

doi: 10.7690/bgzd.2026.03.012

基于自组织映射的配电终端自动化联调数据校验方法

黄磊, 刘颖, 梅嘉馨, 吴鹏, 王鑫鑫

(贵州电网有限责任公司铜仁供电局电力调度控制中心, 贵州 铜仁 554300)

摘要: 针对当前配电终端联调数据来源较多, 导致数据难以清洗与校验的问题, 提出基于自组织映射的配电终端自动化联调数据校验方法。采集配电终端遥信、遥测、保护遥信、保护遥测等数据; 构建由输入层与竞争层共同组成自组织映射神经网络模型, 将所采集的联调数据作为模型输入, 对不同类别联调数据的特征向量实施自动聚类, 通过判断联调数据间的相关性确定配电终端自动化联调数据是否产生异常, 实现配电终端自动化联调数据校验目的。同时, 利用自适应优化模型竞争机制, 缓解学习过度的优势, 并通过灰关系分析动态优化模型权重, 抑制邻域神经元内杂质的消极影响, 优化自组织映射神经网络模型对联调数据的校验性能。实验结果表明: 该方法具有较好的聚类性能, 能够有效实现联调数据的校验目的, 提升终端设备联调效果。

关键词: 自组织映射; 配电终端; 自动化联调; 数据校验; 特征聚类; 竞争机制

中图分类号: TP392 **文献标志码:** A

Verification Method of Distribution Terminal Automation Joint Debugging Data Based on Self-organizing Map

Huang Lei, Liu Ying, Mei Jiaxin, Wu Peng, Wang Xinxin

(Power Dispatch Control Center, Tongren Power Supply Bureau of Guizhou Power Grid Co. Ltd., Tongren 554300, China)

Abstract: Aiming at the problem that it is difficult to clean and verify the data of distribution terminal automation joint debugging due to the large number of data sources, a method of data verification for distribution terminal automation joint debugging based on self-organizing map is proposed. Collect such data as remote signaling, remote metering, protection remote signaling and protection remote metering of power distribution terminal; A self-organizing map neural network model consisting of an input layer and a competition layer is constructed, that collected joint debug data is used as model input, the feature vectors of different types of joint debugging data are subjected to automatic clustering, whether the joint debugging data of the power distribution terminal automation are abnormal or not is determined by judging the correlation among the joint debugging data, and the aim of checking the joint debugging data of the power distribution terminal automation is fulfilled. At the same time, the competition mechanism of the adaptive optimization model is used to alleviate the advantage of over-learning, and the weights of the model are dynamically optimized through the analysis of grey relations to suppress the negative impact of impurities in the neighborhood neurons and optimize the calibration performance of the self-organizing map neural network model on the joint debugging data. The experimental results show that the method has good clustering performance, can effectively achieve the purpose of checking the joint debugging data, and improve the effect of joint debugging of terminal equipment.

Keywords: self-organizing map; distribution terminal; automatic joint debugging; data verification; feature clustering; competitive mechanism

0 引言

配电终端自动化联调过程中, 不能直接确定传输至主站系统内的数据是否准确^[1], 需要主站与终端同时进行逐一校验。此过程中包含较大工作量, 同时会产生大量联调数据^[2]。这些数据中存在一定偏差, 对配电终端联调效果产生不利影响^[3]; 因此, 需研究一种联调数据校验方法, 保障联调数据准确性。

杨玉莲等^[4]在研究数据校验过程中, 构建生成

对抗网络, 结合语义感知模型对数据进行校验。该方法校验过程中存在显著的学习过度问题。耿俊成等^[5]在研究数据校验方法过程中, 通过支持向量构建数据判断模型, 由此判断数据是否产生异常。该方法应用时, 未考虑数据的异常具有线性不可分特征, 导致判断结果产生偏差。李国栋等^[6]在研究数据校验问题中, 利用关联分析算法挖掘数据间的相关性, 根据数据相关性实现数据校验目的。该方法实际应用过程中过度依赖数据, 导致校验结果受初

收稿日期: 2024-11-15; 修回日期: 2024-12-25

第一作者: 黄磊(1987—), 男, 贵州人。

始数据影响显著。针对上述问题，提出基于自组织映射的配电终端自动化联调数据校验方法，降低联调数据中的数据异常概率，提升配电终端联调效果。

1 配电终端自动化联调数据校验方法

1.1 配电终端自动化联调数据获取

配电终端自动化联调的核心为判断配电终端联调双方的点表能否一一匹配，能否准确传输模拟量与状态量。配电终端现场联调过程中需依照相应的标准设定数据传输顺序、终端检测数据的详细数值以及遥信的状态波动^[7-8]。将配电终端联调数据划分为4个类别如表1所示。

表1 配电终端联调数据类别划分

编号	联调数据类别	具体描述
1	遥信数据	生成遥信数据类别列表内的点号与名称，不同的设备能够生成对应的记录，并实时采集状态与时间信息，依照联调规则传输开关信号
2	遥测数据	该类型数据包括配电终端设备的有功功率与电流、电压等全部量测信号，生成遥测数据类别列表内的点号与遥测名称，不同遥测模型均可生成对应的记录，并实时采集遥测值与时间信息
3	保护遥信	生成该联调数据类别列表内的点号与保护遥测名称，不同保护模型均可生成对应的记录，并实时采集状态与时间信息
4	保护遥测	为保障电流加量过程中需将其提升至设定阈值，依照各保护电流值，配网终端传输差异化的保护告警信息

针对表1所示的4类配电终端联调数据，基于调试规则，传输信号，确定配电终端设备调试结果。通过上述联调过程获取配电终端自动化联调数据，以此为基础，采用自组织映射技术对所获取的配电终端自动化联调数据实施校验。

1.2 基于自组织映射的联调数据校验

自组织映射神经网络具有自组织、自学习等特性^[9]，其结构中只包含输入层与竞争层，不具备隐含层。基于自组织映射的配电终端自动化联调数据校验过程中，将所获取的配电终端自动化联调数据作为输入层的输入信息，通过网络自身训练，对配电终端自动化联调数据实施分类检验。

基于自组织映射的配电终端自动化联调数据校验具体过程划分为网络结构初始化、欧氏距离计算、神经元选择、优化权空间、权向量归一化、全部数据输入、参数更新、终止条件设定8个环节^[10]。

网络结构初始化过程中， $\{w_{ij}\}$ 和 $\phi(0)$ 分别表示输入层与竞争层间的权向量和学习速率初始值，设

定 $\{w_{ij}\}$ 的取值为 $[0, 1]$ 范围内的随机值，而 $\phi(0)$ 值为0.8。以 $N_g(0)$ 表示邻域初始值，设定 $N_g(0)$ 值为 M ， M 表示整个竞争层。以 $\mathbf{X}_p = [x_1^p, x_2^p, \dots, x_N^p]$ 和 $\mathbf{W}_j = \{W_{j1}, W_{j2}, \dots, W_{jN}\}$ 分别表示输入向量（即配电终端自动化联调数据）和竞争层 j 节点的连接权向量，在输入一个配电终端自动化联调数据后；利用式(1)确定 $\mathbf{W}_j = \{W_{j1}, W_{j2}, \dots, W_{jN}\}$ 与 $\mathbf{X}_p = [x_1^p, x_2^p, \dots, x_N^p]$ 间的欧氏距离：

$$d_j = \left[\sum_{i=1}^N (x_i^p - W_{ji})^2 \right]^{1/2}, (j=1, 2, \dots, M)。 \quad (1)$$

式中 p 为数据样本编号。通过 $d_g = \min(d_j)$ 确定最小距离 d_g ，根据选择获胜神经元 g 。

以 $N_g(t)$ 表示竞争层第 g 个神经元的邻域，利用式(2)优化 $N_g(t)$ 内全部的神经元同输入层神经元间的连接权。权值优化次数为：

$$w_{ji}(t+1) = \begin{cases} w_{ji}(t) + \phi(t)[x_i^p - w_{ji}(t)], & j \in N_g(t) \\ w_{ji}(t), & j \notin N_g(t) \end{cases}。 \quad (2)$$

利用式(3)对连接权向量 $\mathbf{W}_j(t+1)$ 实施归一化^[11]：

$$\mathbf{W}_j(t+1) = \frac{\mathbf{W}_j(t+1)}{\|\mathbf{W}_j(t+1)\|}。 \quad (3)$$

式中 $\|\mathbf{W}_j(t+1)\| = [w_{j1}(t+1)^2 + \dots + w_{jN}(t+1)^2]^{1/2}$ 。

在自组织映射神经网络输入层内输入下一个配电终端自动化联调数据，返回欧氏距离计算环节，直至全部配电终端自动化联调数据全部输入一次。

利用式(4)优化 $\phi(t)$ 和 $N_g(t)$ ：

$$\left. \begin{aligned} \phi(t) &= \phi_0 \left(1 - \frac{t}{T}\right) \\ N_g(t) &= \text{int} \left[N_g(0) \left(1 - \frac{t}{T}\right) \right] \end{aligned} \right\}。 \quad (4)$$

式中 T 和 $\text{int}[x]$ 分别为整体学习次数和对 x 取整计算。

设定 $t=t+1$ ，返回欧氏距离计算环节，至 $t=T$ 结束。

在优化权向量环节中，归一化处理权向量，由此仅保留向量内的方向因素，快速将权向量优化至同对应的配电终端自动化联调数据输入方向相同^[12]，由此可提升自组织映射神经网络的学习时间。

通过上述过程能够实现配电终端自动化联调数据聚类，通过判断联调数据间的相关性确定配电终端自动化联调数据是否产生异常，实现配电终端自

动化联调数据校验目的, 解决了多源配电终端自动化联调数据不统一、难以实施清洗与校验的问题。

1.3 自组织神经网络优化

1.3.1 自适应竞争机制优化

以 $\delta(t)$ 表示邻域函数半径, 在标准自组织神经网络的训练周期中, $\phi(0)$ 与 $\delta(t)$ 的值均具有不变性, 且随时间而逐渐下降, 即无论 g 是否出现过度学习现象, 均能够获取一致的 $\phi(0)$ 与 $\delta(t)$ 。这种一致性针对次要数据并不公平, 需通过动态的 $\phi(0)$ 与 $\delta(t)$ 令竞争所获取的资源与 g 之间实现自适应^[13]。 $\phi(0)$ 与 $\delta(t)$ 的动态化过程如下:

$$\left. \begin{aligned} \phi_c(t) &= \phi(t) \left[1 + \mu \cdot \exp \left(-\frac{\|w_i - x_n\|^2}{N} \right) \right]^{-1} \\ \delta_c(t) &= \delta(t) \left[1 + \mu \cdot \exp \left(-\frac{\|w_i - x_n\|^2}{N} \right) \right]^{-1} \end{aligned} \right\} \quad (5)$$

式中: $\phi_c(t)$ 和 $\delta_c(t)$ 分别为 $\phi(0)$ 与 $\delta(t)$ 的动态化结果; μ 为弱化学习参数。

基于式(5)能得到, 在相同训练周期内, 利用 g 所获取的 $\phi_c(t)$ 和 $\delta_c(t)$ 是有所差异的, 这个差异性主要由其与配电终端自动化联调数据样本间的距离决定。

在配电终端自动化联调数据样本同权值差异较小的条件下:

$$\left. \begin{aligned} \phi_c(t) &\approx \phi(t)(1 + \mu)^{-1} \\ \delta_c(t) &\approx \delta(t)(1 + \mu)^{-1} \end{aligned} \right\} \quad (6)$$

在此条件下, X_j 的学习被弱化了。

在配电终端自动化联调数据样本同权值差异较大的条件下:

$$\left. \begin{aligned} \phi_c(t) &\approx \phi(t) \\ \delta_c(t) &\approx \delta(t) \end{aligned} \right\} \quad (7)$$

在此条件下, X_j 的学习就能够正常化。

由此可令基于自组织神经网络的配电终端自动化联调数据校验过程中的竞争过程与标准神经网络中的“胜者全得”标准有所差异, 是依照配电终端自动化联调数据的实际情况自适应地获取各类资源^[14]。与标准自适应神经网络相比, 通过优化自适应竞争机制能够令次要配电终端自动化联调数据获取更多与主要配电终端自动化联调数据竞争的机会, 实现更好的配电终端自动化联调数据分类。主要配电终端自动化联调数据在若干次训练后, 学习进一步弱化, 由此可防止出现因学习过度导致的冗

余问题。通过调整 μ 能够有效控制弱化学习水平。

1.3.2 基于灰关系分析的动态权值优化

在自组织映射神经网络学习时, 利用 g 能够优化邻域节点的权值, 由此提升配电终端自动化联调数据的聚类效果。一般情况下, 可依照 g 周边区域或高斯函数选择邻域节点, 基于学习率与输入模式更新权值。

但实际处理配电终端自动化联调数据过程中, 上述方法单独分析输入的配电终端自动化联调数据和待更新的单个神经元, 未考虑其他参与竞争的神经元间的相关性, 因此可通过灰色相关性能够对其进行描述。

基于灰色模糊集论与灰色关联为基础的灰色相关性内, 利用灰关系能够定量呈现系统间的相关性。以输入的配电终端自动化联调数据和权值分别为参考模式与对比模式, 灰关系系数 h_{ij} 为:

$$h_{ij} = \frac{\Delta_{\min} + \lambda \Delta_{\max}}{\Delta_{ij} + \lambda \Delta_{\max}} \quad (8)$$

式中 λ 为判别系数, 同时:

$$\left. \begin{aligned} \Delta_{\min} &= \min_{i=1, 2, \dots, M} \min_{j=1, 2, \dots, N} \|x_j - w_{ij}\| \\ \Delta_{\max} &= \max_{i=1, 2, \dots, M} \max_{j=1, 2, \dots, N} \|x_j - w_{ij}\| \\ \Delta_{ij} &= \|x_j - w_{ij}\| \end{aligned} \right\} \quad (9)$$

通过 h_{ij} 能够描述输入网络内的配电终端自动化联调数据与权值在各维度上的相关性。在 $\Delta_{ij} \rightarrow \Delta_{\min}$ 的条件下, $h_{ij} \rightarrow 1$, 由此表示此条件下权值与其他神经元权值相比, 同输入的配电终端自动化联调数据间具有更高的相关性。基于此相关性, 能够确定邻域内同当前输入的配电终端自动化联调数据相关性较弱的神经元^[15-16]。标准的自组织映射神经网络内, 邻域内的不同神经元更新权值过程中只考虑配电终端自动化联调数据的欧氏距离, 忽略不同神经元间的相关性。因此在更新权值过程中引入 h_{ij} , 依照同其他竞争神经元间的相关性动态优化权值:

$$\Delta w_{ij} = \eta(t) \times F(h_{ij}) \times [x_j - w_{ij}(t)] \quad (10)$$

基于式(10)能够得到, 输入的配电终端自动化联调数据同权值相关性弱的神经元更新权值被抑制, 由此提升了自组织映射神经网络对于配电终端自动化联调数据的处理效果。

2 实验结果

笔者研究基于自组织映射的配电终端自动化联调数据校验方法。为验证该方法在实际数据校验中

的应用效果，选取某配电站为研究对象，针对研究对象内部终端设备进行自动化联调，采集联调数据构建数据集，该数据集中包含配电终端遥信、遥测、保护遥信、保护遥测4种类型数据。采用该方法对数据集内的联调数据进行校验，判断联调数据是否产生异常。

2.1 联调聚类性能测试

为验证该方法中所使用的自组织映射神经网络在聚类方面的性能，从聚类结果中的数据趋向性、数据同源性、数据归属速率以及聚类标准率 ACC 等4个角度出发，对笔者方法进行验证。

针对聚类标准率 ACC，可通过式(11)进行计算。

$$ACC = \max_{\vartheta} \frac{\sum_{i=1}^n 1\{\lambda_i = \vartheta(\beta_i)\}}{n} \quad (11)$$

式中： λ_i 为实际类别划分的标签； ϑ 为聚类结果与实际类别划分标签间的1对1映射； $\sigma_i\beta_i$ 为笔者方法中自组织映射神经网络所得的聚类结果。

根据相关领域中的专家研究结果，设定数据趋向性取值高于65%、数据同源性高于80%、数据归属速率高于50%、而聚类标准率 ACC 高于95%，即可说明数据聚类性能较好。表2为笔者方法聚类结果的分析。

表2 数据聚类性能测试结果 %

指标	联调数据类型			
	遥信数据	遥测数据	保护遥信	保护遥测
数据趋向性	79.24	78.68	76.80	77.29
数据同源性	88.41	86.53	90.01	86.94
数据归属速率	57.26	55.06	62.91	59.68
聚类标准率 ACC	99.20	98.71	96.92	98.03

分析表2能够得到：采用该方法对4类不同的联调数据进行聚类分析过程中，聚类结果的数据趋向性和数据同源性始终高于76%和86%，数据归属速率始终高于55%，而聚类标准率 ACC 始终高于96%。上述指标的数据均高于标准值，由此说明该方法具有较好的数据聚类性能。

2.2 联调数据校验结果

采用该方法对研究对象数据集内部分数据进行校验，所得结果如表3所示。

分析表3能够得到，采用该方法对联调数据集内的联调数据进行校验时，能够有效发现联调数据集内的异常数据，且对联调数据是否异常的判断结果均为准确结果，由此说明该方法能够有效实现联调数据的校验目的。

表3 部分联调数据校验结果

数据编号	笔者方法校验结果	是否准确
000153	异常数据	准确
000462	异常数据	准确
001207	非异常数据	准确
002522	非异常数据	准确
006019	异常数据	准确
010594	异常数据	准确
016283	异常数据	准确
021950	非异常数据	准确
030414	非异常数据	准确
034539	异常数据	准确

2.3 应用效果分析

对比采用笔者方法进行校验前后，研究对象联调数据集内联调数据异常率的变化情况，所得结果如表4所示。

表4 联调数据异常率变化情况 %

联调数据类型	采用笔者方法校验前	采用笔者方法校验后
遥信数据	0.036	0.002
遥测数据	0.042	0
保护遥信	0.098	0.004
保护遥测	0.103	0.004

分析表4得到：采用该方法对联调数据集内联调数据进行校验前，各类联调数据内的异常率范围为0.036%~0.103%，而采用该方法对联调数据集内联调数据进行校验后，各类联调数据内的异常率范围为0~0.004%。由此能够说明该方法显著降低研究对象联调数据集内联调数据的异常率，提升研究对象终端设备联调效果。

3 结论

笔者研究基于自组织映射的配电终端自动化联调数据校验方法，利用自组织映射神经网络对联调数据聚类，基于联调数据间的相关性判断数据是否异常。实验结果表明：该方法能准确聚类联调数据，并能有效对联调数据进行校验，满足最初研究目的。在后续优化过程中，将主要针对自组织映射网络中神经元数量非固定的情况，进行进一步研究。

参考文献：

- [1] 邢晓敏, 徐海瑞, 廖孟柯, 等. 基于云模型和 D-S 证据理论的配电终端健康状态综合评估方法[J]. 电力系统保护与控制, 2021, 49(13): 72-81.
- [2] 李博达, 熊宇峰, 任正伟, 等. 台风期间考虑配电终端功能可用性的配电网重构方法[J]. 电力系统自动化, 2021, 45(4): 38-44.