

基于 Tri-Training-LASSO-BP 网络的 静态电压稳定裕度在线预测方法

唐滢淇¹, 董树锋^{1*}, 朱承治², 吴金城¹, 宋永华³

(1. 浙江大学电气工程学院, 浙江省 杭州市 310027; 2. 国网浙江省电力有限公司, 浙江省 杭州市 310007;
3. 澳门大学智慧城市物联网国家重点实验室, 澳门特别行政区 999078)

Online Prediction Method of Static Voltage Stability Margin Based on Tri-Training-LASSO-BP Network

TANG Yingqi¹, DONG Shufeng^{1*}, ZHU Chengzhi², WU Jincheng¹, SONG Yonghua³

(1. College of Electrical Engineering, Zhejiang University, Hangzhou 310027, Zhejiang Province, China;

2. State Grid Zhejiang Electric Power Co., Ltd., Hangzhou 310007, Zhejiang Province, China;

3. State Key Laboratory of Internet of Things for Smart City, University of Macau, Macau SAR 999078, China)

ABSTRACT: The static voltage stability of power system plays a key role in ensuring operation of the system. Traditional static voltage stability margin assessment methods are difficult to meet the requirements of online real-time monitoring. Common offline surveillance prediction methods require a large number of training samples, and are prone to over-fitting, leading to impact the accuracy of prediction. Therefore, it is of great significance to study ways overcoming these weak points. In this paper, neural network, semi-supervised training, integrated learning and other techniques were applied to the prediction and analysis of static voltage stability margin of power systems. An online prediction method based on Tri-Training-LASSO-BP network was proposed. The network consists of Tri-Training, the least absolute shrinkage and select operator (LASSO) algorithm and the back propagation (BP) neural network. The results on the IEEE 39-node example and IEEE 300-node example and non-parametric tests performed on the results show that the proposed method can reduce the requirement of the data volume of training set, take advantage of the massive data collected during the daily operation of the power system, improve the prediction accuracy of the network and reduce manual intervention.

KEY WORDS: static voltage stability margin; Tri-Training; LASSO-BP neural network; ensemble learning; Mann-Whitney U test

摘要: 电力系统的静态电压稳定性, 对于保证系统正常运行

起着关键作用。传统的静态电压稳定裕度评估方法难以满足在线实时预测的要求, 常用的离线监督预测方法则需要大量的训练样本, 且容易出现过拟合, 会对预测精度造成影响。研究能克服这些缺点的方法, 具有重要意义。该文将神经网络、半监督训练、集成学习等技术应用于电力系统静态电压稳定裕度的预测分析中, 提出基于 Tri-Training-LASSO-BP 网络的在线预测方法, 由三体训练法(Tri-Training)、最小绝对值收缩选择(least absolute shrinkage and select operator, LASSO)方法和误差反向传播(back propagation, BP)神经网络组成。在 IEEE 39 节点和 IEEE 300 节点算例上的结果和对其进行的非参数检验表明, 该方法能够降低对训练集数据量的要求, 发挥电力系统日常运行过程中采集的海量数据的优势, 提高网络的预测精度, 减少人工干预。

关键词: 静态电压稳定裕度; 三体训练法; LASSO-BP 神经网络; 集成学习; Mann-Whitney U 检验

0 引言

近年来, 世界范围内发生了多起重大停电事故^[1-6], 给电力企业的经济效益造成了损失, 也对社会经济的发展造成了严重影响^[7]。总结这些停电事故发现, 相比电力系统同步运行稳定和频率稳定, 电压稳定呈现出更强的突发性和隐蔽性的特点, 电力系统大规模停运绝大部分是静态电压稳定性被破坏造成的^[8]。因此, 静态电压稳定性成为广泛关注的问题。

电力系统静态电压稳定性分析中, 电压稳定裕度指标能够提供直观的信息^[9], 传统的电压稳定裕

基金项目: 国家电网公司科技项目(52110418000N)。

Science and Technology Project of State Grid Corporation of China (52110418000N).

度评估方法都是基于潮流方程的，计算速度慢，难以满足在线实时预测的要求^[10]。随着电力系统网架结构日新月异的变化，传统离线评估电力系统电压稳定裕度的方法难以适应速度和精度上的要求。

国内外研究多采用神经网络、支持向量机^[11]等机器学习方法实现电压稳定裕度的在线预测。文献[12-13]提出了利用单个神经网络估计系统多种故障情况下负荷裕度的方法；文献[14]提出使用模糊神经网络决策树模型对电力系统电压稳定性进行评估。有学者还研究了并行分层自组织神经网络^[15-16]、径向基神经网络^[17]等在静态电压稳定性分析中的应用。文献[18]提出了基于遗传算法的支持向量机 (genetic algorithm and support vector machine, GA-SVM) 在线预测电压稳定性；文献[19]使用了带误差反向传播学习的多层前馈神经网络预测电压稳定性；文献[20]比较了各种神经网络对电力系统电压稳定性评估的优劣。上述方法均采用离线仿真数据训练神经网络，离线建立的训练样本是有限的，离线仿真数据也不可能完全涵盖电网的所有运行状态，因此得到的学习器存在缺陷和不足。同时，电网实际运行的状态是多种多样的，必然有离线训练过程中没有考虑到的因素，因此使用系统运行数据在线进行网络参数的更新和优化具有必要性。

此外，离线监督训练方法需要大量的训练样本，在工程实际中难以满足这样的条件，该方法还容易出现过拟合，对预测精度造成影响。离线训练算法中，更改网络参数只能重新训练再上线，速度和效率较低。随着电力系统自动化水平的提高，减少人工干预成为大趋势。

文献[21]提出使用改进的随机森林算法对电力系统静态电压稳定性进行了在线预测，但这种方法只能判断电网当前运行情况是否安全，无法明确静态电压稳定裕度是多少，属于半监督学习中的分类问题。同时，文献[21]中采用的随机森林模型过于复杂，在算例分析中，对于新得到的在线数据要使用连续潮流法进行再次仿真得到预测值，没有考虑连续潮流法的运行时间，不适合实际工程中在线应用。文献[22]中使用局部回归进行电压稳定裕度的在线自适应预测，但也存在上面提到的问题，即输出变量为离散值而非连续值，无法知道具体的电压稳定裕度。

因此，本文针对上述问题引入了半监督回归方法，给智能电网量测体系中海量的状态估计无标签

数据打上伪标签，参与网络参数的更新，能够预测静态电压稳定裕度的具体值，弥补仅使用离线仿真数据训练网络可能带来的样本覆盖不足等缺陷，降低对训练集样本数目的要求，减少训练过程中的人工干预，用较小的离线训练数据集达到更好的在线预测效果。将本文方法应用到 IEEE 39 节点和 IEEE 300 节点系统，验证了提出的 Tri-Training-LASSO-BP 网络在静态电压稳定裕度预测方面，能够利用无标签状态估计数据提升预测精度。

1 静态电压稳定性分析

1.1 静态电压稳定裕度预测问题

电力系统的静态电压稳定裕度计算如下：

$$K_p = \frac{P_{\max} - P_0}{P_0} \times 100\% \quad (1)$$

式中： K_p 为系统负荷裕度； P_0 为系统当前运行状态下的负荷有功功率； P_{\max} 为系统最大能够承载的负荷有功功率^[23-24]，是用于评估电力系统静态电压稳定性的重要指标。系统当前运行状态下的负荷有功功率 P_0 是已知的，因此要计算静态电压稳定裕度需要先计算得到 P_{\max} 。

静态电压稳定裕度预测问题可以归纳如下：设电力系统当前状态可以用一个 m 维向量 \mathbf{X} 表征，通过对 \mathbf{X} 的分析计算，得出系统静态电压稳定极限点的负荷大小 P_{\max} 的预测值 \hat{P}_{\max} ，使其与真实值的偏差尽可能小。即找到一个函数 f 使得：

$$\begin{cases} \min z = |\hat{P}_{\max} - P_{\max}| \\ \hat{P}_{\max} = f(\mathbf{X}) \end{cases} \quad (2)$$

式中 $\mathbf{X} = [x_1, x_2, \dots, x_{m-1}, x_m]^T$ ， $x_1, x_2, \dots, x_{m-1}, x_m$ 为描述电力系统当前状态的 m 个状态变量，可以是电力系统所有节点各自的电压幅值、相角、有功功率、无功功率，也可以是电力系统所有节点的有功功率之和。

传统的连续潮流法^[10, 25]等计算速度慢，难以满足在线实时预测电压稳定裕度的要求，因此本文的研究重点在于构造新的计算 \hat{P}_{\max} 的函数 f 。根据静态电压稳定裕度预测问题的特点，函数 f 输入为 m 维向量 \mathbf{X} ，输出为系统静态电压稳定极限点的负荷大小预测值 \hat{P}_{\max} 。其中 $\mathbf{X} = [\mathbf{U}, \boldsymbol{\theta}, \mathbf{P}, \mathbf{Q}]^T$ ， $\mathbf{U} = [U_1, U_2, \dots, U_n]^T$ ， U_1, U_2, \dots, U_n 为第 1, 2, ..., n 个节点的电压幅值， $\boldsymbol{\theta} = [\theta_1, \theta_2, \dots, \theta_n]^T$ ， $\theta_1, \theta_2, \dots, \theta_n$ 为第 1, 2, ..., n 个节点的电压相角， $\mathbf{P} = [P_1, P_2, \dots, P_n]^T$ ， P_1, P_2, \dots, P_n

为第 $1, 2, \dots, n$ 个节点的有功功率, $\mathbf{Q} = [Q_1, Q_2, \dots, Q_n]^T$, Q_1, Q_2, \dots, Q_n 为第 $1, 2, \dots, n$ 个节点的无功功率。 \mathbf{U} 已经过标幺化处理, θ 使用弧度为单位, \hat{P}_{\max} 、 \mathbf{P} 和 \mathbf{Q} 均以 S_{base} 为基准, 向量 \mathbf{X} 的维数 $m=4n$, n 为节点数。

1.2 训练样本的划分

本文提出的 Tri-Training-LASSO-BP 网络以神经网络算法为基础, 需要将数据集 S 划分为训练集和测试集。数据集 S 里共 k 个样本, 每个样本均在一定的取值范围内随机生成, 由 m 维向量 \mathbf{X} 和系统静态电压稳定极限点的负荷大小 P_{\max} 构成, 整个数据集 S 表示为

$$S = \{(\mathbf{X}_1, P_{\max,1}), (\mathbf{X}_2, P_{\max,2}), \dots, (\mathbf{X}_k, P_{\max,k})\} \quad (3)$$

将数据集 S 划分为有标签数据集 A 、无标签数据集 B 和测试数据集 C , 样本数量分别为 k_A 、 k_B 、 k_C , 且 $k_A+k_B+k_C=k$ 。有标签数据集 A 中, 输入自变量 \mathbf{X} 和输出响应变量 P_{\max} 都存在, 参与离线训练过程; 无标签数据集 B 模拟了电力系统正常运行过程中使用状态估计方法对大量量测数据进行处理, 得到电力系统当前状态的估计值集合, 含有输入自变量 \mathbf{X} 但不包含输出响应变量 P_{\max} ; 测试数据集 C 模拟了未来某一时刻的电网状态, 可以用来对网络的精度进行测试, 在整个过程中不参与训练。

1.3 Tri-Training-LASSO-BP 网络结构

Tri-Training-LASSO-BP 网络结构如图 1 所示。图 1 中虚线框部分是采用离线监督方式, 先用有标签数据集 A 训练好神经网络后上线进行预测, 这部分是文献中常使用的方法。本文方法增加了神经网络在线半监督训练模块, 能够给无标签数据集 B 打上伪标签, 作为伪标签样本参与网络结构、参数的更新过程。为了测试所提出网络的性能, 用测试数据集 C 对网络的性能进行评估, 测试数据集 C 全程未参与网络的训练过程, 能够在一定程度上模拟实际运行过程中的随机数据, 进而反映网络的性能。

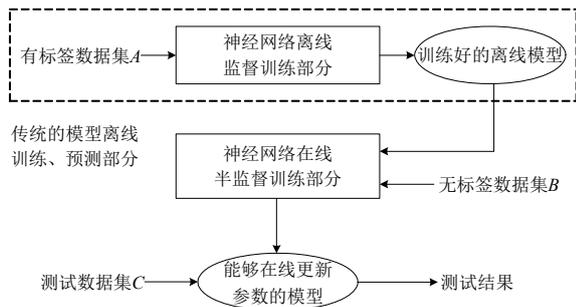


图 1 Tri-Training-LASSO-BP 网络的组成

Fig. 1 Components of Tri-Training-LASSO-BP network

1.4 适应运行方式的变化

电力系统主要运行方式可以按调管职责、时域和系统状态分类, 按时域一般可分为电力系统正常运行方式, 间或出现检修方式。根据系统状态分类则可分为正常运行方式、事故后运行方式和检修运行方式, 其中事故后运行方式的持续时间应尽可能短。在网络建设基本完成, 整体网架结构趋于稳定的情况下, 正常运行方式是电网的主要运行方式, 由调度部门编制, 一般每年只有固定的几套, 其变化是有限的^[26]。因此, 可以针对差异较大的正常运行方式训练不同的模型预测器, 对静态电压稳定性进行预测。而在编制检修运行方式时, 就要进行潮流分布计算、短路容量校验、稳定极限校验工作, 可以在需要编制检修运行方式再重新根据检修设备和电网运行情况训练新的模型预测器。

对于本文所述的 Tri-Training-LASSO-BP 网络, 记其中 3 个不同的 LASSO-BP 子学习器为 M_{1i} 、 M_{2i} 、 M_{3i} , 这 3 个学习器组成一个网络预测器, 记为 $MT_i = \{M_{1i}, M_{2i}, M_{3i}\}$ 。针对差异较大的运行方式训练不同的 Tri-Training-LASSO-BP 网络预测器 MT_1, MT_2, \dots, MT_w , 其中 w 为差异较大的正常运行方式和 $N-1$ 运行方式数。实际上线运行时, 切换运行方式的同时切换预测器, 可以适应运行方式的变化; 检测到 $N-1$ 故障时, 切换相应预测器以适应 $N-1$ 故障下电网拓扑的变化。

2 基于半监督回归的静态电压稳定分析

2.1 数据的预处理

影响电力系统静态电压稳定极限的因素很多, 同时负荷能力极限不能用数学方式解析表达, 所以要选择合适的系统状态量作为输入变量十分困难。如果将所有的系统状态量输入, 训练和预测的速度将会受到影响。为解决这个问题, 引入 LASSO 特征降维方法^[27], 提取样本的关键特征用于网络的训练和测试, 以达到提高算法运行速度, 同时使算法精度不受太大影响的目的。LASSO 方法用模型系数的绝对值函数作为惩罚来压缩模型系数, 使绝对值较小的系数自动压缩为 0, 从而同时实现显著性变量选择和对对应参数的估计^[10]。它克服了传统方法在特征选择模型上的不足, 且其计算复杂度相比其他特征选择算法得到了较好的控制, 时间复杂度与最小二乘法相当^[28]。

针对数据集 S 中每个描述系统状态的样本:

$$(\mathbf{X}_i, P_{\max,i}), i = 1, 2, \dots, k \quad (4)$$

式中 $\mathbf{X}_i = [x_{i,1}, x_{i,2}, \dots, x_{i,m-1}, x_{i,m}]^T$ 。

将 $x_{i,j}$ 进行标准化处理，使 $\sum_i x_{i,j} / N = 0$ ，
 $\sum_i x_{i,j}^2 / N = 1$ ，考虑下述线性回归模型：

$$P_{\max,i} = \alpha + \sum_{j=1}^m \beta_j x_{i,j} + \xi_i, \xi_i \sim N(0, \sigma^2) \quad (5)$$

LASSO 优化的目标函数和约束条件为

$$\begin{cases} z = \arg \min_{\beta} \left\{ \sum_{i=1}^k (P_{\max,i} - \alpha - \sum_{j=1}^m \beta_j x_{i,j})^2 \right\} \\ \sum_{j=1}^m |\beta_j| \leq t \end{cases} \quad (6)$$

式中：函数 z 的目标是最小化残差平方和； α 为常数，假设不失一般性取 $\alpha=0$ ； β_j 为第 j 个变量的回归系数； t 为调整参数且 $t \geq 0$ 。解上述规划问题，设置 t 的大小就能使某些 β_j 为 0，将这些对应的变量删除，起到压缩变量和特征选择的目的。

使用 LASSO 进行数据预处理后的样本为

$$(\mathbf{X}'_i, P_{\max,i}), i = 1, 2, \dots, k \quad (7)$$

式中： $\mathbf{X}'_i = [x_{i,1}, x_{i,2}, \dots, x_{i,m'-1}, x_{i,m'}]^T$ ； m' 为降维后样本的维数， $m' \leq m$ 。 m' 根据 LASSO 问题中约束参数 t 的大小自动调整，约束参数 t 越小， m' 的值也越小。合理地设置 t 的大小就可以控制降维后样本的维数，进而实现在保证预测精度的同时提高网络的训练和预测速度。

2.2 基础学习器的生成

BP 神经网络采用最速下降法为学习规则，反向传播算法用于调节网络的权重值和偏移值，从而使网络的均方误差(mean square error, MSE)最小^[29-30]。在数据预处理基础上，本文半监督训练中的每个学习器都由一个隐含层的 BP 神经网络构建，并使用 LASSO 方法进行预处理，得到的网络称为 LASSO-BP 神经网络学习器^[10]，如图 2 所示，具体参数在下文给出。

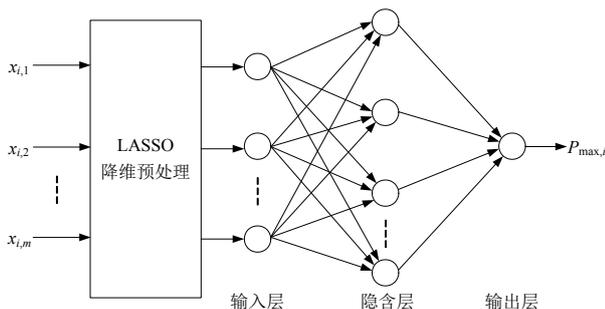


图 2 LASSO-BP 网络

Fig. 2 LASSO-BP network

2.3 在线半监督回归训练

电力系统中的状态估计模块能够利用系统日常运行过程中的量测量得到系统的状态，产生大量描述系统运行状态的数据，即上文提到的 m 维向量 \mathbf{X} ，而这些数据中静态电压稳定极限点的负荷大小 P_{\max} 未知，因此这些数据都属于无标签数据。半监督训练^[31]是介于监督训练和无监督训练之间的一种训练方法，在训练过程中吸收无标签数据的数据特征，能够在数据特征缺失、符合训练要求的有标签数据较少的情况下采用无标签数据进行训练，提升网络的预测精度，降低对训练集样本数目的要求，在有标签数据较少时发挥无标签数据的优势^[32-33]。

对于本文研究的半监督回归问题，常用的解决方法是基于流形学习的方法^[34]和基于差异的方法^[35]。基于流形学习的半监督回归方法参数较多，且选择方法没有指导意义，靠手动调整参数很难得到优化的网络结构和参数。基于差异的方法中，文献[35]最先提出使用协同训练(co-training)算法求解半监督回归问题，利用两个不同阶的回归学习器进行协同训练。为了弥补上述协同训练法的不足，文献[33]提出了三体训练法(tri-training)，它综合了半监督训练、集成学习的优点，提升了学习器的性能。三体训练法没有对数据集的苛刻要求，也不需要不同类型的学习器。

本文针对回归问题对用于分类的三体训练法做了改进，具体实现步骤如下：

1) 准备好有标签数据集 A 、无标签数据集 B 和测试数据集 C ，它们的样本数量分别为 k_A 、 k_B 、 k_C ，且 $k_A + k_B + k_C = k$ 。

2) 处理有标签离线仿真数据集 A ：对有标签数据集 A 重复取样 3 次，得到 3 个有标签数据子集，记为 A_1 、 A_2 、 A_3 ，用它们分别训练得到 3 个不同的 LASSO-BP 网络学习器，记为 M_1 、 M_2 、 M_3 。初始化迭代次数 $\tau=1$ 。

3) 处理无标签在线状态估计数据集 B ：分别使用无标签数据对学习器 M_1 、 M_2 、 M_3 进行重新训练。这里以学习器 M_3 的重新训练为例，介绍学习器的重新训练过程：

使用学习器 M_1 、 M_2 对数据集 B 的无标签数据进行预测，预测结果置信度判断标准为

$$|M_1(\mathbf{X}'_i) - M_2(\mathbf{X}'_i)| < \varepsilon \quad (8)$$

式中 $\mathbf{X}'_i \in B$ ， ε 为常数，可以根据实际情况进行调整。

如果式(8)成立, 则将 $(X'_i, \hat{P}_{\max,i})$ 作为伪标签数据组合加入伪标签数据集 π_3 。 $\hat{P}_{\max,i}$ 为输出响应变量的预测值, 其计算方法为

$$\hat{P}_{\max,i} = \alpha_M M_1(X'_i) + \beta_M M_2(X'_i) \quad (9)$$

式中: $X'_i \in B$; $\alpha_M + \beta_M = 1$ 。

如果式(8)不成立, 则不进行任何操作。

4) 将伪标签数据集 $\pi_3 = \{(X'_i, \hat{P}_{\max,i})\}, X'_i \in B$ 与学习器 M_3 的训练数据集 A_3 合并, 得到新的训练数据集 A'_3 :

$$A'_3 = A_3 \cup \pi_3 \quad (10)$$

用 A'_3 替换掉 A_3 , 使用 A_3 对学习器 M_3 重新训练, 此时, 学习器 M_3 的重新训练完成。

5) 对学习器 M_1 、 M_2 分别重复步骤3)、4) 进行训练, 对3个学习器全部进行了步骤3)、4) 后, 称为一次 Tri-Training 过程。重复运行 Tri-Training 过程, 直到达到最大重复次数 τ_{\max} 后进入步骤6), 其中 τ_{\max} 可以根据实际情况进行调整。

6) 使用经过参数调整的3个学习器 M_1 、 M_2 、 M_3 对测试数据集 C 进行预测, 系统静态电压稳定极限点的负荷预测值 $\hat{P}_{\max,i}$ 为

$$\hat{P}_{\max,i} = \alpha_M M_1(X'_i) + \beta_M M_2(X'_i) + \gamma_M M_3(X'_i) \quad (11)$$

式中: $X'_i \in C$; $\alpha_M + \beta_M + \gamma_M = 1$ 。

具体流程如图3所示, 随着算法的运行, 无标

签数据集 B 中的数据减少, 数据逐步被打上伪标签。三体训练法在有标签数据较少, 训练样本不足的情况下, 能够按照式(8)~(10)的规则给无标签数据打上标签, 充分利用无标签数据的分布特点, 相对来说增大了训练样本, 式(11)吸收了集成学习提高预测精度的优点。

2.4 算法性能的评价指标

为了排除结果数量级对于均方误差评估指标的影响, 衡量网络的稳定性和鲁棒性, 监测偶尔发生的严重错误, 定义平均相对误差 e_{mean} 和最大相对误差 e_{max} 评估性能:

$$e_{\text{mean}} = \frac{1}{k_C} \sum_{i=1}^{k_C} \left| \frac{P_{\max,i} - \hat{P}_{\max,i}}{P_{\max,i}} \right| \quad (12)$$

$$e_{\text{max}} = \max \left(\left| \frac{P_{\max,i} - \hat{P}_{\max,i}}{P_{\max,i}} \right| \right), i = 1, 2, \dots, k_C \quad (13)$$

假设检验^[36]是统计学方法, 可以判断样本与样本、样本与总体之间的差异的显著性, 基本思想是小概率反证法, 认为小概率事件在一次试验中基本不会发生。因此先提出“样本与总体或样本与样本间的差异是由抽样误差引起的, 不存在显著差异”的原假设 H_0 , 再根据样本类型和特点用适当的统计方法计算假设 H_0 成立的可能性 p , 最后根据显著性水平 α_p 对统计结果进行判断: 若 $p > \alpha_p$, 表明很可能是抽样误差造成了差异, 在 α_p 的显著性水平下无法拒绝原假设 H_0 ; 如果 $p \leq \alpha_p$, 表明差异很可能是实验因素不同造成的, 具有统计上的显著性。显著性水平 α_p 可以根据需要选取, 在不同的显著性水平下, 统计学差异与计算得到的 p 值的关系如表1所示。

表1 统计学差异与 p 值的关系^[37]

Tab. 1 Relationship between statistical difference and p value

p 值范围	统计学差异的显著度
>0.05	无显著统计学差异
<0.05	一般统计学差异(*)
<0.01	显著统计学差异(**)
<0.001	极其显著统计学差异(***)

本文的算法性能问题对应的是独立样本, 样本之间没有成对关系或相关关系, 因此适合采用非参数检验中的 Mann-Whitney U 检验^[38-39]。

文献[40]表明, 实施 Mann-Whitney U 检验的每一个集合样本数目不小于10, 就能在一般公认的显著性水平 ($\alpha_p=0.05$ 或 $\alpha_p=0.01$) 下得出是否拒绝原假设 H_0 的结论。如果 Mann-Whitney U 检验认为某一

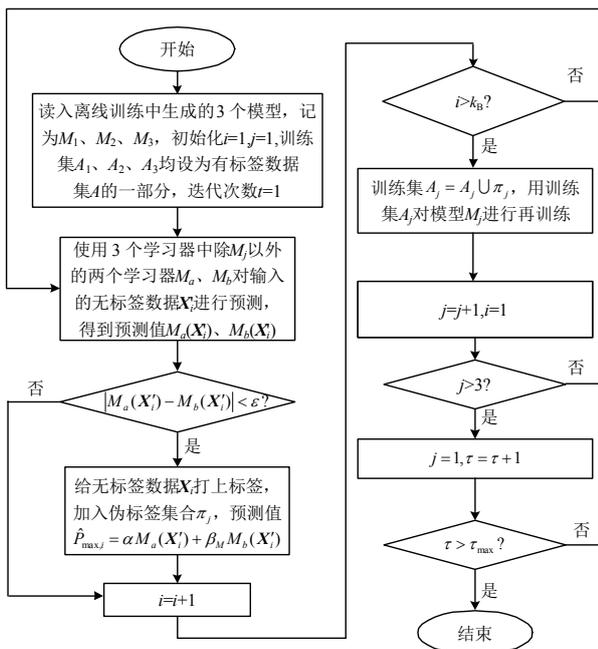


图3 适用于回归问题的改进三体训练法流程图

Fig. 3 Flow chart of improved Tri-Training method for regression problems

算法的评价指标相对于另一种算法有统计学上的显著差异, 如表 1 中 $p < 0.05$ 的情况, 且这种算法相对误差的平均值、标准差比另一种算法小, 或运行时间比另一种算法少, 则可以认为这种算法相对于另一种算法具有显著的优越性。

3 算例分析

以 IEEE 39 节点算例^[23, 41]和 IEEE 300 节点算例^[42]为例进行测试, 系统基准有功功率为 100MW, 基准无功功率为 100Mvar, IEEE 39 节点算例的网架结构见附录 A。某省的电网样本中, 110kV 及以上的节点数目为 435 个, 因此以 IEEE 300 节点算例为例, 对本文方法在省级规模电网上的运行速度和性能进行测试。每个算例中, 使用 MATPOWER 连续潮流计算程序产生 3000 组潮流断面样本, 作为本文测试的数据集 S 。生成潮流断面样本的具体方法^[43]是: 在基准运行状态下, 随机初始化系统的运行状态, 使系统中每个负荷节点的功率因数保持恒定, 再按照表 2 方式随机设置各节点参数, 在新的这种运行状态下, 用连续潮流法求取系统的负荷极限, 算法迭代步长为 0.1。采用的计算机 CPU 型号为 Intel Core i7-8700, 主频 3.20GHz, 可用内存为 15.8G, Matlab 为 R2018b 版本。

表 2 各节点参数的变化范围

Tab. 2 Range of parameter of each node

数据类型	随机变化范围
每个负荷节点的有功功率	基准值 $\times(0.7\sim 1.3)$
每个发电机节点的有功出力	基准值 $\times(0.7\sim 1.3)$
每个发电机节点的机端电压	基准值 $\times(0.97\sim 1.03)$

IEEE 39 节点算例中输入变量维数为 $m=4n=156$, 其中 $n=39$, 输出变量维数为 1。IEEE 300 节点算例中输入变量维数为 $m=4n=1200$, 其中 $n=300$, 输出变量维数为 1。

对于运行算法得到的平均相对误差、最大相对误差和算法运行时间, 使用 Mann-Whitney U 检验方法进行评估, 同时计算这些指标的平均值和标准差作为补充评估指标。

3.1 LASSO 降维方法对预测精度的影响

为了验证 LASSO 降维方法对于预测精度影响不大, 在正式测试开始前以 IEEE 39 节点算例为例对 LASSO 降维方法的影响进行测试。原始数据集产生过程中, 系统中所有负荷按恒功率因数同步增长, 系统中增长的负荷功率由所有发电机按初始出力比例共同承担, 增长系数为 2.5, 不考虑发电机

的无功限制。LASSO 方法的终止判据为迭代次数达到 10000 次或收敛判据小于 1×10^{-7} 。综合考虑保留样本中输入变量的维数和模型误差, 取 $t=30$, 此时 β 中非零元素个数为 78, 其对应的 78 个状态量将在样本中保留。将 3000 个样本的原始数据集按照 0.85:0.15 的比例随机拆分为训练集和测试集, 即训练集样本数为 2550, 测试集样本数为 450。使用单隐含层的 BP 神经网络, 隐含层中有 10 个神经元, 活化函数采用 tan-sigmoid 函数, 输入层和输出层均采用 purelin 函数, 使用 Levenberg-Marquardt 算法进行训练, 初始学习率为 1, 学习率增大系数为 10, 学习率减小系数为 0.1, 终止条件是训练周期达到 200 次或性能指标小于 1×10^{-5} 。采用 10 折交叉验证进行精度评估。实验结果如表 3 所示。

表 3 LASSO-BP 网络和单一 BP 网络的性能对比

Tab. 3 Performance comparison between LASSO-BP network and single BP network

评价指标	BP 神经网络平均值	LASSO-BP 神经网络 ^[10] 平均值
$e_{\text{mean}}/\%$	0.2701	0.2753
$e_{\text{max}}/\%$	3.3088	3.4482
时间/s	37.514	8.169

使用 Mann-Whitney U 检验评估两种方法的性能, 对于两种方法的平均相对误差 $p=0.8798 > 0.05$, 最大相对误差 $p=0.6501 > 0.05$, 无法拒绝原假设, 不存在显著差异。评估两种方法消耗的时间, $p=0.0002 < 0.001$, 拒绝原假设, 存在显著差异。这说明使用 LASSO 降维后, BP 神经网络的离线训练时间大大缩短, LASSO 降维方法能够提升网络训练的速度, 减少计算机资源消耗。同时在保证较高训练速度的前提下, 对 BP 神经网络的预测精度影响不大。

3.2 Tri-Training-LASSO-BP 网络性能测试

原始数据集产生过程中, 系统中所有负荷按恒功率因数同步增长, 系统中增长的负荷功率由所有发电机按初始出力比例共同承担, 增长系数为 2.5, 考虑发电机的无功限制。

将 3000 个样本的原始数据集按照 0.40:0.45:0.15 的比例分成有标签数据集 A 、无标签数据集 B 和测试数据集 C , 离线 LASSO-BP 网络只使用 A 进行训练, C 进行测试; 本文提出的 Tri-Training-LASSO-BP 网络使用 A 、 B 进行训练, C 进行测试。LASSO 方法的终止判据为迭代次数达到 10000 次或收敛判据小于 1×10^{-7} 。生成的 3 个学习器的参数如表 4 所示, 区别主要在于对有标签训练集进行重

表4 3个BP神经网络学习器的参数

Tab. 4 Parameters of three BP neural network learners

参数名	1号学习器	2号学习器	3号学习器
隐含层数		1	
活化函数		tan-sigmoid	
输入层、输出层函数		purelin	
训练算法		Levenberg-Marquardt	
初始学习率		1	
学习率增大系数		10	
学习率减小系数		0.1	
训练集中作为验证集的比例		5%	
训练目标(MSE)		1×10^{-5}	
隐含层神经元数目	10	5	7
随机重复抽样比例	80%	80%	80%
训练终止条件	训练周期达到到200次	训练周期达到1000次	训练周期达到600次

采样的过程和隐含层中神经元数目的不同, 在线训练过程中使用占原始有标签数据 80%的部分数据参与训练。

综合考虑保留样本中输入变量的维数和模型误差, 对于 IEEE 39 节点系统, 取置信误差限 $\epsilon=1$, LASSO 方法取 β 中非零元素个数为 78; 对于 IEEE 300 节点系统, 取置信误差限 $\epsilon=1.35$, LASSO 方法取 β 中非零元素个数为 600。

实验中 1 轮的定义为: 运行 10 次目标算法, 结果取 10 次的平均值。对离线 LASSO-BP 网络和提出的 Tri-Training-LASSO-BP 网络各测试 10 轮, 得到性能测试结果如表 5 所示, 各轮次的平均相对误差和最大相对误差分布如图 4、5 所示。

算例表明, 在离线有标签样本有限时, 本文提出的 Tri-Training-LASSO-BP 网络能够利用在线无标签样本进行参数优化, 其最大、平均相对误差的平均值和标准差均小于离线 LASSO-BP 网络的最大相对误差和平均相对误差。使用 Mann-Whitney U 检验评估两种网络的性能, 平均相对误差 $p=0.0002$ ($z=3.780$), 最大相对误差 $p=0.0015$ ($z=3.175$), 说明两种算法的结果存在极其显著的统计学差异。因

表5 离线 LASSO-BP 网络和 Tri-Training-LASSO-BP 网络的性能对比

Tab. 5 Performance comparison between offline LASSO-BP network and Tri-Training-LASSO-BP network

测试系统	离线 LASSO-BP 网络 ^[10]		Tri-Training-LASSO-BP 网络	
	$e_{\text{mean}}/\%$	$e_{\text{max}}/\%$	$e_{\text{mean}}/\%$	$e_{\text{max}}/\%$
IEEE 39 节点	1.79306	28.4496	1.32853	19.8986
IEEE 300 节点	3.01852	21.6218	2.16967	18.1581

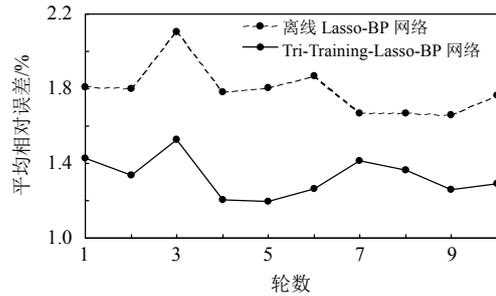


图4 离线 LASSO-BP 网络和 Tri-Training-LASSO-BP 网络在 IEEE 39 节点测试系统上的平均相对误差

Fig. 4 Average relative error of offline LASSO-BP network and Tri-Training-LASSO-BP network on IEEE 39 nodes test case

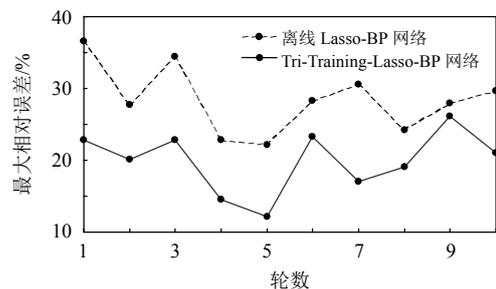


图5 离线 LASSO-BP 网络和 Tri-Training-LASSO-BP 网络在 IEEE 39 节点测试系统上的最大相对误差

Fig. 5 Maximum relative error of offline LASSO-BP network and Tri-Training-LASSO-BP network on IEEE 39 nodes test case

此, 可以认为 Tri-Training-LASSO-BP 网络相对于传统离线 LASSO-BP 网络性能更好。根据 DL/T 5429-2009 电力系统设计技术规程^[44]的规定, 电力系统的总备用容量不低于最大发电负荷功率的 20%, 在本文提出的 Tri-Training-LASSO-BP 网络下, 系统静态电压稳定极限负荷预测值最大误差降至 20%以下, 能够在规定标准下实现系统安全运行。

对算法的速度进行评估, 保持其他测试条件相同, 记录下每次训练所需的时间如表 6 所示。

目前电网中采用的量测装置主要有 PMU、RTU 和 AMI: PMU 的实时数据的输出时延不大于 30ms, 为毫秒级采样, 记其采样周期为 T_{PMU} ; RTU 一般为秒级采样, 记其采样周期为 T_{RTU} ; AMI 采样周期较长, 一般为 15min, 记其采样周期为 T_{AMI} ^[45-46]。算例表明, 本文提出的 Tri-Training-LASSO-BP 网

表6 Tri-Training-LASSO-BP 网络的速度测试结果

Tab. 6 Speed test results for the Tri-Training-LASSO-BP network

测试系统	降维处理时间/s	参数更新时间/s
IEEE 39 节点	0.156	28.162
IEEE 300 节点	12.398	65.446

络训练速度较快，对于 IEEE 39 节点系统和 IEEE 300 节点系统，分别能够在 30s 内、90s 内完成网络参数的更新。考虑到目前状态估计计算周期一般为 min 级，本文方法可以满足在线应用的要求。

3.3 有、无标签样本数目对训练结果的影响

本文还对有标签、无标签样本占比不同时的网络性能进行实验评估，在 IEEE 39 节点算例中改变有标签、无标签样本的比重得到的结果如表 7 所示。随着加入的无标签样本比例增多，平均相对误差总体上呈先减小后增大的趋势，由于每次训练神经网络各层参数的差异，会出现平均相对误差上下波动的情况。当有标签样本比例减小至 0.05 时，平均相对误差达到 2.84%，相对于基准组显著增大，已经无法满足精确预测的要求。相对来说，有标签样本比例在 0.15~0.40 之间取值，得到的模型效果较好。

本文还以 IEEE 300 节点为例，对采用不同数量的无标签样本进行参数更新得到的网络性能进行了评估。调整置信误差限 ε 以控制参与训练的无标签样本数，实验结果如表 8 所示。实验表明，控

表 7 有标签、无标签样本比例对网络性能的影响

Tab. 7 Impact of labeled, unlabeled sample ratio on network performance

有标签样本比例	无标签样本比例	$e_{\text{mean}}/\%$
0.40	0.45	1.3012
0.35	0.50	1.4688
0.30	0.55	1.4812
0.25	0.60	1.3529
0.20	0.65	1.3810
0.15	0.70	1.2946
0.10	0.75	1.4333
0.05	0.80	2.8482

表 8 参与训练的无标签样本数对网络性能的影响

Tab. 8 Impact of the number of unlabeled samples participating in training on network performance

ε	参与训练的平均无标签样本数	$e_{\text{mean}}/\%$
0	0	2.4162
0.005	3.8	2.2984
0.01	6.3	2.2967
0.02	13.8	2.2621
0.05	33.6	2.2547
0.30	164.2	2.2369
0.55	324.4	2.2057
0.80	490.8	2.2159
1.05	521.8	2.1990
1.55	762.0	2.1816
1.80	874.6	2.1744

制有标签样本数不变的情况下，随着参与参数更新的无标签样本数增加，模型的平均相对误差减小，且一开始加入无标签样本时，模型性能的提升更加明显。

根据上述算例分析结果，在实际应用中，可以根据工程需要、有标签样本获取的难易程度、需要的模型预测精度等确定用于离线训练的有标签样本数 \tilde{k}_A 和有标签样本比例 r_A ，令 r_A 在 0.15~0.40 取值，此时无标签样本数为

$$\tilde{k}_B = \frac{\tilde{k}_A}{r_A}(1 - 0.15 - r_A) \quad (14)$$

程序上线后，每隔时间 T 检查一次搜集的无标签样本数量是否达到 \tilde{k}_B ，其中 $T = k \cdot \text{lcm}(T_{\text{PMU}}, T_{\text{RTU}}, T_{\text{AMI}})$ ， lcm 为离散数学中求最小公倍数的符号； k 为正整数，可以根据工程实际设置。在一次检查中，若发现搜集的无标签样本数达到 \tilde{k}_B 个，则进行一次模型参数更新训练。

4 结论

本文在静态电压稳定裕度预测领域引入了无标签样本概念，提出了一种针对智能电网量测体系中海量的状态估计无标签数据的利用思路。工程实际中，无标签样本能够被大量获取。在有标签样本难以通过连续潮流计算，在线、实时获得的情况下，引入的无标签样本能够在线对预测模型进行参数优化，提高模型的预测精度。

将以往在计算机领域中应用的三体训练法引入电力系统静态电压稳定预测领域，基于 Tri-Training-LASSO-BP 网络的静态电压稳定裕度在线预测方法能够充分利用无标签样本中隐含的数据特征进行模型参数更新，在有标签样本数受限时，提升只使用有标签样本进行训练的传统方法的预测精度。

此外，三体训练法还能够充分发挥各个结构不同的学习器的优点。3 个学习器之间相互配合，通过投票方式给无标签数据打上标签，使它们成为伪标签数据参与模型参数更新。

本文在算法性能评估层面引入了统计学中针对独立样本的 Mann-Whitney U 非参数检验，采用定量方法评估算法的性能，使结果更具有可信性和说服力。

在后续工程实际应用时，需要考虑如何对系统的海量运行数据进行特征、样本筛选，选取有代表

性的特征维度和样本数据参与网络参数的在线更新。

参考文献

- [1] 甘德强, 胡江溢, 韩桢祥. 2003 年国际若干停电事故思考[J]. 电力系统自动化, 2004, 28(3): 1-4.
Gan Deqiang, Hu Jiangyi, Han Zhenxiang. Thoughts on several international blackouts in 2003[J]. Automation of Electric Power Systems, 2004, 28(3): 1-4(in Chinese).
- [2] US-Canada Power System Outage Task Force. Final report on the August 14, 2003 blackout in the United States and Canada: causes and recommendations[EB/OL]. [2019-06-01]. <https://reports.energy.gov>.
- [3] 李春艳, 孙元章, 陈向宜, 等. 西欧“11·4”大停电事故的初步分析及防止我国大面积停电事故的措施[J]. 电网技术, 2006, 30(24): 16-21.
Li Chunyan, Sun Yuanzhang, Chen Xiangyi, et al. Preliminary analysis of large scale blackout in western Europe power grid on November 4 and measures to prevent large scale blackout in China[J]. Power System Technology, 2006, 30(24): 16-21(in Chinese).
- [4] 陈亦平, 洪军. 巴西“11·10”大停电原因分析及对我国南方电网的启示[J]. 电网技术, 2010, 34(5): 77-82.
Chen Yiping, Hong Jun. Analysis on causes of blackout occurred in Brazilian power grid on Nov. 11, 2009 and lessons drawn from it to China southern power grid[J]. Power System Technology, 2010, 34(5): 77-82(in Chinese).
- [5] 汤涌, 卜广全, 易俊. 印度“7·30”、“7·31”大停电事故分析及启示[J]. 中国电机工程学报, 2012, 32(24): 167-174.
Tang Yong, Bu Guangquan, Yi Jun. Analysis and lessons of the black out in Indian power grid on July 30 and 31, 2012[J]. Proceedings of the CSEE, 2012, 32(24): 167-174(in Chinese).
- [6] 颜廷鑫. 基于神经网络的电压稳定裕度快速计算方法[D]. 长沙: 湖南大学, 2017.
Yan Tingxin. Fast calculation method for voltage stability modulus based on neural network[D]. Changsha: Hunan University, 2017(in Chinese).
- [7] 韩桢祥, 曹一家. 电力系统的安全性及防治措施[J]. 电网技术, 2004, 28(9): 1-6.
Han Zhenxiang, Cao Yijia. Power system security and its prevention[J]. Power System Technology, 2004, 28(9): 1-6(in Chinese).
- [8] 彭志炜, 胡国根, 韩桢祥. 电力系统电压稳定与同步稳定分析[J]. 电力系统及其自动化学报, 2000, 12(1): 1-4.
Peng Zhiwei, Hu Guogen, Han Zhenxiang. The analysis of voltage stability and synchronism stability in power systems[J]. Proceedings of the EPSA, 2000, 12(1): 1-4(in Chinese).
- [9] 陈爱军, 刘爱国. 基于神经网络模型的在线电压稳定裕度评估[J]. 电力科学与工程, 2010, 26(8), 19-23.
Chen Aijun, Liu Aiguo. On-line voltage stability evaluation based on neural networks model[J]. Electric Power Science and Engineering, 2010, 26(8), 19-23(in Chinese).
- [10] 刘昇, 徐政, 华文, 等. 用于在线预测静态电压稳定性的 SIPSS-Lasso-BP 网络[J]. 中国电机工程学报, 2014, 34(34): 6032-6041.
Liu Sheng, Xu Zheng, Hua Wen, et al. A SIPSS-Lasso-BP network for online forecasting static voltage stability[J]. Proceedings of the CSEE, 2014, 34(34): 6032-6041(in Chinese).
- [11] Suganyadevi M V, Babulal C K, Kalyani S. Assessment of voltage stability margin by comparing various support vector regression models[J]. Soft Computing, 2014, 20(2): 1-12.
- [12] Wan H B, Ekwue A O. Artificial neural network based contingency ranking method for voltage collapse[J]. International Journal of Electrical Power & Energy Systems, 2000, 22(5): 349-354.
- [13] Pandit M, Srivastava L, Sharma J. Contingency ranking for voltage collapse using parallel self-organizing hierarchical neural network[J]. International journal of electrical power & energy systems, 2001, 23(5): 369-379.
- [14] 吴杰康, 邓松, 梁志武, 等. 基于模糊神经网络决策树的电压稳定性评估[J]. 电网技术, 2008, 32(14): 25-30.
Wu Jiekang, Deng Song, Liang Zhiwu, et al. Evaluation of power system voltage stability based on fuzzy neural network decision tree[J]. Power System Technology, 2008, 32(14): 25-30(in Chinese).
- [15] Srivastava L, Singh S N, Sharma J. Parallel selforganising hierarchical neural network based estimation of degree of voltage insecurity[J]. Computers & Electrical Engineering, 2003, 29(5): 589-602.
- [16] Pandit M, Srivastava L, Sharma J. Fast voltage contingency selection using fuzzy parallel self-organizing hierarchical neural network[J]. IEEE Transactions on Power Systems, 2003, 18(2): 657-664.
- [17] Jain T, Srivastava L, Singh SN. Fast voltage contingency screening using radial basis function neural network[J]. IEEE Transactions on Power systems, 2003, 18(4): 1359-1366.
- [18] Sajjan K S, Kumar V, Tyagi B. Genetic algorithm based support vector machine for on-line voltage stability monitoring[J]. International Journal of Electrical Power & Energy Systems, 2015(73): 200-208.

- [19] Rahi O P, Yadav A K, Malik H, et al. Power system voltage stability assessment through artificial neural network[J]. *Procedia Engineering*, 2012(30): 53-60.
- [20] Sharma A K, Saxena A, Soni B P, et al. Voltage stability assessment using artificial neural network[C]//2018 IEEMA Engineer Infinite Conference (eTechNxT), New Delhi, India: IEEE, 2018.
- [21] Su H Y, Liu T Y. Enhanced-online-random-forest model for static voltage stability assessment using wide area measurements[J]. *IEEE Transactions on Power Systems*, 2018, 33(6): 6696-6704.
- [22] Li S, Ajarapu V, Djukanovic M. Adaptive online monitoring of voltage stability margin via local regression[J]. *IEEE Transactions on Power Systems*, 2017, 33(1): 701-713.
- [23] 周双喜, 朱凌志, 郭锡玖, 等. 电力系统电压稳定性及其控制[M]. 北京: 中国电力出版社, 2004: 152-294. Zhou Shuangxi, Zhu Lingzhi, Guo Xijiu, et al. Power system voltage stability and its control[M]. Beijing: China Electric Power Press, 2004: 152-294(in Chinese).
- [24] Kundur Prabha. Power system stability and control[M]. New York: McGraw-Hill Inc, 1994: 601-756.
- [25] Iba K, Suzuki H, Egawa M, et al. Calculation of critical loading condition with nose curve using homotopy continuation method[J]. *IEEE Transactions on Power Systems*, 1991, 6(2): 584-593.
- [26] 王维超, 张明, 胡堃. 电力系统运行方式[M]. 北京: 中国电力出版社, 2009: 3-10. Wang Weichao, Zhang Ming, Hu Kun. Operation mode of power system[M]. Beijing: China Electric Power Press, 2009: 3-10(in Chinese).
- [27] Tibshirani R. Regression shrinkage and selection via the LASSO[J]. *Journal of the Royal Statistical Society, Series B (Methodological)*, 1996, 58(1): 267-288.
- [28] 施万锋, 胡学钢, 俞奎. 一种面向高维数据的均分式 LASSO 特征选择方法[J]. *计算机工程与应用*, 2012, 48(1): 157-161. Shi Wanfeng, Hu Xuegang, Yu Kui. K-part LASSO based on feature selection algorithm for high-dimensional data[J]. *Computer Engineering and Applications*, 2012, 48(1): 157-161(in Chinese).
- [29] Rumelhart D E, McClelland J L, the PDP Research Group. *Parallel Distributed Processing: Explorations in the Microstructures of Cognition. Volume 1: Foundation*[M]. Cambridge, MA: The MIT Press, 1986: 282-317.
- [30] 周开利, 康耀红. 神经网络模型及其 MATLAB 仿真程序设计[M]. 北京: 清华大学出版社, 2005: 90. Zhou Kaili, Kang Yaohong. *Neural Network Model and MATLAB Simulation Programming*[M]. Beijing: Tsinghua University Press, 2005: 90(in Chinese).
- [31] 吴明胜, 邓晓刚. 基于 Tri-DE-ELM 的半监督模式分类方法研究[J]. *计算机工程与应用*, 2018, 54(3): 109-114. Wu Mingsheng, Deng Xiaogang. Semi supervised pattern classification method based on Tri-DE-ELM[J]. *Computer Engineering and Applications*, 2018, 54(3): 109-114(in Chinese).
- [32] Miller D J, Uyar H S. A mixture of experts classifier with learning based on both labelled and unlabelled data[C]//9th International Conference on Neural Information Processing Systems. Denver, Colorado, USA: NIPS, 1997: 571-577.
- [33] Zhou Z H, Li M. Tri-training: Exploiting unlabeled data using three classifiers[J]. *IEEE Transactions on Knowledge & Data Engineering*, 2005(11): 1529-1541.
- [34] 杨剑, 王珏, 钟宁. 流形上的 Laplacian 半监督回归[J]. *计算机研究与发展*, 2007, 44(7): 1121-1127. Yang Jian, Wang Yu, Zhong Ning. Laplacian semi-supervised regression on a manifold[J]. *Journal of Computer Research and Development*, 2007, 44(7): 1121-1127(in Chinese).
- [35] Zhou Z H, Li M. Semi-supervised regression with co-training[C]//19th international joint conference on Artificial intelligence. Edinburgh, Scotland: IJCAI, 2005: 908-913.
- [36] Lehmann E L, Romano J P. *Testing statistical hypotheses*[M]. New York: Springer Science & Business Media, 2006: 56-59.
- [37] 邓奋发. MATLAB R2015b 概率与数理统计[M]. 北京: 清华大学出版社, 2017: 138-143. Deng Fenfa. *MATLAB R2015b probability and mathematical statistics*[M]. Beijing: Tsinghua University Press, 2017: 138-143(in Chinese).
- [38] Mann H B, Whitney D R. On a test of whether one of two random variables is stochastically larger than the other[J]. *The Annals of Mathematical Statistics*, 1947: 50-60.
- [39] MacFarland T W, Yates J M. *Introduction to nonparametric statistics for the biological sciences using R*[M]. Switzerland: Springer, Cham, 2016: 103-132.
- [40] Luis Ospina Forero. Wilcoxon-Mann-Whitney test and a small sample size[EB/OL]. [2019-06-10]. <https://www.blogpig.com/blog/2013/10/wilcoxon-mann-whitney-test-and-a-small-sample-size>.
- [41] Pai M A. *Energy function analysis for power system stability*[M]. USA: Springer Science & Business Media, 2012: 223-228.
- [42] Illinois Center for a Smarter Electric Grid. IEEE 300-Bus System[EB/OL]. [2019-06-13]. <https://icseg.iti.illinois.edu/ieee-300-bus-system/>.
- [43] 马睿博. 基于深度学习的电力系统静态稳定性预测[D]. 北京: 北京邮电大学, 2018.

Ma Ruibo. Static stability prediction of power system based on deep learning[D]. Beijing: Beijing University of Posts and Telecommunications, 2018(in Chinese).

- [44] 电力行业电力规划设计标准化技术委员会. DL/T 5429-2009 电力系统设计技术规程[S]. 北京: 中国电力出版社, 2009.

Power planning and design standardization technical committee of power industry. DL/T 5429-2009 Technical code of design for the electric power system[S]. Beijing: China Electric Power Press, 2009(in Chinese).

- [45] 盛万兴, 方恒福, 沈玉兰, 等. 考虑量测时延时基于三种数据融合的配网状态估计[J/OL]. 电力系统及其自动化学报: 1-7[2019-09-09]. <https://doi.org/10.19635/j.cnki.csu-epsa.000204>.

Sheng Wanxing, Fang Hengfu, Shen Yulan, et al. State estimation of distribution network based on fusion of three data sources considering time-delay[J/OL]. Proceedings of the CSU-EPSA: 1-7[2019-09-09]. <https://doi.org/10.19635/j.cnki.csu-epsa.000204>(in Chinese).

- [47] 王少芳, 刘广一, 黄仁乐, 等. 多采样周期混合量测环境下的主动配电网状态估计方法[J]. 电力系统自动化, 2016, 40(19): 30-36.

Wang Shaofang, Liu Guangyi, Huang Renle, et al. State estimation method for active distribution networks under environment of hybrid measurements with multiple sampling periods[J]. Automation of Electric Power Systems, 2016, 40(19): 30-36(in Chinese).

附录 A

IEEE 39 节点系统如图 A1 所示。

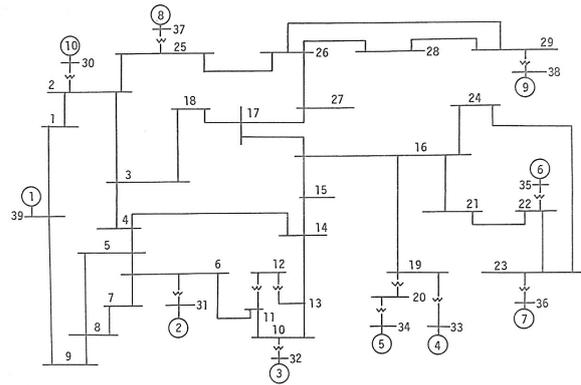


图 A1 IEEE 39 节点测试系统

Fig. A1 IEEE 39 nodes test case



唐滢淇

在线出版日期: 2020-02-26。

收稿日期: 2019-07-09。

作者简介:

唐滢淇(1997), 男, 硕士, 主要研究方向为智能电网与人工智能, tangyq@zju.edu.cn;

*通信作者: 董树锋(1982), 男, 博士, 副教授, 主要研究方向为智能电网优化与控制技术, dongshufeng@zju.edu.cn;

朱承治(1977), 男, 博士, 高级工程师, 主要研究方向为电力系统及其自动化, chengzhi_zhu@163.com。

(责任编辑 乔宝榆)