不同方法光照强度区间预测偏差

Table 5 Prediction bias of light intensity intervals by different methods

模型	PICP/%	PINAW	CRPS
VMD-QRCNN	93.2	0.165	0.0561
QRCNN-LSTM	93.7	0.151	0.0486
QRCNN-BiLSTM	94.8	0.138	0.0413
VMD-QRCNN-BiLSTM	95.9	0.116	0.0276

负荷预测结果比较如图10所示,由图可知, Method1的概率密度曲线最接近实际值,而Method1所指代的是VMD-QRCNN-BiLSTM方法,因此可说明所提方法的优越性与有效性。需继续验证所提方法的有效性,可使用前文所提出概率区间的评价指标。

如表6所示为不同方法负荷区间预测偏差,其中可以看出,VMD-QRCNN-BiLSTM方法区间预测偏差最小, PICP值为96.8%对比其余3种方法最大; PINAW值为0.107对比其余3种方法最小; CRPS值为0.0236对比其余3种方法最小。通过以上评价指标可验证所提方法的优越性与有效性。

本节概率区间预测使用对象为风速与光照强度,使用功率转换公式便可得到风光出力以及负荷数据,风速与光

如表4所示为不同方法风速区间预测偏差,其中可以

照强度通过所提预测方法可较好预测,因此所转换的风光出力以及负荷预测值与实际值的偏差较小。

表 6 不同方法负荷区间预测偏差

Table 6 Load interval prediction deviation of different methods

模型	PICP/%	PINAW	CRPS
VMD-QRCNN	94.5	0.152	0.0411
QRCNN-LSTM	94.9	0.142	0.0352
QRCNN-BiLSTM	95.7	0.131	0.0293
VMD-QRCNN-BiLSTM	96.8	0.107	0.0236

由以上图表可知,所提方法通过概率区间评价指标以及准确性评价指标均是优于其余方法,因此所提方法可更好的对风光出力以及负荷进行预测。

4.3 可靠性评估分析

算例分析采用 IEEE RBTS Bus 2 进行分析,如图 11 所示。该系统包含 4 条馈线,22 个负荷节点,10 个联络开关和 2 个合环开关。有 6 组分布式能源接入,假定出力变化和与负荷演化定场景,用于模拟多元故障状态下系统的接力和反应能力。系统中设置了不同类型的断路器和熔断器 FUS,以故障形成多条解路和转供途径,适用于 DFT

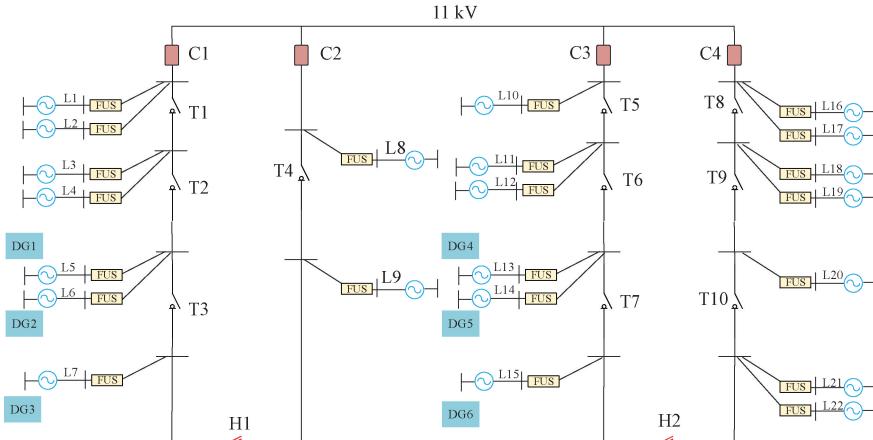


图 11 IEEE RBTS Bus 2 拓扑结构

Fig. 11 IEEE RBTS Bus 2 topology

分析和多速状态通路构造。

图 11 中,C1~C4 表示各线路的断路器;FUS 表示每段馈线的熔断器;L1~L7 表示馈线 1 所带负荷,L8~L9 表示馈线 2 所带负荷,L10~L15 表示馈线 3 所带负荷,L16~L22 表示馈线 4 所带负荷;T1~T10 表示联络开关;H1 和 H2 表示合环开关,正常时为断开状态;DG1~DG6 表示分布式能源的接入(风光新能源)。

首先,通过 VMD-BiLSTM 算法预测获得 1 200 组光风荷数据,作为输入使用 IEEE RBTS Bus 2 配电网系统进行仿真;然后,采用本文所提 DFT-MP-DBN 方法对比蒙特卡洛法(MC)、马尔可夫过程结合贝叶斯网络(MP-BN)、故障树分析法结合马尔可夫过程(DFT-MP),如表 7 所示。

表 7 4 个方法的可靠性分析比较

Table 7 Comparison of reliability analysis of the four methods

方法	SAIFI/(次/户/年)	SAIDI/(小时/户/年)	AENS/(kWh/年)	ASAI/%
MC	0.472	4.724	25.631	99.812
MP-BN	0.543	6.213	30.183	99.854
DFT-MP	0.422	4.121	21.425	99.886
DFT-MP-DBN	0.231	3.496	17.465	99.943

由表 7 可知,对比 MC 的 SAIFI 降低约 50%、SAIDI 缩短约 26%,对比 MP-BN 的 AENS 减少约 42%,对比 3 种传统方法 ASAI 提升达到了 99.943%,计算效率高,计算准确性高。验证了本文所提 DFT-MP-DBN 的配电网可靠性评估方法有效性和优越性。

为全面验证所提 DFT-MP-DBN 方法在不同局部区域的可靠性评估效果,本文特别选取了网络结构中两个关键区域进行深入对比分析:一是负荷最集中的节点 L6,该节点连接多个末端负载,具有显著的用电密度与敏感性,是反映用户侧影响的代表;二是 DG4-DG6 分布式电源集中接入区域,该区域汇集了多个新能源接入点,其输出功率波动大,且与配电网的互动最为频繁,对系统运行稳定性具有重要影响。

此外,本文还对其他典型区域(如 L1~L5、L10~L15 等)进行了测试,结果显示:DFT-MP-DBN 方法在各区域的表现均优于其他方法,趋势一致,但在上述两个关键区域优势更为明显。因此,选择 L6 和 DG 接入区域作为代表,重点展示其在高负载与高波动区域的评估能力。并分别对比 4 种方法(MC、MP-BN、DFT-MP、DFT-MP-DBN)在这些关键区域下的 SAIFI、SAIDI、AENS 和 ASAI 指标结果如表 8 所示。

表8 局部节点可靠性指标对比
Table 8 Comparison of local node reliability indicators

局部节点位置	方法	SAIFI/(次/户/年)	SAIDI/(小时/户/年)	AENS/(kWh/年)	ASAI/%
节点 L6	MC	0.821	5.873	3.105	99.722
	MP-BN	0.892	6.334	3.843	99.681
	DFT-MP	0.752	4.061	2.568	99.762
	DFT-MP-DBN	0.311	2.126	1.912	99.881
DG4~DG6 接入点	MC	0.714	4.932	2.994	99.758
	MP-BN	0.768	5.487	3.416	99.729
	DFT-MP	0.603	3.412	2.111	99.790
	DFT-MP-DBN	0.248	1.873	1.475	99.914

如表8所示,分析可得在节点L6处,DFT-MP-DBN方法在所有指标上均显著优于其他3种方法,特别是在SAIFI和SAIDI上相较于MP-BN分别下降62.1%和63.8%,说明该方法能更准确识别故障链条并动态调整故障隔离与恢复策略;DG集中接入点,DFT-MP-DBN对分布式电源引起的波动与失效影响具备更强鲁棒性和预测能力,ASAI提升至99.914%,展现出优越的局部服务保障能力;相比传统的MC和静态MP-BN方法,DFT-MP-DBN的动态推理机制和故障演化建模显著增强了对高风险节点的识别与保护作用。

5 结论

为提高配电网可靠性评估的效率和精度,融合VMD-QRCNN-BiLSTM预测与DFT-MP-DBN建模的主动配电网可靠性评估方法,得出以下结论:

在风光荷预测方面,VMD-QRCNN-BiLSTM预测方法在MAE、RMSE、MAPE三项核心指标上全面优于对比模型,尤其在光照预测中表现最为突出,体现了其对突变和非平稳信号的强鲁棒性。

在可靠性评估建模方面,由于融合VMD-QRCNN-BiLSTM预测使得DFT-MP-DBN方法能够显著降低SAIFI、SAIDI,提高ASAI,减少AENS,均优于其他方法,显著减少了用户中断事件,缩短了停电时长,并提升了系统整体与局部的供电保障能力。

参考文献

- [1] 王倩,李维展,李丰君,等.计及源荷不确定性的配电网可靠性高效评估方法[J].电工电能新技术,2024,43(9):74-81.
WANG Q, LI W ZH, LI F J, et al. An efficient reliability assessment method for distribution networks taking into account source-load uncertainty [J]. New Technology of Electrical Engineering, 2024, 43(9): 74-81.
- [2] 杨墨缘,张沈习,程浩忠,等.考虑故障后多阶段恢复的SOP柔性互联配电网可靠性评估[J/OL].中国电机工程学报,1-15 [2025-03-18]. <http://kns.cnki.net/kcms/detail/11.2107.tm.20240914.1110.008.html>. YANG M Y, ZHANG SH X, CHENG H ZH, et al. Reliability assessment of SOP flexible interconnected distribution network considering multi-stage recovery after failure [J/OL]. Chinese Journal of Electrical Engineering, 1-15 [2025-03-18]. <http://kns.cnki.net/kcms/detail/11.2107.tm.20240914.1110.008.html>.
- [3] 刘敬敬,白牧可,樊文婷,等.基于马尔可夫链与改进最小路法的柔性配电网运行可靠性评估[J].供用电,2024,41(9):24-33,52.
LIU J J, BAI M K, FAN W T, et al. Reliability assessment of flexible distribution network operation based on Markov chain and improved minimum path method[J]. Electricity Supply, 2024, 41(9): 24-33, 52.
- [4] 刘凯诚,钟鸣,曾平良,等.考虑分布式可再生电源和储能的智能配电网可靠性评估综述[J].电测与仪表,2021,58(7): 1-11.
LIU K CH, ZHONG M, ZENG P L, et al. A review on reliability assessment of smart distribution networks considering distributed renewable power sources and energy storage [J]. Electrical Measurement and Instrumentation, 2021, 58(7): 1-11.
- [5] 王长伟,招永锦,吴晗,等.考虑新型配电元件多状态可靠性的配电网可靠性评估[J].供用电,2023,40(4): 74-82.
WANG CH W, ZHAO Y J, WU H, et al. Reliability assessment of distribution networks considering a new multi-state reliability model for distribution components [J]. Electricity Supply, 2023, 40(4): 74-82.
- [6] 金国彬,刘玉龙,李国庆,等.考虑可靠性的交直流混合配电网网架与分布式电源协同优化规划[J].电力系统保护与控制,2022,50(22): 59-70.
JIN G B, LIU Y L, LI G Q, et al. Co-optimised planning of AC-DC hybrid distribution network framework with distributed power sources considering reliability[J]. Power System Protection and Control,

- 2022, 50(22): 59-70.
- [7] 马钰, 韦钢, 李扬, 等. 考虑孤岛源-荷不确定性的直流配电网可靠性评估[J]. 电工技术学报, 2021, 36(22): 4726-4738.
- MA Y, WEI G, LI Y, et al. Reliability assessment of DC distribution networks considering islanding source-load uncertainty [J]. Journal of Electrotechnology, 2021, 36(22): 4726-4738.
- [8] XU X, NIU D, PENG L, et al. Hierarchical multi-objective optimal planning model of active distribution network considering distributed generation and demand-side response [J]. Sustainable Energy Technologies and Assessments, 2022, 53: 102438.
- [9] LIU X, JIN C, CHEN Z, et al. Research on information security protection of active distribution network based on trusted computing [C]. Journal of Physics: Conference Series. IOP Publishing, 2021, 2136(1): 012013.
- [10] TAHIR M F, YOUSAF M Z, TZES A, et al. Enhanced solar photovoltaic power prediction using diverse machine learning algorithms with hyperparameter optimization [J]. Renewable and Sustainable Energy Reviews, 2024, 200: 114581.
- [11] 刘晓艳, 王珏, 姚铁锤, 等. 基于卫星遥感的超短期分布式光伏功率预测[J]. 电工技术学报, 2022, 37(7): 1800-1809.
- LIU X Y, WANG J, YAO T C H, et al. Ultra-short-term distributed photovoltaic power prediction based on satellite remote sensing [J]. Journal of Electrotechnology, 2022, 37(7): 1800-1809.
- [12] 吉锌格, 李慧, 叶林, 等. 基于波动特性挖掘的短期光伏功率预测[J]. 太阳能学报, 2022, 43(5): 146-155.
- JI X G, LI H, YE L, et al. Short-term photovoltaic power prediction based on fluctuation characteristic mining[J]. Journal of Solar Energy, 2022, 43(5): 146-155.
- [13] LIU S, XU T, DU X, et al. A hybrid deep learning model based on parallel architecture TCN-LSTM with Savitzky-Golay filter for wind power prediction[J]. Energy Conversion and Management, 2024, 302: 118122.
- [14] LI J, RAO C, GAO M, et al. Efficient calculation of distributed photovoltaic power generation power prediction via deep learning[J]. Renewable Energy, 2025, 246: 122901.
- [15] 陈子含, 滕伟, 胥学峰, 等. 基于图卷积网络和风速差分拟合的中长期风功率预测[J]. 中国电力, 2023, 56(10): 96-105.
- CHEN Z H, TENG W, XU X F, et al. Medium-and long-term wind power prediction based on graph convolutional network and differential fitting of wind speed[J]. China Power, 2023, 56(10): 96-105.
- [16] 冯沛儒, 江桂芬, 徐加银, 等. 基于CEEMD-BiLSTM-RFR的短期光伏功率预测[J]. 科学技术与工程, 2024, 24(5): 1955-1962.
- FENG P R, JIANG G F, XU J Y, et al. Short-term photovoltaic power prediction based on CEEMD-BiLSTM-RFR [J]. Science, Technology and Engineering, 2024, 24(5): 1955-1962.
- [17] 姚成玉, 饶乐庆, 陈东宁, 等. TS动态故障树分析方法[J]. 机械工程学报, 2019, 55(16): 17-32.
- YAO C H Y, RAO L Q, CHEN D N, et al. TS dynamic fault tree analysis method [J]. Journal of Mechanical Engineering, 2019, 55(16): 17-32.
- [18] WU B, LIMNIOS N. A comparative study of numerical methods for reliability assessment based on semi-Markov processes[J]. Reliability Engineering & System Safety, 2024, 252: 110431.
- [19] 彭铎, 曹坚, 黎亚亚. 基于动态贝叶斯LS-SVM的水下节点移动预测定位算法[J]. 电子测量与仪器学报, 2023, 37(10): 134-144.
- PENG D, CAO J, LI Y Y. Predictive localisation algorithm for underwater node movement based on dynamic Bayesian LS-SVM[J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(10): 134-144.
- [20] DENG Y, HONG Z, WANG J, et al. Reliability analysis of wind turbine with dynamic fault tree based on markov chain [C]. 2024 8th International Conference on Green Energy and Applications (ICGEA). IEEE, 2024: 38-42.

作者简介

牟晋麟,硕士,硕士研究生,主要研究方向为配电网运行。
E-mail:2201149781@qq.com

杨超(通信作者),博士,副教授,主要研究方向为电力系统与综合能源。

E-mail:3567756906@qq.com