

DOI: 10.19783/j.cnki.pspc.231067

基于改进 Att-LSTNet 与无迹粒子滤波融合的 主动配电网预测辅助状态估计

王玥, 于越, 金朝阳

(电网智能化调度与控制教育部重点实验室(山东大学), 山东 济南 250061)

摘要: 针对传统的无迹粒子滤波(unscented particle filter, UPF)存在不准确的新息向量及未知的量测噪声协方差矩阵导致估计精度低的问题, 提出一种改进 Att-LSTNet 与 UPF 融合的主动配电网预测辅助状态估计(forecasting-aided state estimation, FASE)方法。首先, 采用引力搜索算法(gravitational search algorithm, GSA)对支持向量回归(support vector regression, SVR)的关键参数进行优化处理, 利用历史数据建立 GSA-SVR 模型, 并将其引入至 Att-LSTNet 模型的输出层, 构建一种增强预测模型。然后, 利用 UPF 中的新息向量来训练该模型, 并结合孤立森林算法和箱线图法对原始新息向量进行监控和修正。最后, 针对量测噪声协方差矩阵未知的情况, 结合修正后的新息向量和 UPF 计算出未知量测噪声协方差矩阵, 并进行状态估计。基于 IEEE33 与 IEEE118 节点标准配电系统的算例结果表明, 所提出的方法在估计精度、泛化能力和鲁棒性等方面具有优越性。

关键词: 主动配电网; 预测辅助状态估计; Att-LSTNet; 无迹粒子滤波; SVR

Forecasting-aided state estimation for active distribution networks based on improved Att-LSTNet and unscented particle filter fusion

WANG Yue, YU Yue, JIN Zhaoyang

(Key Laboratory of Power System Intelligent Dispatch and Control (Shandong University),
Ministry of Education, Jinan 250061, China)

Abstract: In response to the issue of inaccurate innovation vectors and unknown measurement noise covariance matrices in the traditional unscented particle filter (UPF), a forecasting-aided state estimation (FASE) method for active distribution network is proposed, which integrates the improved Att-LSTNet and UPF. First, the key parameters of support vector regression (SVR) are optimized using a gravitational search algorithm (GSA), and a GSA-SVR model is established using historical data. This model is then introduced into the output layer of the Att-LSTNet model to create an enhanced forecasting model. Subsequently, the innovation vectors from UPF are used to train this model, and the isolation forest algorithm and box-plot method are employed to monitor and correct the original innovation vectors. Finally, in the case of unknown measurement noise covariance matrices, the corrected innovation vectors and UPF are combined to calculate the unknown measurement noise covariance matrices and perform state estimation. Case study results on the IEEE33-bus and IEEE118-bus test systems demonstrate the superiority of the proposed method in terms of estimation accuracy, generalizability, and robustness.

This work is supported by the National Natural Science Foundation of China (No. U22B20101).

Key words: active distribution networks; forecasting-aided state estimation; Att-LSTNet; UPF; SVR

0 引言

随着我国分布式电源(distributed generation, DG)接入比例的不不断提高, 电力系统的实时监控和

安全运行面临着日益复杂的挑战^[1-3]。电力系统的安全运行需要精确可靠的实时系统状态信息, 而状态估计在此过程中发挥着重要作用^[4-6]。主动配电网为状态估计提供的量测数据主要来源于相量测量单元(phasor measurement units, PMUs)和数据采集与监控系统(supervisory control and data acquisition,

基金项目: 国家自然科学基金项目资助(U22B20101)

SCADA)。然而, 由于设备故障、通信中断等原因, 这些传统量测设备无法提供足够的准确估计系统状态。为了精确有效地估计量测数据, 文献[7]提出了一种预测辅助状态估计方法(forecasting-aided state estimation, FASE), 该方法在新型电力系统的实时建模和能源管理中心起关键作用。常用的 FASE 方法包括无迹卡尔曼滤波(unscented kalman filter, UKF)^[8-9]和粒子滤波(particle filter, PF)等。但以上滤波算法存在估计精度受线性化或粒子退化影响^[10]的缺陷。为此, 文献[11]提出了无迹粒子滤波(unscented particle filter, UPF), 该算法通过结合 UKF 和 PF 的优势, 提高了估计性能。但不准确的新息向量会导致 UPF 产生估计偏差, 降低了估计的精度。此外, 当量测噪声协方差矩阵未知时, UPF 无法准确估计量测权重, 从而降低了滤波算法的准确性和对异常情况的鲁棒性。

为进一步提高状态估计结果的准确性, 文献[12]提出了一种基于深层神经网络的数据降维方法, 将深度学习(deep learning, DL)方法引入电力系统。DL 通过自动学习和提取数据特征来提供更全面的状态估计结果^[13]。基于此, 文献[14]提出了一种基于递归神经网络(recurrent neural networks, RNN)的混合 DL, 考虑了系统状态间的非线性依赖性, 存在梯度爆炸等问题。文献[15]使用长短期记忆神经网络模型(long-short term memory, LSTM)预测时间序列数据, 解决了 RNN 梯度爆炸问题, 但当时间序列较长或网络结构较深时, LSTM 模型无法有效捕捉时间序列中的长期依赖关系。为此, 文献[16]提出了长短期时间序列网络(long-short term time-series network, LSTNet)模型, 通过融合卷积神经网络(convolutional neural networks, CNN)来提取局部模式和捕捉全局时间序列依赖关系, 其循环跳过层却难以提取部分非季节性和非周期性的长短期模式。而文献[17]提出了一种基于注意力机制的 LSTNet(attention LSTNet, Att-LSTNet)模型, 通过引入注意力机制捕捉重要的时间序列特征, 从而更全面地提取时序数据中的长短期模式, 但预测误差逐渐累积会导致 Att-LSTNet 模型泛化能力降低。基于此, 学者们提出了岭回归(ridge regression, RR)^[18]、主成分分析(principal component analysis, PCA)^[19]和支持向量回归(support vector regression, SVR)^[20]等方法来提高模型的泛化能力。

其中, RR 基于线性关系假设进行建模, 并引入正则化以提高模型的稳定性和泛化能力; PCA 假设特征之间存在线性关系, 并进行降维处理以提取关键特征, 以提高模型的泛化性。而当数据间存在

复杂的非线性关系时, RR 和 PCA 无法有效地捕捉这些非线性模式。相比之下, SVR 利用核函数处理非线性关系, 具有更好的泛化能力, 并能够更好地处理训练数据外的新数据。因此, 本文提出一种新型的增强预测模型结构, 将 SVR 引入至 Att-LSTNet 模型的输出层, 以提高 Att-LSTNet 模型的泛化能力。然而, 由于 SVR 容易陷入局部最优解^[21], 专家学者提出了粒子群算法(particle swarm optimization, PSO)^[22]和蚁群算法(ant colony optimization, ACO)^[23]等优化算法来应对这一挑战。但二者在参数选择不当或信息素更新速率过高时, 无法快速找到全局最优解。

针对上述问题, 提出了一种基于改进 Att-LSTNet 与 UPF 融合的主动配电网 FASE 方法。首先, 采用引力搜索算法(gravitational search algorithm, GSA)对 SVR 的关键参数进行优化, 以有效避免 SVR 陷入局部最优解; 然后, 改变 Att-LSTNet 模型的原有结构, 构建一种新型增强预测模型, 即 ALSTNet_{GS} 模型: 利用优化后的 GSA-SVR 模型改进 Att-LSTNet 模型的输出层, 通过并联的方式对预测结果进行修正, 以提高模型的预测精度和泛化能力; 在此基础上, 使用滑动窗口内的新息向量训练 ALSTNet_{GS} 模型, 并结合孤立森林算法^[24]与箱线图法^[25]对新息向量进行监控与修正; 最后, 结合处理后的新息向量及 UPF, 计算未知的量测噪声协方差矩阵, 以提高估计结果的鲁棒性。本文选择 IEEE 33 和 IEEE 118 节点标准配电系统进行了对比实验, 经实验验证, 所提出的方法在估计精度、泛化能力和鲁棒性等方面具有优越性。

1 基本的 FASE 模型

1.1 传统 FASE

对于主动配电网, 应考虑系统非线性和噪声随机性, 在多个时间段下建立时间空间下的状态方程和量测方程, 其表达式为

$$\mathbf{x}_{k+1} = f(\mathbf{x}_k) + \mathbf{q}_k \quad (1)$$

$$\mathbf{y}_k = h(\mathbf{x}_k) + \mathbf{r}_k \quad (2)$$

式中: \mathbf{x}_k 为状态向量; \mathbf{y}_k 为量测向量; f 为状态转移函数; h 为量测转移函数; \mathbf{q}_k 、 \mathbf{r}_k 分别为 n 维的系统误差向量和 m 维的量测误差向量, 服从均值为零、标准差为 \mathbf{M} 和 \mathbf{R} 的白噪声分布。

1.2 无迹粒子滤波

针对 PF 的估计精度受建议分布函数和重采样过程影响的缺陷, 本文采用 UPF 进行状态估计。UPF 基于 PF 的框架, 利用 UKF 生成的参考分布来指导状态预测粒子的生成过程。UPF 不仅克服了 UKF

和 PF 的缺点, 还保持了 PF 的灵活性, 通过调整粒子数量来改变估计的精度^[26], 其步骤如下所示。

1) 采用对称策略实现无迹变换 (unscented transform, UT), 生成 N 个粒子的重要性密度函数。构造每个粒子的 Sigma 采样点集 χ_{k+1}^i 和权值 $W_{i,m}^i$ 、 $W_{i,c}^i$ 。更新 Sigma 采样点集, 计算状态预测值 $z_{k|k+1}^i$ 、状态预测均值 $\bar{z}_{k|k+1}^i$ 、自协方差 P_{zz}^i 和互协方差 P_{xz}^i 。然后, 计算卡尔曼增益 K^i , 利用最新的量测值更新系统状态变量 \hat{x}_k^i 和协方差 \hat{P}_k^i , 从而产生重要性密度函数, 其推导公式见文献[11]。

2) 从重要性密度函数中进行采样, 生成用于粒子滤波的预测粒子 \hat{x}_k^i , 根据最新的量测量及相应的权值公式计算每个粒子的重要性权值, 并对每个重要性权值进行归一化处理得 \tilde{w}_k^i , 推导公式见文献[11]。

3) UPF 迭代计算完成后, 输出状态量的估计值 \hat{x}_k 和协方差矩阵 \hat{P}_k , 如式(3)和式(4)所示。

$$\hat{x}_k = \sum_{i=1}^N \tilde{w}_k^i \hat{x}_k^i \quad (3)$$

$$\hat{P}_k = \sum_{i=1}^N \tilde{w}_k^i (\hat{x}_k^i - \hat{x}_k)(\hat{x}_k^i - \hat{x}_k)^T \quad (4)$$

在 UPF 中, 新息向量 $\delta\lambda_k^i$ 为实际量测值 z_k^i 与预测值 $z_{k|k+1}^i$ 之间的偏差, 则新息向量的表达式如式(5)所示。

$$\delta\lambda_k^i = z_k^i - z_{k|k+1}^i \quad (5)$$

结合 $z_{k|k+1}^i = h(y_{k|k+1}^i) + r_{k+1}^i$ 和 $y_{k|k+1}^i = h(x_{k|k+1}^i) + r_{k+1}^i$ 可得

$$\delta\lambda_k^i = (z_k^i - z_{k|k+1}^i) + z_{k|k+1}^i - h(y_{k|k+1}^i) - r_{k+1}^i = v_k^i + h(x_{k|k+1}^i, i_{k+1}) - h(y_{k|k+1}^i) - r_{k+1}^i \quad (6)$$

式中: r_{k+1} 为 $k+1$ 时刻的量测误差; r_{k+1}^i 为第 i 个粒子 $k+1$ 时刻的量测误差。

$$\begin{aligned} \text{Cov}(\delta\lambda_k^i) &= E[(\delta\lambda_k^i - E(\delta\lambda_k^i))(\delta\lambda_k^i - E(\delta\lambda_k^i))^T] = \\ &= E(\delta\lambda_k^i \delta\lambda_k^{iT}) + E\left[\left(\frac{1}{N} \sum_{j=1}^N \delta\lambda_k^j\right) \cdot \left(\frac{1}{N} \sum_{j=1}^N \delta\lambda_k^j\right)^T - \right. \\ &\quad \left. \delta\lambda_k^i \left(\frac{1}{N} \sum_{j=1}^N \delta\lambda_k^j\right)^T - \delta\lambda_k^{iT} \frac{1}{N} \sum_{j=1}^N \delta\lambda_k^j\right] = \\ &= E(\delta\lambda_k^i \delta\lambda_k^{iT}) + \zeta_k^i \end{aligned}$$

其中:

$$\zeta_k^i = E \left[\begin{array}{c} \left(\frac{1}{N} \sum_{j=1}^N \delta\lambda_k^j\right) \cdot \left(\frac{1}{N} \sum_{j=1}^N \delta\lambda_k^j\right)^T - \delta\lambda_k^i \left(\frac{1}{N} \sum_{j=1}^N \delta\lambda_k^j\right)^T - \\ \delta\lambda_k^{iT} \frac{1}{N} \sum_{j=1}^N \delta\lambda_k^j \end{array} \right] \quad (7)$$

式中: $E[\cdot]$ 为期望运算; j 为新息向量的个数。

结合式(6)和式(7)可得新息向量的协方差表达式为

$$\begin{aligned} \text{Cov}(\delta\lambda_k^i) &= E\{[v_k^i + h(x_{k|k+1}^i, i_{k+1}) - \\ &\quad h(y_{k|k+1}^i) - r_{k+1}^i] \cdot [v_k^i + h(x_{k|k+1}^i, i_{k+1}) - \\ &\quad h(y_{k|k+1}^i) - r_{k+1}^i]^T\} + \zeta_k^i = \\ &= E(v_k^i v_k^{iT}) + E[h(x_{k|k+1}^i, i_{k+1}) - \\ &\quad h(y_{k|k+1}^i) - r_{k+1}^i] \cdot [h(x_{k|k+1}^i, i_{k+1}) - \\ &\quad h(y_{k|k+1}^i) - r_{k+1}^i]^T + \zeta_k^i = R_k^i + T_k^i + \zeta_k^i \end{aligned} \quad (8)$$

其中:

$$\begin{cases} R_k^i = E(v_k^i v_k^{iT}) \\ T_k^i = E[h(x_{k|k+1}^i, i_{k+1}) - h(y_{k|k+1}^i) - r_{k+1}^i] \cdot \\ \quad [h(x_{k|k+1}^i, i_{k+1}) - h(y_{k|k+1}^i) - r_{k+1}^i] \end{cases}$$

结合式(8)可得观测信息协方差矩阵的表达式为

$$\hat{C}_{\delta\lambda,k}^i = \frac{1}{S} \sum_{p=k-S}^k \delta\lambda_p^i \delta\lambda_p^{iT} \quad (9)$$

式中, S 为滑动窗口宽度。

结合式(8)和式(9)可得量测噪声协方差矩阵的表达式为

$$R_k^i = \hat{C}_{\delta\lambda,k}^i - T_k^i - \zeta_k^i \quad (10)$$

然而, 当假设的噪声模型参数与实际系统不匹配时, 使用 UPF 得到的新息向量会导致估计结果与真实值偏差较大, 并引入更多的不确定性和噪声, 从而降低了估计结果的准确性和算法的鲁棒性。此外, 未知的量测噪声协方差矩阵也会对 UPF 的估计精度及鲁棒性产生不利影响。

2 改进 SVR 优化的 Att-LSTNet 模型

2.1 基于注意力机制的 LSTNet 模型

本文采用 Att-LSTNet 模型作为 ALSTNet_{GS} 模型的基础, Att-LSTNet 模型通过结合 CNN 和 RNN, 提高了对数据中长时间序特征的提取能力, 并合理分配权重以增强预测性能。为解决神经网络对线性特征识别不敏感的问题, 引入了自回归模型。Att-LSTNet 模型的结构如图 1 所示^[27]。

Att-LSTNet 模型的第 1 个模块是 CNN, 用于对主动配电网时间序列进行卷积运算, 提取局部特征和捕捉局部依赖关系。卷积层由多个滤波结构组成, 输出特征向量详见文献[27]。

Att-LSTNet 模型的第 2 个模块是循环模块 (recurrent) 和循环跳过模块 (recurrent-skip), 接受卷积模块输出的矩阵并进行特征提取。recurrent 采用 GRU 神经网络单元, 并引入循环跳过机制, 用于提

取时间序列中的相对长期依赖关系, 其结构如图 2 所示。当时间序列非常长时, 为有效捕捉其中的相对关系, 引入了 recurrent-skip 模块, 在当前隐藏状态和相邻时间段的隐藏状态之间添加循环跳过结构, 更新表达式见文献[27]。

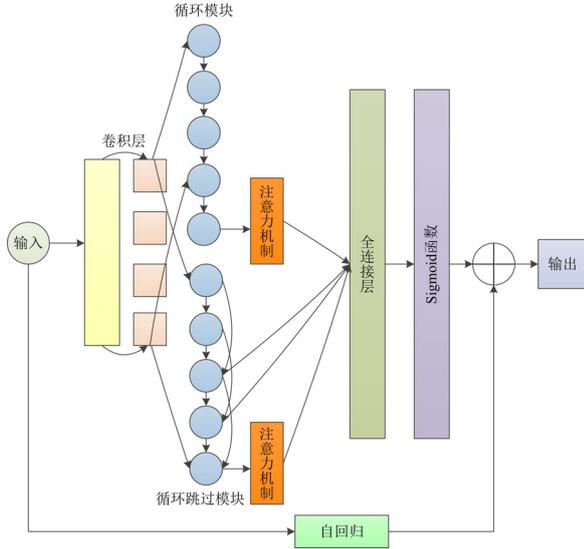


图 1 Att-LSTNet 模型结构图

Fig. 1 Structure of the Att-LSTNet model

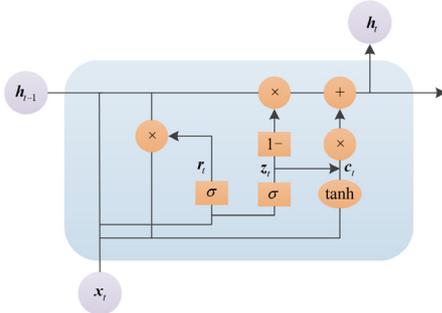


图 2 GRU 神经网络单元结构

Fig. 2 Structure of the GRU neural network unit

然而, 使用 recurrent-skip 需要预设超参数, 导致难以提取时间序列中的非季节性特征。相比之下, 注意力机制能更有效地解决时间序列中需要关注的特征尺度。在引入注意力机制模块后的 Att-LSTNet 模型中, Dense 层的计算表达式为

$$h_t^D = W_{GRU}[c_t; h_{t-1}^R] + b \quad (11)$$

式中: h_t^D 为 Dense 层的输出; W_{GRU} 为权重参数矩阵; c_t 为加权向量; h_{t-1}^R 为 recurrent-skip 模块在 $t-1$ 时刻的输出; b 为 Att-LSTNet 模型的偏置向量。

此外, 由于 CNN 和 RNN 对局部线性特征的识别不够敏感, 本文采用自回归模型(autoregressive,

AR)来提取时间序列的线性特征, 并将神经网络部分和 AR 模型叠加, 得到 Att-LSTNet 模型的输出结果如式(12)所示。

$$\hat{\delta}_t = h_t^D + h_t^L \quad (12)$$

式中: $\hat{\delta}_t$ 为 t 时刻的最终预测结果; h_t^L 为 AR 模型输出结果。

2.2 基于引力搜索算法的 SVR 模型

文献[28]提出一种优化算法 GSA, 该算法以物体间的万有引力为基础, 使种群中每一个物体向质量更大的物体移动, 从而实现优化目标最小化或最大化。其步骤如下所述。

1) 初始化种群位置。假设种群维度为 D , 含有 M 个粒子, 第 θ 个粒子的位置 φ_θ 如式(13)所示。

$$\varphi_\theta = (\varphi_\theta^1, \varphi_\theta^2, \varphi_\theta^3, \dots, \varphi_\theta^D), \theta = 1, 2, 3, \dots, M \quad (13)$$

2) 计算粒子受到的合力和加速度, 并更新粒子的位置和速度。在 t 时刻, 计算粒子 θ 对 ω 的作用力 $F_{\theta, \omega}^D$ 和粒子 θ 、 ω 间的欧式距离 $R_{\theta\omega}(t)$, 计算过程见文献[28]。为增加算法的随机特征, 本文在 t 时刻引入一个随机数 rand_θ , 取值[0,1], 并计算出粒子 θ 在 D 维中 $t+1$ 时刻速度 $v_\theta^D(t+1)$ 和位置 $\varphi_\theta^D(t+1)$ 分别如式(14)和式(15)所示。

$$v_\theta^D(t+1) = \text{rand}_\theta \times v_\theta^D(t) + \alpha_\theta^D(t) \quad (14)$$

$$\varphi_\theta^D(t+1) = \varphi_\theta^D(t) + v_\theta^D(t+1) \quad (15)$$

式中, $\alpha_\theta^D(t)$ 为粒子 θ 的引力常数变化因子。

3) 计算 SVR 个体适应度函数值并更新引力质量与惯性质量。通过文献[28]中的式(14)、式(16)一式(18), 可得 SVR 个体引力质量 $m_\theta(t)$ 和惯性质量 $M_\theta(t)$ 分别如式(16)和式(17)所示。

$$m_\theta(t) = \frac{f_{\text{itness}\theta}(t) - w_{\text{orst}}(t)}{b_{\text{est}}(t) - w_{\text{orst}}(t)} \quad (16)$$

$$M_\theta(t) = \frac{m_\theta(t)}{\sum_{\omega=1}^M m_\omega(t)} \quad (17)$$

式中: $f_{\text{itness}\theta}(t)$ 为粒子 θ 在 t 时刻的适应度函数值; $m_\omega(t)$ 为粒子 ω 的引力质量; $w_{\text{orst}}(t)$ 为在最小值问题中适应函数值的最大值; $b_{\text{est}}(t)$ 为适应函数值的最小值, 反之亦然, 具体推导见文献[28]。

GSA 通过引入 Kbest 策略^[28]来避免陷入局部最优解。Kbest 是一个时间变化函数, 初始值为 K_0 , 初始时刻所有粒子都互相施加引力, 但随着时间推移, Kbest 逐渐线性减小, 最终只有一个粒子对其他粒子施加引力。

SVR 是机器学习中广泛应用于预测的一种方法^[29]。与传统的经验风险最小化算法不同, SVR 采

用最小化结构风险原则，有效避免了“维数灾难”并解决了传统模型识别困难等问题，其线性回归模型通常表示为

$$f(\boldsymbol{y}_{\text{SVR}}) = \boldsymbol{w}^T \boldsymbol{y}_{\text{SVR}} + \boldsymbol{g} \quad (18)$$

式中： \boldsymbol{w} 为输入向量的法向量； $\boldsymbol{y}_{\text{SVR}}$ 为输入向量； \boldsymbol{g} 为 SVR 的偏置项。

主动配电网状态序列通常呈现非线性变化。因此，SVR 采用非线性映射函数将样本映射到高维空间，再利用高斯径向基核函数替换高维空间中的向量内积。高斯径向基核函数的具体表达式为

$$K(\boldsymbol{y}_{\text{SVR}_i}, \boldsymbol{y}_{\text{SVR}_j}) = \exp\left(-\frac{\|\boldsymbol{y}_{\text{SVR}_i} - \boldsymbol{y}_{\text{SVR}_j}\|^2}{2\sigma^2}\right) \quad (19)$$

式中： $\boldsymbol{y}_{\text{SVR}_i}$ 为第 i 个输入向量； σ 为高斯核的带宽， $\sigma > 0$ ；“ $\|\cdot\|^2$ ”为欧氏距离的平方。高斯径向基核函数增强了 SVR 的非线性预测能力，SVR 的最终回归函数如式(20)所示。

$$f(\boldsymbol{y}_{\text{SVR}}) = \sum_{i=1}^m (\alpha_i^* - \alpha_i) K(\boldsymbol{y}_{\text{SVR}}, \boldsymbol{y}_{\text{SVR}_i}) + \boldsymbol{g} \quad (20)$$

式中： m 为输入数据的数量； α_i 和 α_i^* 均为拉格朗日乘子。

在 SVR 中，寻找最优参数需要对大量参数组合进行搜索，传统的穷举计算方法效率低且易陷入局部最优解。因此，本文采用 GSA 优化 SVR 的惩罚参数 C 和核函数参数 γ ，通过全局搜索提高效率，找到全局最优解。该算法基于参数集合的适应度、引力和位移等参数，自适应地调整参数集合的位置并更新步长，实现对 SVR 参数的调整，提升预测精度。

2.3 基于 Att-LSTNet 模型的增强预测模型

传统的 Att-LSTNet 模型在准确建模未知数据方面存在困难，由于误差累积^[30]和特征提取能力的限制，导致泛化能力较差，无法准确预测未知数据。为解决此问题，本文利用 Att-LSTNet 模型在预测的初始阶段对原始数据进行长时间序列处理，然后在优化阶段将 GSA-SVR 模型嵌入到 Att-LSTNet 模型的输出层，对预测结果进行修正。该模型的具体参数如表 1 所示，预测步骤如下：

- 1) 对原始数据进行预处理，包括处理缺失数据和离群点，并构建 Att-LSTNet 模型所需要的数组 \boldsymbol{Y} ；
- 2) 将经过归一化后的数组输入 Att-LSTNet 模型进行训练与预测，生成一组预测值 $\hat{\boldsymbol{y}}$ ；
- 3) 将预测值 $\hat{\boldsymbol{y}}$ 与原始数据进行差值运算，得到误差项 \boldsymbol{e} ；
- 4) 将误差项 \boldsymbol{e} 作为 GSA-SVR 模型的输入，利用 GSA-SVR 模型进行回归预测，得到误差预测值 $\hat{\boldsymbol{e}}$ ；

表 1 ALSTNet_{GS} 模型具体参数

Table 1 Specific parameters of ALSTNet _{GS} model		
ALSTNet _{GS} 层级	模型参数	设置
卷积层	隐藏层数	3
	卷积核高度	7
recurrent	隐藏层数	38
recurrent-skip	隐藏层数	11
	循环跳过数	101
注意力机制层	注意力头数	2
AR 层	正则化系数	1
	窗口大小	48
GSA-SVR 层	种群维度 D	5
	粒子数 N	30
	引力常数值 G_0	100
	引力常数变化因子 α	20
	迭代次数 T	50
	K_0	30, 线性减小到 1
	核函数	径向基核函数
	γ	100
	ϵ	0
	C	2.758 108 99
	学习率	1×10^{-8}
	批量大小	96
其他参数	Dropout 失活率	0.4
	训练次数	50
	优化算法	Adam
	输入步长	96
	输出步长	4
每步间隔时间	15 min	

5) 将 Att-LSTNet 模型的预测值 $\hat{\boldsymbol{y}}$ 与修正后的误差项 $\hat{\boldsymbol{e}}$ 合并，得到最终的预测结果 $\hat{\boldsymbol{x}}$ 。

由式 (11) 和式 (12)、式 (18) 一式 (20) 得到 ALSTNet_{GS} 模型最终的预测结果为

$$\hat{\boldsymbol{Y}}_t = \sum_{i=1}^m (\alpha_i^* - \alpha_i) K(\boldsymbol{h}_t^D + \boldsymbol{h}_t^L - \boldsymbol{\eta}_t, \boldsymbol{h}_{t,i}^D + \boldsymbol{h}_{t,i}^L - \boldsymbol{\eta}_{t,i}) + \boldsymbol{h}_t^D + \boldsymbol{h}_t^L + \boldsymbol{g}_t \quad (21)$$

式中： $\hat{\boldsymbol{Y}}_t$ 为 t 时刻的预测结果； $\boldsymbol{\eta}_t$ 为 t 时刻的总输入结果； \boldsymbol{h}_t^L 为 t 时刻 AR 模型的总输出结果； \boldsymbol{h}_t^D 为 t 时刻 Dense 层的总输出结果； $\boldsymbol{h}_{t,i}^D$ 为 t 时刻 Dense 层的第 i 个输出结果； $\boldsymbol{h}_{t,i}^L$ 为 t 时刻 AR 模型的第 i 个输出结果； $\boldsymbol{\eta}_{t,i}$ 为 t 时刻的第 i 个输入结果； \boldsymbol{g}_t 为 Att-LSTNet_{GS} 模型 t 时刻的偏置项。

3 基于改进 Att-LSTNet 与 UPF 融合的 FASE 方法

本文利用新息向量训练 ALSTNet_{GS} 模型，并借

助双异常值检测方法检测 ALSTNet_{GS} 模型的预测值与原始新息向量中的离群点, 然后计算量测噪声

协方差矩阵, 以获得更准确的估计结果。具体流程如图 3 所示。

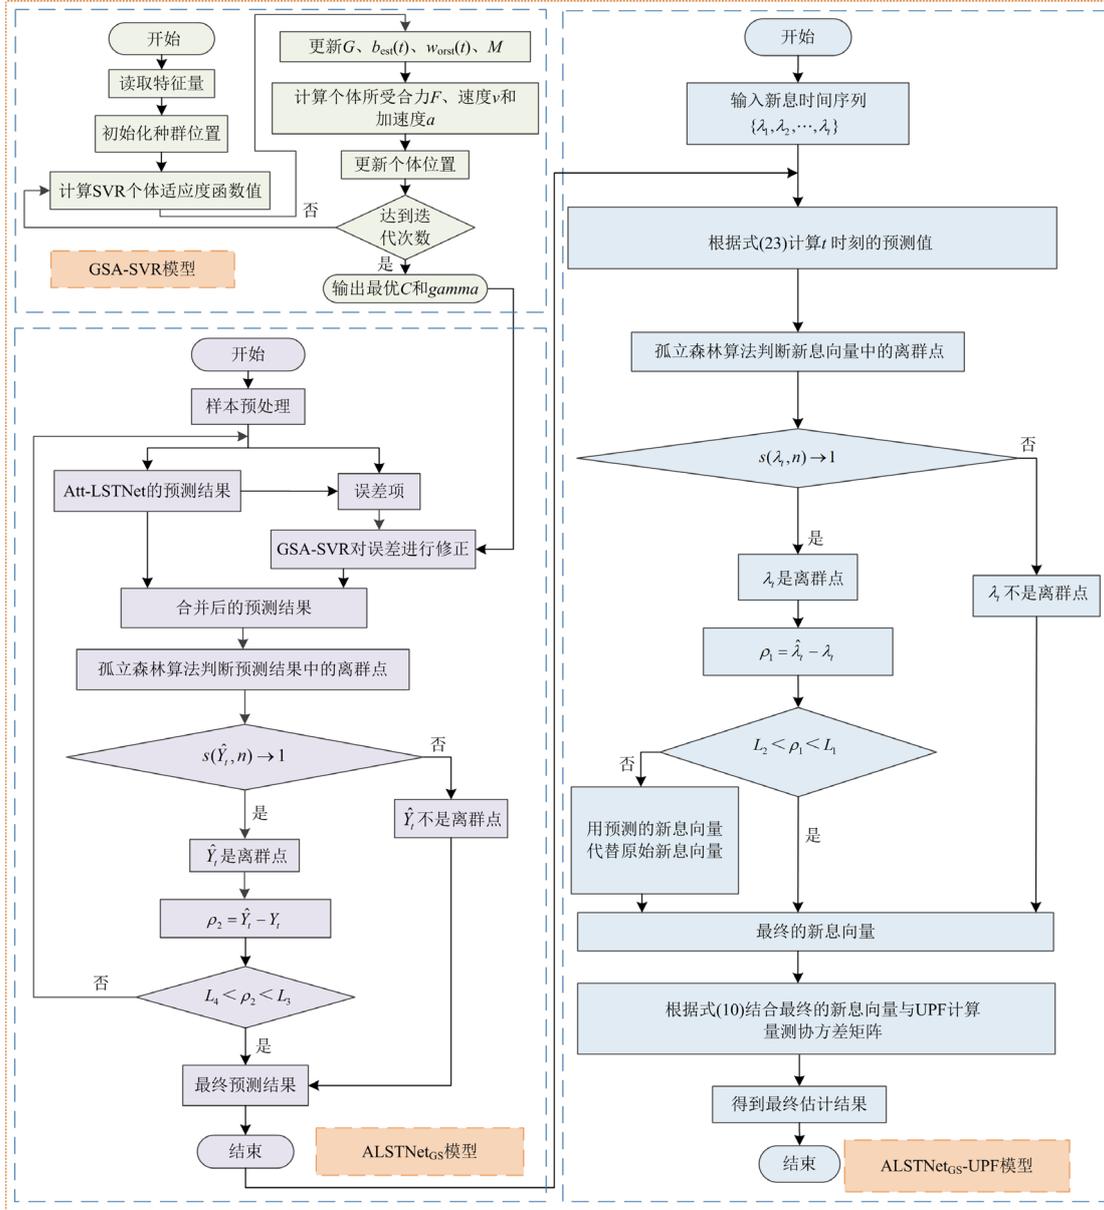


图 3 改进 Att-LSTNet 与 UPF 融合的主动配电网 FASE 结构图

Fig. 3 Structure of the FASE for active distribution networks based on improved Att-LSTNet and UPF fusion

所提方法的具体步骤如下所示。

1) 建立历史数据与原始新息向量的映射关系。

假设新息向量的时间序列为 $\{\lambda_1, \lambda_2, \dots, \lambda_t\}$, 该时间序列呈现出一定的变化趋势。通过历史数据来预测当前时刻的新息向量 λ_{t+1} , 它们之间的映射关系 $f: R^m \rightarrow R$ 可表示为

$$\hat{\lambda}_t = f(\lambda_t, \lambda_{t+1}, \dots, \lambda_{m-1}) \quad (22)$$

式中, $\hat{\lambda}_t$ 为预测值。

通过对样本进行学习, 可以得到 ALSTNet_{GS} 模型, 从而得到当前时刻的预测值为

$$\hat{Y}_t = \sum_{i=1}^{N_A-m} (\alpha_i^* - \alpha_i) K(\mathbf{h}_t^D + \mathbf{h}_t^L - \lambda_{t-m|t-1}, \mathbf{h}_{t,i}^D + \mathbf{h}_{t,i}^L - \eta_{t,i}) + \mathbf{h}_t^D + \mathbf{h}_t^L + \mathbf{g}_t \quad (23)$$

式中: N_A 为新息向量的数量; $\lambda_{t-m|t-1}$ 为 $t-m$ 到 $t-1$ 时刻的新息向量。

2) 采用双异常值检测方法检测离群点。本文首先采用孤立森林算法来判断数据集中是否存在不准

确的值, 该算法是一种基于树的异常检测方法, 旨在识别数据集中的离群点, 核心思想在于利用异常点在特征空间中的孤立性来进行检测, 检测步骤见附录 A。然后, 运用箱线图法确定需要校正的离群点, 这是一种基于数据分布的离群点检测方法, 主要依赖数据的统计特性来判断是否存在异常值。相比于单一的离群点检测方法, 采用双异常值检测方法能够提高检测的准确性, 降低误报率。

假设新息向量数据样本数量为 n , 其路径长度为 $h(n)$, 本文将孤立森林算法中的 $h(n)$ 作为离群点指标。具体地, 离群点的平均路径长度 $c_L(n)$ 如式(24)所示。

$$c_L(n) = 2H(n-1) - \frac{2(n-1)}{n} \quad (24)$$

式中, $H(n-1)$ 为谐波数。通过对孤立二叉树的长度进行归一化处理, 可以得到离群点的判断指标为

$$s(\lambda_i, n) = 2 \frac{E(h(\lambda_i))}{c_L(n)} \quad (25)$$

$$\begin{cases} s(\lambda_i, n) \rightarrow 1, \lambda_i \text{ 是离群点} \\ s(\lambda_i, n) \rightarrow 0, \lambda_i \text{ 不是离群点} \end{cases} \quad (26)$$

式中, $s(\lambda_i, n)$ 表示离群点指数。

计算预测的新息向量 $\hat{\lambda}_i$ 与原始新息向量 λ_i 之间的偏差 ρ_i , 如式(27)所示。

$$\rho_i = \hat{\lambda}_i - \lambda_i \quad (27)$$

箱线图法阈值判断公式为

$$L_1 = Q_{31} + 1.5 \times I_{QR1} \quad (28)$$

$$L_2 = Q_{11} - 1.5 \times I_{QR1} \quad (29)$$

式中: L_1 是 ρ_i 的上边缘; L_2 是 ρ_i 的下边缘; Q_{31} 是 ρ_i 的上四分位数; Q_{11} 是 ρ_i 的下四分位数; I_{QR1} 是四分位数间距 ($I_{QR1} = Q_{31} - Q_{11}$)。当 ρ_i 大于 L_1 或小于 L_2 时, 采用预测的新息向量代替原始新息向量。为提高最终新息向量的准确性, 本文在检测原始新息向量的离群点之前, 采用双异常值检测方法检测 ALSTNet_{GS} 模型的预测结果中的离群点, 步骤与前述相似, 具体步骤见附录 A。

3) 将处理好的新息向量应用于 UPF 的迭代过程中, 并结合式(10)计算未知的量测噪声协方差矩阵。

4 算例分析

本文选取了 IEEE33 节点与 IEEE118 节点标准配电系统作为算法的估计性能测试系统, 以验证所提出的改进 Att-LSTNet 与 UPF 融合的 FASE 方法 (ALSTNet_{GS}-UPF) 的优越性。为了进行对比评估, 本文将其与 4 种方法进行对照, 分别是: 1) UPF; 2) 基

于 LSTNet 和 UPF 的 FASE 方法 (LSTNet-UPF); 3) 基于 Att-LSTNet 和 UPF 的 FASE 方法 (ALSTNet-UPF); 4) 基于 SVR 优化的 Att-LSTNet 和 UPF 的 FASE 方法 (SALSTNet-UPF)。在本文实验中, 电网数据来自于一个真实的配电系统^[31], 用于生成训练集和测试集。本文模型使用 Python 软件进行模型训练, 并在系统上搭建了基于 Add Interpreter 的编译环境, 同时安装 Pycharm 作为编译软件进行调试, 基于 Tensorflow-gpu 框架训练模型。本文的实验硬件平台基于一台 Lenovo 启天 M450-A245 计算机, 配备 16 GB 内存, 显卡是 RTX 1660Ti, 显存为 6 G。

为了直观地展示各个方法的估计性能, 本文对测试集数据进行状态估计, 并将其与真实值进行比较以获得绝对误差值。此外, 根据均方根误差 (root mean squared error, RMSE) 和平均绝对误差 (mean absolute error, MAE) 来评估上述方法的估计性能^[32]。

$$\mathcal{J}_{\text{RMSE}} = \sqrt{\frac{1}{G} \sum_{g=1}^G (\hat{x}_g - x_t)^2} \quad (30)$$

$$\mathcal{J}_{\text{MAE}} = \frac{1}{G} \sum_{g=1}^G |\hat{x}_g - x_t| \quad (31)$$

式中: $\mathcal{J}_{\text{RMSE}}$ 是 RMSE 值; \mathcal{J}_{MAE} 是 MAE 值; G 是状态量维数; x_t 是真实值; \hat{x}_g 是估计值。

4.1 IEEE33 节点标准配电系统测试

在 IEEE33 节点标准配电系统中, 如图 4 所示, 节点 5、14 处安装了光伏单元 PV1 和 PV2, 二者容量均为 600 kW。从支路 1-2、支路 2-3、支路 3-4 和支路 9-10 的节点注入功率中获得实际量测值, 并根据节点 2—33 处的负荷数据生成了伪量测值。为了准确地模拟主动配电网的真实数据条件, 本文在负荷数据中添加了 45% 的均匀噪声, 并在节点注入功率中添加了 1% 的均匀噪声。此外, 本文利用真实的负荷数据生成了 6750 个量测状态对作为数据集, 随机选择了其中的 4000 个量测状态对作为训练集, 剩余的量测状态对作为测试集。为了与模拟系统中的功率需求相匹配, 并克服不同数据之间的量纲差异, 使用 Matlab 中的 mapminmax 函数对数据进行归一化处理。

4.2 模型参数设置

在算例中, 利用 GSA 优化了 SVR 中的惩罚参数 C 和核函数参数 γ 。优化后的参数值及 ALSTNet_{GS} 模型的其他参数设置如表 1 所示。

4.3 估计精度与时效性分析

为验证所提 ALSTNet_{GS}-UPF 方法在非高斯情况下的估计精度, 本文进行了双峰高斯混合噪声的模拟试验。在所有的历史量测数据中叠加双峰高斯

混合噪声, 并将其与在 Gaussian 白噪声情况下的估计结果进行对比。所模拟的两种噪声如表 2 所示, 其中

I 为单位矩阵。

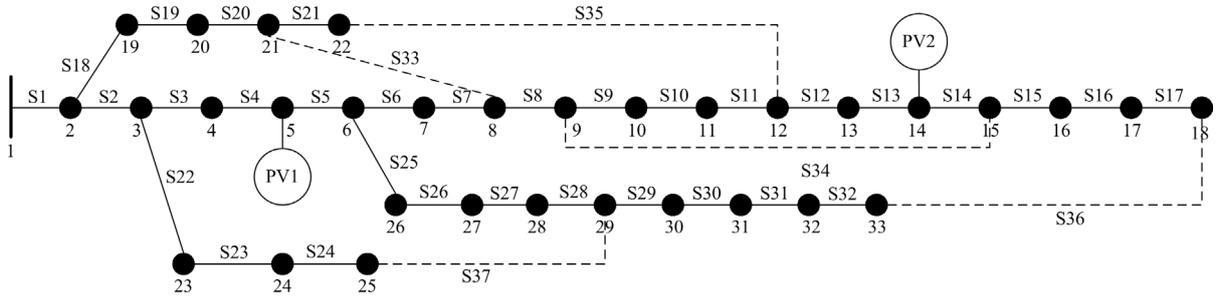


表 3 5 种方法在 Gaussian 白噪声下的估计性能

Table 3 Estimation performance of five methods under Gaussian white noise

方法	电压幅值/($\times 10^{-4}$ p.u.)		电压相角/($\times 10^{-4}$ °)	
	RMSE	MAE	RMSE	MAE
UPF	2.0114	1.8195	2.0547	1.9168
LSTNet-UPF	1.6639	1.2899	1.9713	1.3469
ALSTNet-UPF	1.6493	1.2842	1.6823	1.3129
SALSTNet-UPF	1.4608	1.2086	1.4742	1.2263
ALSTNet _{GS} -UPF	0.1042	0.1014	0.1215	0.1137

表 4 5 种方法在双峰高斯混合噪声下的估计性能

Table 4 Estimation performance of five methods under bimodal Gaussian mixed noise

方法	电压幅值/($\times 10^{-4}$ p.u.)		电压相角/($\times 10^{-4}$ °)	
	RMSE	MAE	RMSE	MAE
UPF	2.1282	1.8293	2.3683	2.1654
LSTNet-UPF	1.7738	1.2949	1.8719	1.4795
ALSTNet-UPF	1.7644	1.2886	1.8369	1.3925
SALSTNet-UPF	1.5139	1.2304	1.5683	1.2405
ALSTNet _{GS} -UPF	0.1051	0.1192	0.1828	0.1763

表 5 5 种方法的运算时间比较

Table 5 Computational time comparison of five methods

方法	运算时间/s	
	高斯白噪声	双峰高斯混合噪声
UPF	1.86	2.61
LSTNet-UPF	2.83	3.81
ALSTNet-UPF	3.64	4.73
SALSTNet-UPF	3.71	4.82
ALSTNet _{GS} -UPF	5.59	6.84

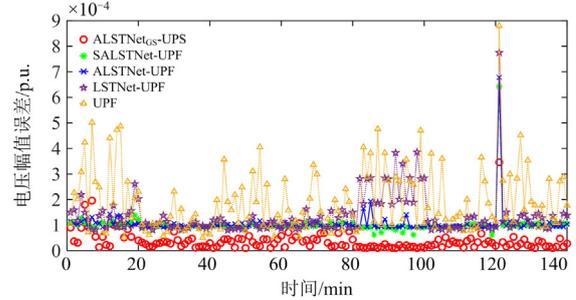
由表 5 可知，在两种噪声情况下，尽管 UPF 具有最短的运算时间，但由表 3 和表 4 可知，UPF 的估计精度最低。与其他 4 种方法相比，本文所提方法的运算速度最慢，但通过 ALSTNet_{GS} 模型的离线训练，其在线估计时间极短。在完成模型构建和训练后，在硬件设备的支持下，估计时间能够缩短至毫秒级。同时，通过对比表 3 和表 4 的数据可知，本文所提方法具备较高的估计精度。因此，仿真结果表明，ALSTNet_{GS}-UPF 方法在求解性能上表现出优越性。

4.4 鲁棒性分析

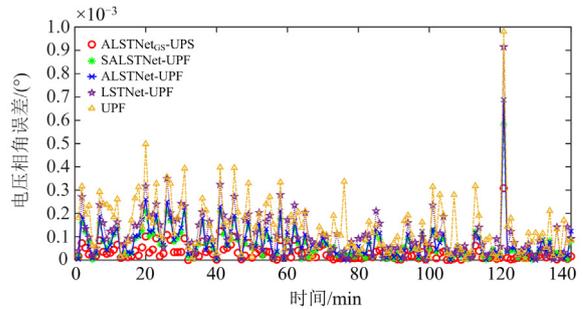
为验证本文方法在系统量测中包含坏数据时的鲁棒性，本文通过在负荷数据中添加 $5\sigma \sim 11\sigma$ (σ 为标准差) 坏数据来模拟主动配电网中出现坏数据的情况。并对 5 种方法进行估计性能测试。

由图 7 可知，与仅存在高斯白噪声的情况相比，

坏数据的存在使得 5 种方法的估计误差增大且波动更剧烈，甚至出现了突变情况。然而，本文提出的方法在对含有坏数据的量测及其相邻量测进行估计时仍比其他 4 种方法更接近真实值，表现出较高的估计精度。此外，ALSTNet_{GS}-UPF 方法的误差曲线也是 5 种方法中最平缓的。



(a) 电压幅值估计精度对比



(b) 电压相角估计精度对比

图 7 存在坏数据时的估计结果

Fig.7 Estimation results in the presence of bad data

由表 6 可知，与高斯白噪声情况相比，本文方法的 RMSE 和 MAE 值分别增大了 11.23%、66.75%、12.03% 和 57.34%，而这 4 个增幅均小于其他 4 种方法的增幅。本文所提方法结合了 GSA 的鲁棒性、Att-LSTNet 模型的序列建模能力及 GSA-SVR 模型的稳定性，可以在存在坏数据的情况下更准确地预测新息向量。并通过孤立森林算法和箱线图法对异

表 6 5 种方法在存在坏数据时的估计性能

Table 6 Estimation performance of five methods in the presence of bad data

方法	电压幅值/($\times 10^{-4}$ p.u.)		电压相角/($\times 10^{-4}$ °)	
	RMSE	MAE	RMSE	MAE
UPF	2.1214	1.8662	6.6397	6.2282
LSTNet-UPF	1.7608	1.2915	5.3203	4.7275
ALSTNet-UPF	1.7592	1.2709	2.4611	2.1574
SALSTNet-UPF	1.5781	1.2303	1.9853	1.8728
ALSTNet _{GS} -UPF	0.1159	0.1136	0.2026	0.1789

常值具有一定的容忍性。因此, 本文方法面对存在坏数据的情况时能够有效地应对, 并展现出更强的鲁棒性。

4.5 泛化能力分析

在主动配电网中, 如电网扩建或自然灾害等因素可能导致网络拓扑结构频繁变化, 因此需要及时更新和重新训练模型, 以适应新的网络拓扑场景。具备强泛化能力的模型能够从训练数据中学习到一般规律和模式, 更好地适应新的网络拓扑场景, 并产生更准确的预测结果^[33]。为验证所提方法的强泛化能力, 本文将 IEEE118 节点标准配电系统作为测试系统, 如图 8 所示, 在表 7 所示的 3 个不同场景下进行测试。

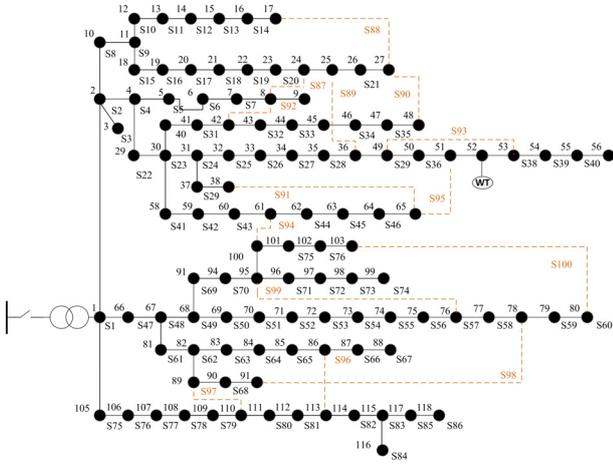


图 8 IEEE118 节点标准配电系统

Fig. 8 IEEE118-bus benchmark distribution network

表 7 不同网络拓扑结构类型

Table 7 Different network topology types

场景	类型
1	断开线路 7-8、28-29, 闭合线路 25-29, 9-15
2	断开线路 7-8、11-12, 闭合线路 21-8, 22-12
3	断开线路 11-12、28-29, 闭合线路 22-12, 25-29

为直观比较本文所提方法与其他 4 种方法在估计精度上的表现, 将 5 种方法的状态估计值与真实值进行对比。当误差在 10^{-4} 内时, 则认为该估计值合格, 并计算 5 种方法的合格率, 其结果如图 9 所示。

由图 9 和表 8 可知, 本文方法在新的网络拓扑场景下能更准确地预测未知数据, 从而为 UPF 提供更准确的新息向量, 具有最高的合格率和最佳的估计效果。因此, 仿真结果表明该方法对于部分主动配电网拓扑结构展现出了较强的泛化能力和普适性。

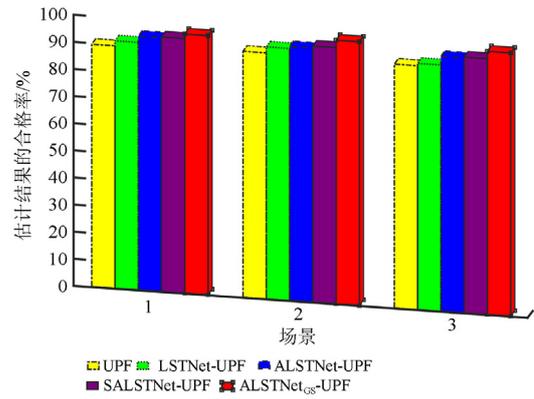


图 9 5 种方法在不同网络拓扑场景下的电压幅值合格率
Fig. 9 Voltage amplitude pass rate of five methods in different network topology scenarios

表 8 5 种方法在不同场景下的估计性能

Table 8 Estimation performance of five methods in different scenarios

场景	方法	电压幅值/ $(\times 10^{-4}$ p.u.)		电压相角/ $(\times 10^{-4} ^\circ)$	
		RMSE	MAE	RMSE	MAE
1	UPF	2.0457	1.8617	2.0991	2.0815
	LSTNet-UPF	1.7072	1.2917	1.7644	1.3283
	ALSTNet-UPF	1.7066	1.2676	1.7524	1.2842
	SALSTNet-UPF	1.5505	1.2198	1.5915	1.4544
	ALSTNet _{GS} -UPF	0.1077	0.1062	0.2406	0.1649
2	UPF	2.0983	1.8932	2.1149	1.9151
	LSTNet-UPF	1.7352	1.2808	1.8095	1.7861
	ALSTNet-UPF	1.7032	1.2794	1.8072	1.7205
	SALSTNet-UPF	0.1469	1.2143	1.5869	1.5046
	ALSTNet _{GS} -UPF	0.1078	0.1053	0.2950	0.2659
3	UPF	2.1174	1.9165	2.2748	2.1496
	LSTNet-UPF	1.7563	1.2911	1.8779	1.8545
	ALSTNet-UPF	1.7005	1.2664	1.8731	1.7314
	SALSTNet-UPF	1.5875	1.2118	1.5920	1.5311
	ALSTNet _{GS} -UPF	0.1053	0.0974	0.1161	0.0979

4.6 有效性分析

为验证所提方法的有效性, 将 ALSTNet_{GS}-UPF 方法与现有的 SC-DNN 方法^[32]、改进 SMOTE-Prophet-PF 方法^[33]和 PF&CNN 方法^[34]在估计精度、估计时间和鲁棒性 3 个方面进行对比, 结果如表 9 所示。

由表 9 可知, 尽管本文所提 ALSTNet_{GS}-UPF 方法在估算时间上不是最短的, 但与估算时间最短的 SC-DNN 方法相比, 其 RMSE 和 MAE 值分别在两种情况下减小了 34.23%、34.02%和 32.96%、33.13%, 表现出更高的估计精度和更强的鲁棒性。虽然改进

SMOTE-Prophet-PF 方法具有最小的 RMSE 和 MAE 值,但其时间复杂度最高,相比之下,ALSTNet_{GS}-UPF 方法的估计时间分别减小了 68.37%和 79.45%。综合来看,本文所提 ALSTNet_{GS}-UPF 方法在兼具时效性的同时也具有较高的鲁棒性,并具有实际应用潜力。

表 9 3 种不同方法的估计性能对比

Table 9 Comparison of estimation performance of three different methods

场景	方法	电压幅值/($\times 10^{-4}$ p.u.)		估计时间/s
		RMSE	MAE	
正常情况	SC-DNN	0.1659	0.1587	0.029
	改进			
	SMOTE-Prophet-PF	0.1085	0.1027	0.117
	PF&CNN	0.1293	0.1274	0.076
	ALSTNet _{GS} -UPF	0.1091	0.1047	0.037
异常情况	SC-DNN	0.1762	0.1654	0.045
	改进			
	SMOTE-Prophet-PF	0.1123	0.1093	0.253
	PF&CNN	0.1357	0.1341	0.097
	ALSTNet _{GS} -UPF	0.1146	0.1106	0.052

5 结语

本文利用 GSA-SVR 模型对 Att-LSTNet 模型的架构进行改进,构建了 ALSTNet_{GS} 模型,并对传统的 UPF 进行优化,提出了一种基于改进 Att-LSTNet 和 UPF 融合的主动配电网 FASE 方法,得到以下结论。

1) 通过采用 GSA 对 SVR 进行优化,有效克服了使用 SVR 时参数选择容易陷入局部最优解的问题。将优化后的模型嵌入到 Att-LSTNet 模型中,提高了模型的预测精度及泛化能力。

2) 基于 UPF 中的新息向量对 ALSTNet_{GS} 模型进行训练,并结合孤立森林算法和箱线图法对原始新息向量进行监控和修正。该方法能够提供更准确的新息向量,在面对量测存在非高斯混合噪声和坏数据的情况下,具备较高的估计精度和鲁棒性。

3) 结合修正后的新息向量和 UPF,计算未知的量测噪声协方差矩阵,在一定程度上解决了量测噪声协方差矩阵未知带来的影响,提高了所提方法的收敛速度。通过运用优化后的 UPF 对系统的状态量进行估计,提高了估计结果的准确性。

未来的研究将重点关注所提方法在三相不平衡网络的应用上,以进一步增强其在实际应用中的有效性。

附录 A

1) 孤立森林算法的检测步骤

(1) 随机选择特征和随机切分:首先随机选择一

个特征,然后在该特征的取值范围内随机选择一个切分点。

(2) 构建树:将数据分为两部分,一部分是取该特征值小于切分点的数据,另一部分是大于等于切分点的数据。重复此过程,递归地构建一棵二叉树。

(3) 重复构建多棵树:重复上述步骤,构建多棵树。

(4) 计算异常分值:对于一个数据点,通过计算它在每棵树中的路径长度 h 的平均值 c ,来衡量该点的异常分值。异常分值越高,表示数据点是离群点的概率越大。

2) ALSTNet_{GS} 模型预测值中离群点的处理方法
假设 ALSTNet_{GS} 模型预测值的数据样本数量为 n ,其路径长度为 $h(n)$,本文将孤立森林算法中的 $h(n)$ 作为离群点指标。具体地,离群点的平均路径长度 $c_L(n)$ 为

$$c_L(n) = 2H(n-1) - \frac{2(n-1)}{n} \quad (A1)$$

式中, $H(n-1)$ 为谐波数。通过对孤立二叉树的长度进行归一化处理,可以得到离群点的判断指标。

$$s(\hat{Y}_t, n) = 2^{\frac{E(h(\hat{Y}_t))}{c_L(n)}} \quad (A2)$$

$$\begin{cases} s(\hat{Y}_t, n) \rightarrow 1, \hat{Y}_t \text{ 是离群点} \\ s(\hat{Y}_t, n) \rightarrow 0, \hat{Y}_t \text{ 不是离群点} \end{cases} \quad (A3)$$

式中: $s(\hat{Y}_t, n)$ 表示离群点指数; $E(h(\hat{Y}_t))$ 表示某个给定值的路径长度的期望。

然后,计算预测值 \hat{Y}_t 与原始值 Y_t 之间的偏差 ρ_2 。

$$\rho_2 = \hat{Y}_t - Y_t \quad (A4)$$

箱线图法阈值判断公式为

$$L_3 = Q_{32} + 1.5 \times I_{QR2} \quad (A5)$$

$$L_4 = Q_{12} - 1.5 \times I_{QR2} \quad (A6)$$

式中: L_3 是 ρ_2 的上边缘; L_4 是 ρ_2 的下边缘; Q_{32} 是 ρ_2 的上四分位数; Q_{12} 是 ρ_2 的下四分位数; I_{QR2} 是四分位数间距 ($I_{QR2} = Q_{32} - Q_{12}$)。当 ρ_2 大于 L_3 或小于 L_4 时,调整 ALSTNet_{GS} 模型的随机种子数,然后重新进行预测。

参考文献

- [1] 高立克,陈绍南,秦丽文,等.基于混合整数非线性方法的配网可靠性规划[J].高压电器,2022,58(9):182-189,196.
GAO Like, CHEN Shaonan, QIN Liwen, et al. Reliability planning of distribution network based on mixed integer nonlinear method[J]. High Voltage Apparatus, 2022, 58(9): 182-189, 196.

- [2] 俞拙非, 刘菲, 刘瑞环, 等. 面向配电网弹性提升的源网荷灵活资源优化研究综述及展望[J]. 中国电力, 2022, 55(4): 132-144.
YU Zhuofei, LIU Fei, LIU Ruihuan, et al. Resilience-oriented optimization of source-grid-load flexible resources in distribution systems: review and prospect[J]. Electric Power, 2022, 55(4): 132-144.
- [3] 叶耀, 龚锦霞, 李琛舟, 等. 一种考虑分布式电源的配电网自动化系统规划方法[J]. 智慧电力, 2022, 50(10): 109-115.
YE Yao, GONG Jinxia, LI Chenzhou, et al. A planning method for distribution automation system considering distributed generation[J]. Smart Power, 2022, 50(10): 109-115.
- [4] 赵化时, 李胜, 林子杰, 等. 电力系统低模型耦合智能状态估计[J]. 电力科学与技术学报, 2022, 37(2): 116-128.
ZHAO Huashi, LI Sheng, LIN Zijie, et al. Smart power system state estimation with low model coupling[J]. Journal of Electric Power Science and Technology, 2022, 37(2): 116-128.
- [5] 黄崇鑫, 洪明磊, 伏帅, 等. 考虑虚假数据注入攻击的有源配电网分布式状态估计[J]. 电力工程技术, 2022, 41(3): 22-31.
HUANG Chongxin, HONG Minglei, FU Shuai, et al. Distributed state estimation of active distribution network considering false data injection attack[J]. Electric Power Engineering Technology, 2022, 41(3): 22-31.
- [6] 龚逊东, 费有蝶, 凌佳凯, 等. 基于深度神经网络仿量测建模的交直流混合配电网交替迭代法状态估计[J]. 电力建设, 2022, 43(10): 111-120.
GONG Xundong, FEI Youdie, LING Jiakai, et al. alternating-iteration state estimation of AC/DC hybrid distribution system based on pseudo-measurement modeling using deep neural network[J]. Electric Power Construction, 2022, 43(10): 111-120.
- [7] SCHWEPPE F C, WILDES J. Power system static-state estimation, part I: exact model[J]. IEEE Transactions on Power Systems, 1970, 89(1): 120-125.
- [8] 黄蔓云, 王天昊, 卫志农, 等. 基于长短期记忆网络的 UKF 动态谐波状态估计[J]. 电力系统保护与控制, 2022, 50(11): 1-11.
HUANG Manyun, WANG Tianhao, WEI Zhinong, et al. Dynamic harmonic state estimation of an unscented Kalman filter based on long short-term memory neural networks[J]. Power System Protection and Control, 2022, 50(11): 1-11.
- [9] 田钧祥, 陈铁, 陈彬. 基于改进自适应 UKF 算法的中压配电网鲁棒动态状态估计方法[J]. 中国电力, 2023, 56(11): 128-133.
TIAN Junxiang, CHEN Tie, CHEN Bin. Robust dynamic state estimation method for medium voltage distribution networks based on improved adaptive UKF algorithm[J]. Electric Power, 2023, 56(11): 128-133.
- [10] 杨德昌, 王雅宁, 李朝霞, 等. 基于改进粒子滤波的综合能源系统预测辅助状态估计[J]. 电力工程技术, 2022, 41(6): 172-181.
YANG Dechang, WANG Yaning, LI Zhaoxia, et al. Forecasting-aided state estimation of integrated energy systems based on improved particle filter[J]. Electric Power Engineering Technology, 2022, 41(6): 172-181.
- [11] YU Shenglong, GUO Junhao, TAT K C, et al. An unscented particle filtering approach to decentralized dynamic state estimation for DFIG wind turbines in multi-area power systems[J]. IEEE Transactions on Power Systems, 2020, 35(4): 2670-2682.
- [12] 周家玉, 侯慧娟, 盛戈峰, 等. 状态参量关联规则挖掘及深度学习融合的变压器故障诊断算法[J]. 高压电器, 2023, 59(3): 108-115.
ZHOU Jiayu, HOU Huijuan, SHENG Gehao, et al. Transformer fault diagnosis algorithm based on association rules mining of state parameters and deep learning[J]. High Voltage Apparatus, 2023, 59(3): 108-115.
- [13] FAIAZ A, NAZIA H D, SUBRATA K S, et al. Data-driven next-generation smart grid towards sustainable energy evolution: techniques and technology review[J]. Protection and Control of Modern Power Systems, 2023, 8(3): 696-737.
- [14] ZHENG Chao, WANG Shaorong, LIU Yilu, et al. A novel equivalent model of active distribution networks based on LSTM[J]. IEEE Transactions on Neural Networks and Learning Systems, 2019, 30(9): 2611-2624.
- [15] 季玉琦, 严亚帮, 和萍, 等. 基于 K-Medoids 聚类与栅格法提取负荷曲线特征的 CNN-LSTM 短期负荷预测[J]. 电力系统保护与控制, 2023, 51(18): 81-93.
JI Yuqi, YAN Yabang, HE Ping, et al. CNN-LSTM short-term load forecasting based on the K-Medoids clustering and grid method to extract load curve features[J]. Power System Protection and Control, 2023, 51(18): 81-93.
- [16] GUO Xifeng, GAO Ye, LI Yupeng, et al. Short-term household load forecasting based on long-and short-term time-series network[J]. Energy Reports, 2021, 7: 58-64.
- [17] 乔石, 王磊, 张鹏超, 等. 基于模态分解及注意力机制长短时间网络的短期负荷预测[J]. 电网技术, 2022, 46(10): 3940-3951.
QIAO Shi, WANG Lei, ZHANG Pengchao, et al. Short-term load forecasting by long- and short-term temporal networks with attention based on model decomposition[J]. Power System Technology, 2022, 46(10): 3940-3951.
- [18] YATCHEW A. Nonparametric regression techniques in economics[J]. Journal of Economic Literature, 1998, 36(2): 669-721.

- [19] TEODORA D, URBAN R, RAFAEL M. Indirect power-system contingency screening for real-time applications based on PCA[J]. IEEE Transactions on Power Systems, 2018, 33(1): 1080-1081.
- [20] 刘俊磊, 钱峰, 伍双喜, 等. 基于支持向量回归的直流受端电网动态无功需求在线评估[J]. 电力系统保护与控制, 2019, 47(13): 37-45.
LIU Junlei, QIAN Feng, WU Shuangxi, et al. Online evaluation of dynamic reactive power demand of DC receiving power grid based on SVR[J]. Power System Protection and Control, 2019, 47(13): 37-45.
- [21] JAHAN I S, SNASEL V, MISAK S. Intelligent systems for power load forecasting: a study review[J]. Energies, 2020, 13(22): 6105.
- [22] 赵晋斌, 张建平, 毛玲, 等. 基于 PSO-Soft attention 双向 LSTM 算法的光伏发电量预测研究[J]. 智慧电力, 2022, 50(3): 1-7.
ZHAO Jinbin, ZHANG Jianping, MAO Ling, et al. photovoltaic power generation forecasting based on PSO-Soft attention bidirectional LSTM algorithm[J]. Smart Power, 2022, 50(3): 1-7.
- [23] 孙湛冬, 焦娇, 李伟, 等. 基于改进蚁群算法的电力云数据中心任务调度策略研究[J]. 电力系统保护与控制, 2022, 50(2): 95-101.
SUN Zhandong, JIAO Jiao, LI Wei, et al. A task scheduling strategy for a power cloud data center based on an improved ant colony algorithm[J]. Power System Protection and Control, 2022, 50(2): 95-101.
- [24] XU Hongzuo, PANG Guansong, WANG Yijie, et al. Deep isolation forest for anomaly detection[J]. IEEE Transactions on Knowledge and Data Engineering, 2023, 35(12): 12591-12604.
- [25] 张超, 王星星, 张冰玉, 等. 大数据技术在分布式光伏用户管理中的应用[J]. 河北电力技术, 2019, 38(2): 10-12.
ZHANG Chao, WANG Xingxing, ZHANG Bingyu, et al. Application of big data in distributed photovoltaic user management[J]. Hebei Electric Power, 2019, 38(2): 10-12.
- [26] 罗永平, 刘敏, 谭文勇, 等. 基于无迹粒子滤波的配电网状态估计[J]. 电测与仪表, 2020, 57(16): 71-77.
LUO Yongping, LIU Min, TAN Wenyong, et al. State estimation of distribution network based on unscented particle filtering[J]. Electrical Measurement & Instrumentation, 2020, 57(16): 71-77.
- [27] 王增平, 赵兵, 纪维佳, 等. 基于 GRU-NN 模型的短期负荷预测方法[J]. 电力系统自动化, 2019, 43(5): 53-62.
WANG Zengping, ZHAO Bing, JI Weijia, et al. Short-term load forecasting method based on GRU-NN model[J]. Automation of Electric Power Systems, 2019, 43(5): 53-62.
- [28] RASHEDI E, NEZAMABADI-POUR H, SARYAZDI S. GSA: a gravitational search algorithm[J]. Information Sciences, 2009, 179(13): 2232-2248.
- [29] 熊红林, 冀和, 樊重俊, 等. 基于 LSTM-SVR 模型的航空旅客出行指数预测[J]. 系统管理学报, 2020, 29(6): 1169-1176.
XIONG Honglin, JI He, FAN Zhongjun, et al. Forecast of travel index of air passengers based on LSTM-SVR model[J]. Journal of Systems & Management, 2020, 29(6): 1169-1176.
- [30] LI Huixuan, LI Peng, ZHANG Yihan, et al. Research on electricity demand forecasting based on LSTM-SVR[C] // 2022 2nd International Conference on Algorithms, High Performance Computing and Artificial Intelligence (AHPCAI), October 23-25, 2022, Guangzhou, China: 233-239.
- [31] A real 240-bus distribution system with one-year smart meter data[EB/OL]. <http://wzy.ece.iastate.edu/testsystem.html>.
- [32] 宋雨露, 樊艳芳, 刘牧阳, 等. 基于 SC-DNN 和多源数据融合的新能源电力系统状态估计方法[J]. 电力系统保护与控制, 2023, 51(9): 177-187.
SONG Yulu, FAN Yanfang, LIU Muyang, et al. State estimation method of a new energy power system based on SC-DNN and multi-source data fusion[J]. Power System Protection and Control, 2023, 51(9): 177-187.
- [33] WANG Xiaobo, ZHAO Junbo, HUANG Zhenyu, et al. Assessing Gaussian assumption of PMU measurement error using field data[J]. IEEE Transactions on Power Delivery, 2018, 33(6): 3233-3236.
- [34] 刘晓莉, 曾祥晖, 黄翊阳, 等. 联合粒子滤波和卷积神经网络的电力系统状态估计方法[J]. 电网技术, 2020, 44(9): 3361-3367.
LIU Xiaoli, ZENG Xianghui, HUANG Yiyang, et al. State estimation based on particle filtering and convolutional neural networks for power systems[J]. Power System Technology, 2020, 44(9): 3361-3367.

收稿日期: 2023-08-18; 修回日期: 2023-12-13

作者简介:

王 玥(1999—), 女, 硕士研究生, 研究方向为电力系统状态估计; E-mail: 974467139@qq.com

于 越(1998—), 男, 硕士研究生, 研究方向为基于机器学习的电力系统状态估计; E-mail: yuyue_98@163.com

金朝阳(1991—), 男, 通信作者, 副教授, 硕士生导师, 研究方向为低惯量电力系统关键参数估计、电力系统状态估计。E-mail: zhaoyang.jin@sdu.edu.cn

(编辑 张 颖)