

DOI: 10.19783/j.cnki.pspc.181497

基于遥信数据故障编码技术及 DHNN 校正的 电网故障诊断方法

肖飞¹, 杨建平¹, 邓祥力², 叶康¹, 魏聪聪²

(1. 国网上海市电力公司, 上海 200122; 2. 上海电力大学电气工程学院, 上海 200090)

摘要: 提出采用故障编码技术形成故障空间最优编码集, 然后通过模板匹配的方式进行电网故障诊断的方法。针对由于缺少前端故障遥信数据处理的清洗算法, 造成故障诊断算法诊断正确率不高的问题, 提出了建立离散 Hopfield 神经网络模型用于故障遥信数据的前端数据清洗的算法。利用故障遥信数据之间的相关性对遥信变位数据进行分组, 并对各组数据分别采用所提出的算法进行数据清洗, 利用穷举输入状态数据的方法求取了算法的修正域, 从而建立了 DHNN 清洗模型。最终形成具有纠错能力的电网故障智能诊断方法, 实现在故障诊断空间内对故障元件的诊断。通过实际电网的故障遥信数据的测试, 验证了 DHNN 神经网络信息纠正模型和故障诊断模型对电网故障元件诊断的有效性。

关键词: 故障遥信; 数据清洗; 离散 Hopfield 神经网络; 电网故障诊断

A fault diagnosis method of power grid based on remote signal data fault coding technology and DHNN correction

XIAO Fei¹, YANG Jianping¹, DENG Xiangli², YE Kang¹, WEI Congcong²

(1. State Grid Shanghai Municipal Electric Power Company, Shanghai 200122, China;

2. School of Electric Engineering, Shanghai University of Electric Power, Shanghai 200090, China)

Abstract: This paper proposes a method for power grid fault diagnosis based on fault coding technology, which first forms the optimal code set of fault space and then makes template matching. Aiming at the problem that the diagnostic accuracy of fault diagnosis algorithm is not high due to the lack of cleaning algorithms for front-end fault remote signal data processing, this paper proposes an algorithm of establishing discrete Hopfield neural network model for front-end data cleaning of fault remote signal data. The correlation between the faulted remote signal data is used to group the remote signal displacement data, and the algorithm proposed in this paper is used for data cleaning, and the modified domain of the algorithm is obtained by exhaustive input state data. Thus the DHNN cleaning model is established. Finally, an intelligent power grid fault diagnosis method with error correction capability is formed to realize the diagnosis of fault elements in the fault diagnosis space. The validity of Hopfield neural network information correction model and fault diagnosis model in fault component diagnosis of power grid is verified by testing the fault remote communication data of actual power grid.

This work is supported by National Natural Science Foundation of China (No. 51777119) and Science and Technology Project of State Grid Shanghai Electric Power Company (No. 520900170024).

Key words: fault remote signal; data cleaning; discrete Hopfield neural network; power system fault diagnosis

0 引言

目前利用遥信变位数据进行电网故障诊断的算

法中, 为了提高电网故障诊断的正确率, 需研究对遥信数据进行清洗的算法, 即对遥信中的差错数据进行清洗, 同时不影响正常数据使用的方法。现有故障诊断算法利用算法本身的容错机制对遥信误变位或丢失数据进行纠正, 如 Petri 网、0-1 规划、多维方程求解等方法。文献[1]提出一种遥信纠错理

基金项目: 国家自然科学基金项目资助(51777119); 国网上海市电力公司科技项目资助(520900170024)

念, 但并未做深入研究。文献[2]提出了一种基于负荷预测与关联规则修正的不良数据辨识方法。文献[3]提出基于信息流监测与报文解析技术的诊断方法。文献[4]提出了一种智能备份监控系统, 用于检测和分类电网中发生的输电线路故障类型。文献[5]通过构造虚拟事件集, 利用故障推理链来推理出遥信的可靠性, 建模机制复杂, 但运算过程复杂, 难以处理大规模电网、复杂故障的诊断。文献[6]提出一种基于语义分析的电网遥信信息解析方法, 没有清洗流程, 难以对差错数据进行纠正。文献[7]建立时序加权模糊网, 通过比较引入时序信息前后的模糊故障度, 验证时序加权模糊网在诊断中的有效性。文献[8]基于电网二次系统模型, 以量测量的变化信息为辅助, 实现对 SCADA/EMS 上送信息的识错功能。文献[9]采用数据挖掘的方法, 构造分类器, 从历史数据中挖掘出规则, 去除实时报警信息的噪声。文献[10]建立了一种保护信息逻辑模型, 用它来推理遥信信息的误报、漏报情况, 可移植性差。文献[11]提出了将专家系统与信息论相结合的故障诊断新方法, 采用专家系统正反向推理功能和信息理论来度量故障过程中的不确定性和遥信错误造成的不确定性。文献[12]把故障诊断问题转化为 0-1 规划问题, 纠正 SOE 中的变异事件, 得到高的容错性能。文献[13]提出一种基于粗糙集理论和朴素贝叶斯网络的电网故障诊断方法, 先利用粗糙集进行属性约简, 分析故障信息的冗余性, 提取关键属性, 然后利用贝叶斯网络的柔性推理得出诊断结果, 可提高系统在缺失关键报警信息情况下的容错性。文献[14]介绍了一种实现故障信息数据滤波的方法。这些算法大多数通过复杂数学模型的求解, 得出在一定概率下的期望变位遥信数据, 再和实际故障遥信数对比, 检测出误变位或丢失的遥信数据。算法复杂、运算量大, 没有专门针对遥信数据差错进行纠正, 而是通过建立数学模型来考虑对遥信差错数据的影响, 使得电网故障诊断结果准确度不高。其复杂的数学计算过程难以适应于电网大数据平台下、大量遥信变位数接入算法诊断的时效性。

因此, 有必要研究单独的遥信变位数的数据清洗方法, 在利用故障诊断算法前, 首先对采集到的故障遥信数据进行清洗, 对干扰误变位数据进行修正, 对丢失数据进行补充, 查找差错数据, 从而查找数据误变位及丢失的原因, 对提高大电网故障诊断的精度, 具有重要的意义。离散 Hopfield 神经网络 (DHNN)^[15]是一种全连接的递归神经网络。已经广泛地应用于不同的领域, 如模式识别^[16-17]、图

像处理^[18]和信号检测^[19]等方面。由于其良好的联想记忆功能^[20], 在字母和数字识别^[21-24]方面的作用尤为突出。本文将其应用到电网故障诊断方面, 通过分析离散 Hopfield 神经网络的特点和工作原理, 设计了对故障遥信数据进行清洗的算法, 对本文提出的问题提出了一种解决思路。

本文采用故障编码技术, 并根据监控遥信量的任意组合形成数据样本, 通过 k-means 聚类方法形成故障空间最优编码集。故障时, 在大数据平台中将遥信二进制数据映射到故障诊断空间, 在故障诊断空间内利用最优编码集对故障遥信编码进行识别, 从而对电网故障进行快速诊断。为了构建 DHNN 模型, 本文根据遥信数据位的相关性建立遥信数据组, 并形成多个记忆模式, 利用记忆模式训练 DHNN 模型, 并利用变电站数据丢失规则求取模型数据吸引域, 形成遥信数据清洗模型, 对遥信差错数据进行纠正。通过仿真研究, 验证了本文所提方法的可行性, 并分析了其优势和局限性。

1 离散 Hopfield 神经网络(DHNN)对二进制数纠正的基本原理

1.1 离散 Hopfield 神经网络(DHNN)的网络结构

离散 Hopfield 神经网络(DHNN)具有很强的记忆和联想功能, 利用其联想功能可以对遥信二进制数进行数据清洗, 其网络结构图如图 1 所示。

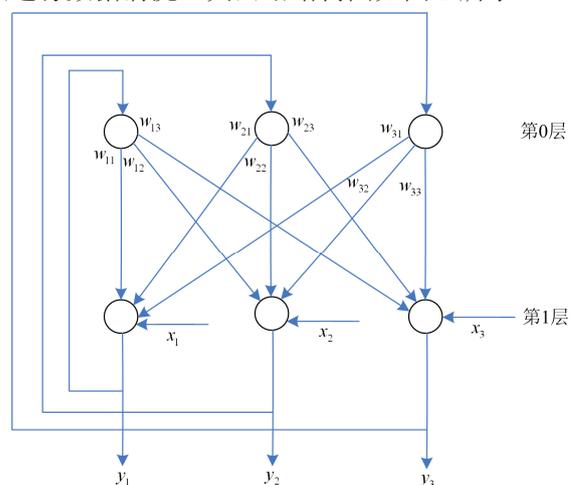


图 1 离散 Hopfield 神经网络图的结构

Fig. 1 Structure of discrete Hopfield neural network graph

图 1 中, 第 0 层为输入层, 没有计算功能, 第 1 层为输出层, 含有神经元, 具有计算功能。神经元计算函数为简单的阈值函数。其描述方程式为式 (1)一式(3)。

$$u_j(t) = \sum_{i=1}^n w_{ij} y_i(t) + x_j - \theta_j \quad (1)$$

$$y_j(t+1) = f[u_j(t)] = \begin{cases} 1, & u_j(t) \geq 0 \\ -1, & u_j(t) < 0 \end{cases} \quad (2)$$

$$\mathbf{Y}(t) = [y_1(t), y_2(t), y_3(t), \dots, y_n(t)]^T \quad (3)$$

式中: w_{ij} 为神经元连接权值; x_j 为神经元处理函数截距; θ_j 为神经元处理函数阈值。神经网络的输出值为向量 $\mathbf{Y}(t)$, 为 n 个输出层神经元的输出状态。

DHNN 的网络参数的训练就是利用训练样本 $\mathbf{S} = \{\mathbf{Y}_1, \dots, \mathbf{Y}_n\}$, 设定输出层神经网络的状态, 采用最优的方法求解连接权值 w_{ij} 。不同的训练样本向量代表了不同的输入模式, 通过不断的寻优过程, 求出一组最优连接权值 w_{ij} , 完成了对样本模式的记忆功能。如果输入的模式不同于训练样本模式, 则 DHNN 选取最接近的一组模式为输出, 实现了其联想功能, 即具有很好的纠错功能, 把由于干扰出错的二进制数据进行纠正, 还原其真实值。

1.2 离散 Hopfield 神经网络(DHNN)输出状态的计算

当网络参数 w_{ij} 和 θ_j 确定后 DHNN 就确定了, 当输入一组 $\mathbf{Y}(t)$ 样本后, DHNN 输出值不断变化, 最终为稳定定值, 即 $t+1$ 时刻状态值 $\mathbf{Y}(t+1)$ 。DHNN 有两种工作方式:

串行工作方式。在某一时刻只有一个输出神经元的状态改变。通过随机的方式改变下一个神经元的输出状态, 所以神经元输出的变化次序是随机的。

并行的工作方式。输出神经元状态的改变通过分组来实现, 每次有一个组的输出神经元状态改变。

当满足 $\mathbf{Y}(t) = \mathbf{Y}(t+1)$ 时, 输出神经元状态不再改变, 神经网络处于稳定状态。从图 1 可以看出, Hopfield 网络模型是一个多输入、多输出、带阈值的输出状态为“0”和“1”非线性动力学系统。如果以能量函数来描述 Hopfield 网络的动力学行为, 给定一组样本数据的情况, 能量函数在网络运行过程中不断降低, 最后趋于稳定平衡状态的最小能量值。

如果输出层神经元的状态用 v_i 表示, 则能量函数可表示为

$$E = -\frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n w_{ij} v_i v_j + \sum_{i=1}^n \theta_i v_i \quad (4)$$

式中, n 为输出层神经元的个数。

Hopfield 网络输出状态变化后, 网络能量函数的变化量为

$$\Delta E = -\left(\sum_{j=1}^n w_{ij} v_j - \theta_i\right) \Delta v_i \quad (5)$$

当输出状态 v_i 由 0 变为 1 时, $\Delta v_i > 0$, 当输出状态 v_i 由 1 变为 0 时, $\Delta v_i < 0$ 。

从中可以看出, DHNN 模型在状态更新过程中, 其能量函数 E 总是随状态变化而严格单调递减, 最终稳定在某一确定状态。同时, DHNN 模型的最终稳定输出状态和能量函数 E 的状态空间中的局部极小值点一一对应。所以, DHNN 模型的计算过程就是给定权值 w_{ij} , 计算对应能量函数最小的输出状态的过程。

Hopfield 网络的记忆功能就是给定样本作为其稳定的状态, 通过网络的学习求合适的权矩阵 \mathbf{W} (对称阵) 的过程。联想功能就是已知权矩阵 \mathbf{W} , 寻找具有最小能量 E 的网络稳定状态。学习样本值对应能量函数状态空间的极小值点。

1.3 DHNN 模型能量极小值对应状态空间点的确定

能量极小值点对应网络的一个稳定平衡点。如果将输入样本信息存储于不同的网络能量极小值点, 则可以实现 DHNN 模型的记忆功能。如果输入数据和样本数据均不相同, 则可以利用 DHNN 模型的联想功能, 找出相应的记忆数据。

能量极小点的数值由 DHNN 模型联接权值和阈值决定。可以采用 Hebb 学习规则^[25]和误差型学习算法求取连接权值矩阵 \mathbf{W} 。

DHNN 在学习训练的计算方法中有两种工作模式: 学习记忆模式和计算工作模式。当处于学习工作模式时, 网络的稳定状态和能量极小值是给定的, 通过网络的学习求合适的权矩阵 \mathbf{W} (对称阵)。当处于计算工作模式时, 其权矩阵 \mathbf{W} 已知, 求取对应网络能量极小点的状态。

权值设计的方法有外积法、伪逆法、正交设计法等。外积法 (Hebb 学习规则): 是一种比较简单高效的方法, 其公式为

$$\mathbf{W} = \sum_{k=1}^m [\mathbf{X}^{(k)} (\mathbf{X}^{(k)})^T - \mathbf{I}] \quad (6)$$

$$w_{ij} = \sum_{k=1}^m x_i^k x_j^k, \quad w_{ii} = 0, \quad i = 1 \sim n \quad (7)$$

式中: $\mathbf{X} \in R^n$; $K = 1 \sim m$; \mathbf{I} 为 $n \times n$ 的单位阵; $\mathbf{X}^{(k)}$ 表示第 K 个样本向量。

在学习记忆模式下, 已知样本向量, 通过上述公式计算出连接权值 \mathbf{W} 后, 输入样本的 K 个模式实际上已存入连接权值 \mathbf{W} 中。在计算模式下, 输入某组数据向量使得 DHNN 处于某种初始状态, 通过输出状态的多次翻转, 即网络方程动态运行, 最终达到一个稳定的网络状态, 如果和 K 个样本模式中的某种模式相同, 则实现了 DHNN 的联想功能。

Hopfield 网络用于联想记忆受其记忆容量和样本差异制约。当记忆的模式较少且模式之间的差异较大, 则联想结果正确; 而当需记忆的模式较多就容易引起混淆, 网络到达的稳定状态往往不是已记忆的模式。此外当需记忆的模式之间较为相近时网络就不能辨别出正确的模式, 甚至连自身都会联想错, 即使用已记忆的模式作为联想模式(自联想), 也可能出错。

2 基于遥信数据的智能故障诊断方法原理

2.1 遥信数据组的编码

目前电网调度人员对电网故障的分析以单个遥信数为单位, 所以效率低、分析时间长。所以应该首先把故障遥信进行分组, 以组为单位把故障遥信进行编码, 再查找故障遥信编码库, 找到匹配故障编码类型, 输出诊断结果。

本文把遥信数据分为: 故障过程组、保护动作组合故障类型组, 分组编码方法为

$$\begin{cases} f_1(A_1) = c_1 \\ \vdots \\ f_n(A_n) = c_n \end{cases} \quad (8)$$

式中: A_1, \dots, A_n 为 n 个故障后遥信二进制数据矩阵; c_1, \dots, c_n 为通过编码后的故障编码数据; f_1, \dots, f_n 为 n 个故障编码映射函数。通过方程(8), 实际上完成了遥信二进制数到 n 维编码空间 (c_1, \dots, c_n) 的映射, 所以, 利用遥信变位数据的故障诊断问题, 转换为多维空间中的样本数据的归类问题。

2.2 利用聚类算法形成故障遥信编码库

对故障遥信分组编码的方法, 实质是把单个的遥信数据映射到了故障诊断空间内。按照故障类型遥信任意组合形成的编码库的编码数据庞大, 对应故障诊断空间的点的数目也很大, 故障空间故障类型点之间的距离很小, 很容易出现误归类的情况。所以, 应该在故障空间中, 通过聚类的方法形成最优编码集, 成为故障类型诊断的最简标准编码库, 如图 2 所示。图 2(a)和图 2(b)中空间点的各个坐标是由式(8)所形成的码值, 无单位。

2.3 遥信数据清洗模式的确定

本文作为故障诊断算法的清洗方法, 以相关联的遥信数组为单位进行清洗, 对错误数据或丢失数据进行修正, 便于故障诊断算法的正确判断。以线路的遥信数据故障诊断为例, 本文把输电线路的故障后产生的遥信数据分为故障过程诊断类、保护动作诊断类和跳闸类型类 3 个类型。

以保护动作类型为例, 其遥信数据组的内容如表 1 所示。

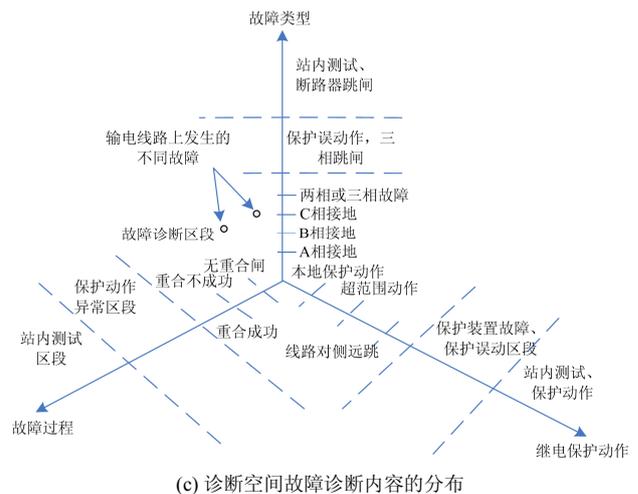
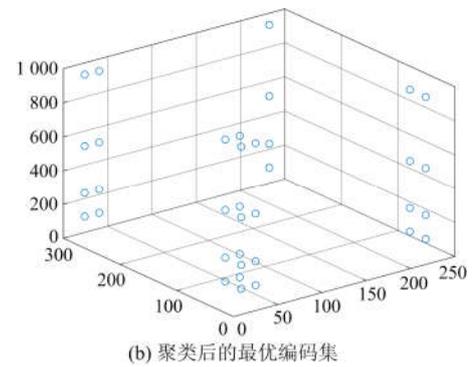
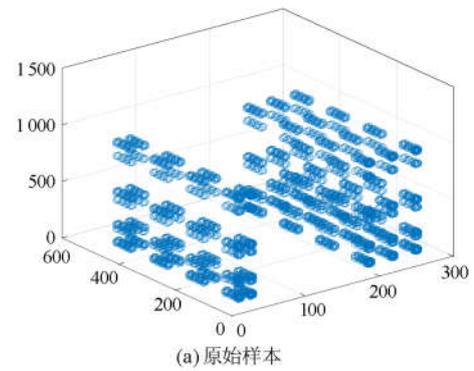


图 2 最优编码集的形成

Fig. 2 Formation of standard fingerprint database

表 1 遥信数据组的内容

Table 1 Content of the remote data group

一套主保护	二套主保护	后备保护	远方跳闸 1	远方跳闸 2
a_1	a_2	a_3	a_4	a_5

表 1 中, $a_1 \sim a_5$ 为遥信数据位, 其取值为 0 或 1。由于通信干扰等原因可能出错或丢失。当遥信数据丢失时, 故障诊断算法认为这一位遥信数据没有变位, 其值为 0。故障诊断清洗算法的目的就是对遥信数据中的差错进行修正, 对遥信丢失数据进行修补, 而没有发生差错的数不进行纠正, 保持不变。

根据以上分析,变电站内故障遥信数据有以下特点。

1) 变电站上传的遥信数据仅有少数数据位发生差错,由于监控系统或一次设备的原因,会经常发生某一位的数据丢失。所以待清洗的遥信数据组模式不会是数据组内部遥信位数的所有组合模式,仅需要对少数有限组模式进行校正。

2) 通过变电站内部历史故障遥信数据的差错或丢失情况,确定清洗数据的模式,其他没有出现

的变电站数据模式可以剔除,减少算法的复杂度和数据清洗的正确性。

对于表 1 所示的保护动作类型遥信数据组,其所有位的组合方式有 25 个,但实际电网中可能出现的正确的方式只有几种。根据变电站历史遥信数据,大概可以确定模式,有远方跳闸遥信则不可能出现本地跳闸模式,几种可能的模式如表 2 所示。

表 2 几种可能的遥信数据组

Table 2 Several possible remote data sets

序号	故障录波启动	一套主保护	二套主保护	后备保护	远方跳闸 1	远方跳闸 2	故障类型
1	1	1	1	1	0	0	线路区内故障
2	1	0	0	1	0	0	线路区外故障
3	1	0	0	0	1	0	远方一套保护跳闸
4	1	0	0	0	0	1	远方二套保护跳闸

表 2 对应了输电线路故障的几种标准的遥信变位模式,其他的遥信数据模式要么属于数据差错,要么属于信息冗余。比如,线路区内故障正常情况下可能产生一套主保护、二套主保护和后备保护动作信号,但经常会发生只有一套主保护的动遥信,没有后备保护动作遥信的情况,这些情况在数据清洗算法中都输入需要纠正的情况。所以,通过遥信数据清洗算法可以将其他模式修正成以上 4 种标准模式。

2.4 基于 DHNN 的遥信清洗算法

表 2 中的遥信数据标准模式可以作为 DHNN 算法的记忆模式,即吸引子,用于训练网络。通过 Hebb 规则的外积法,计算网络的权值矩阵,确定 DHNN 网络的参数,然后故障诊断算法接收到故障遥信数据后,按相关性进行分组,然后输入到训练好 DHNN 网络进行修正。

记忆模式吸引域的求取采用穷举可能的输入数据状态的组合,输入 DHNN 算法,根据归类结果求取吸引域。DHNN 模型实际上是一个非线性动力学模型,输入状态数据后在每次求解过程中不断变化,最终收敛于网络能量局部最小值。如果记忆模式向量相互正交,记忆模式对应的能量值都是局部最小值,输入不同的状态值最终都会收敛于记忆模式向量。如果输入模式向量不完全正交,网络的计算过程会陷入局部能量极小值点,对应的归类输出向量为伪记忆向量(伪吸引子),即输入状态向量会被归类到错误的状态向量上去。清洗算法流程图如图 3 所示。

2.5 故障诊断的流程

如图 4 所示,故障诊断流程分为故障空间最优

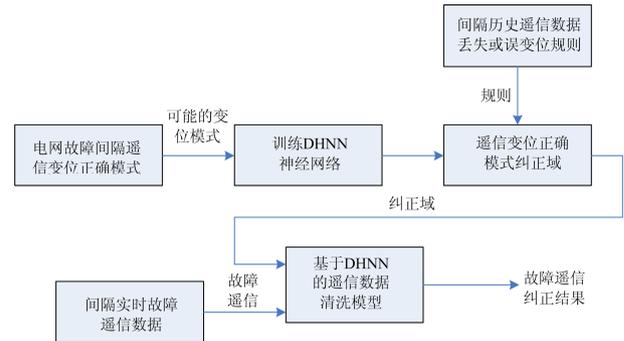


图 3 基于 DHNN 的遥信数据清洗算法

Fig. 3 Remote data cleaning algorithm based on DHNN

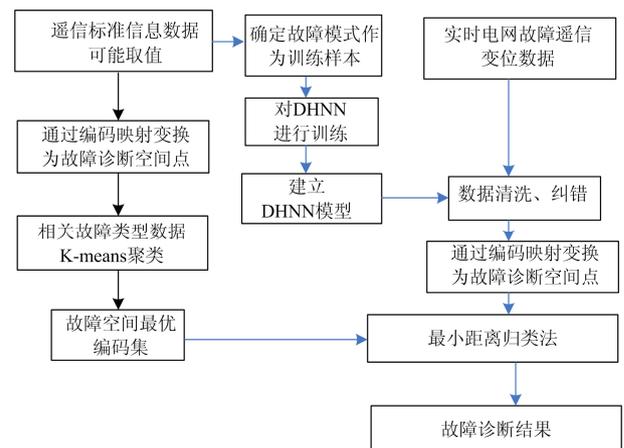


图 4 智能故障诊断方法流程

Fig. 4 Intelligent fault diagnosis method flow chart

编码集的形成、DHNN 模型的建立、实时故障遥信数据归类三部分。根据标准遥信信息数据的所有可能组合,形成遥信变位数据最大集样本,利用故障诊断空间映射编码和 K-means 聚类方法,求取故障

空间最优编码集; 并利用最大数据样本提取故障模式作为 DHNN 训练数据, 建立 DHNN 模型, 作为数据清洗和纠错的神经网络模型。捕获电网故障的实时遥信变位数据, 通过 DHNN 模型对遥信误变位和丢失数据分别进行纠正和修补, 然后把清洗后的遥信数映射到故障诊断空间。通过最小距离法在故障诊断空间内对故障数据进行归类, 输出诊断结果。

3 仿真研究

某市电网 500 kV 输电线路区内故障接线图如图 5 所示, A 变电站和 B 变电站之间通过 500 kV 输电线路连接, 通过本文基于 DHNN 算法对 A 变电站的故障遥信变位数据进行清洗, 以满足故障诊断算法故障诊断正确性的要求。

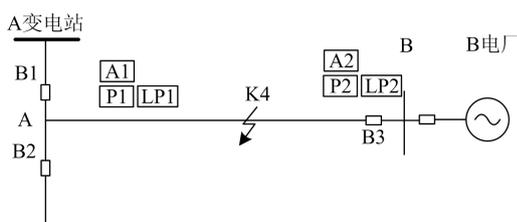


图 5 某市 500 kV 输电线路区内故障

Fig. 5 Fault in a 500 kV transmission line in a city

输电线路故障或电网其他设备上故障, A 变电站内会有故障遥信数据上传到调度中心, 为了便于故障诊断算法的处理, 通常会把相关联的遥信数据进行分组。A 变电站和输电线路 AB 相关的故障遥信数据可以分为 3 个组: 故障过程遥信数据组、保护动作遥信组和跳闸类型数据组。故障过程遥信数据组={AB 线路保护出口, 断路器跳闸出口, 线路保护重合闸出口, 线路保护后加速出口, 断路器跳闸出口}, 其中两次断路器跳闸出口表示重合闸前和重合闸后两次断路器跳闸遥信信息。保护动作遥信数据组={故障录波启动, 一套主保护, 二套主保护, 后备保护, 远方跳闸 1, 远方跳闸 2}。跳闸类型数据组={A 相跳闸, B 相跳闸, C 相跳闸, 三相跳闸}。因为 500 kV 输电线路只有单相跳合闸遥信和三相跳合闸遥信, 所以没有两相故障的遥信动作信息。

对应的记忆模式为: 故障过程遥信数据组为 3 个记忆模式 $\{(1,1,0,0,0), (1,1,1,0,0), (1,1,1,1,1)\}$, 分别表示 {无重合闸故障快速切除、瞬时故障重合成功, 重合闸不成功永久故障切除}。保护动作遥信数据组为 4 个记忆模式 $\{(1,1,1,1,0,0), (1,0,0,1,0,0), (1,0,0,0,1,0), (1,0,0,0,0,1)\}$, 分别表示 {线路区内故障, 线路区外故障, 远方一套保护跳闸, 远方二套保护跳闸}。跳闸遥信数据组为 4 个记忆模式

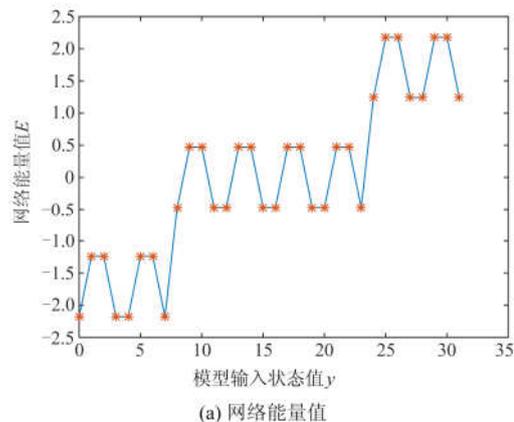
$\{(1,0,0,0), (0,1,0,0), (0,0,1,0), (0,0,0,1)\}$, 分别表示不同相断路器跳闸。

用 3 个数组的记忆模式分别训练 3 个不同的 DHNN 网络, 通过外积法获得 3 个不同网络结构的权值矩阵 W_1 、 W_2 和 W_3 , 建立不同的数据清洗数学模型。

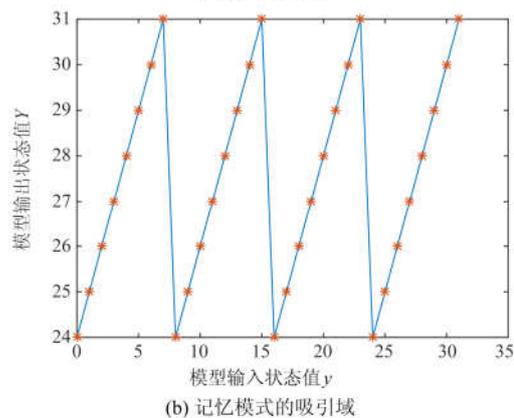
3.1 故障过程遥信数据组的清洗域的求取

建立 DHNN 网络数据清洗模型后, 还关心不同输入二进制数据的模型输出状态值。记忆模式的状态所对应输入二进制数据的范围, 为记忆模式的数据清洗域。

为便于后续的仿真和分析, 本文把二进制数组变为十进制数。所以, 把清洗数据组的遥信状态位数转化为十进制数, 如故障过程遥信数据组记忆模式 1 转换为十进制数表示为: $(11000)_2 = (24)_{10}$ 。图 6 中的横坐标为输入 DHNN 模型的遥信状态位对应的十进制数, 采用穷举法研究清洗模型的记忆模式吸引域, 如故障过程遥信数据组有 5 个状态位, 对应的状态位组合方式为 25 种, 对应的十进制数据范围为 $2^0 \sim 2^5 (0 \sim 32)$ 。该分析方法同样应用于以下的保护动作遥信数据、跳闸遥信数据组清洗的分析。DHNN 模型算法为 18 次循环。网络能量值与记忆模式的吸引域如图 6 所示。



(a) 网络能量值



(b) 记忆模式的吸引域

图 6 故障过程遥信数据的清洗

Fig. 6 Cleaning of the fault process remote signal data

图 6 中横坐标为输入 DHNN 模型的状态位二进制数对应的十进制数。图 6(a)为网络的能量函数值,收敛于 6 个最小能量函数值。图 6(b)为输入所有状态位数据 DHNN 模型的输出结果。从图中可以看出,清洗算法一共有 8 个收敛解,而故障过程遥信数据只有 3 个记忆模式,有 5 个为虚假记忆模式,如果不对清洗数据进行滤除,模型有可能收敛到虚假的记忆模式上(修正错误),造成后续故障诊断算法的误诊断。收敛于 3 正确记忆模式的吸引域如图 7 所示。从图 7 可以看出,如果输入的数据为记忆的 3 种模式图中分别为 24、28、31,输出不会改变。说明数据没有差错的情况下,数据清洗结果不受影响。其他 3 个点均为含有差错的数据,DHNN 模型按照记忆模式对其进行了纠正,其吸引域只有 4 个点。

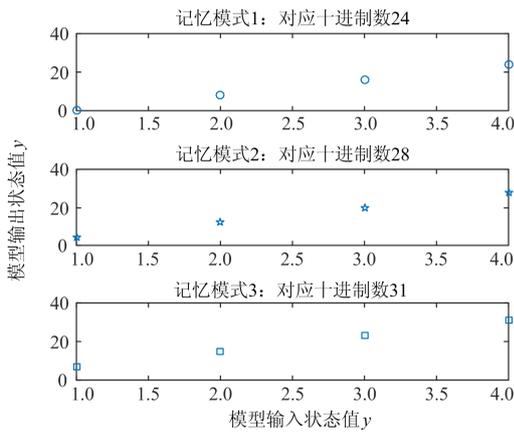


图 7 故障过程遥信数据吸引域

Fig. 7 Attraction domain of the fault process remote signal data

3.2 保护动作遥信数据组清洗域的求取

保护动作遥信数据的清洗算法的结果如图 8、图 9 所示。由于保护动作遥信待清洗状态数据位为 6 位,因此有 26 种输入状态。图 8(a)为 DHNN 模型收敛到吸引子后模型能量函数的局部最小点。从图 8(b)吸引域可以看出清洗算法一共有 8 个收敛解,而记忆模式是 4 个,因此有 4 个吸引子为虚假收敛解,需要把收敛到虚假解的输入状态从输入数据中剔除,否则会出现虚假的修正结果。最后可得出保护动作遥信数据的吸引域,如图 9 所示,共有 8 个状态点。

3.3 跳闸遥信数据组的清洗

跳闸数据的清洗如图 10、图 11 所示。从图 10(a)可以看出能量函数没有局部最小值,不同的输入状态值获得不同的能量函数值。从图 10(b)可看出,DHNN 模型几乎没有记忆模式,其图形为角度是 45° 的直线,说明输入什么状态输出即为什么状态。原

因是训练数据向量矩阵(记忆模式)为对角阵,所含信息单一。其吸引域如图 11 所示,为单个转态点,即输入的哪几种模式,输出还是哪几种模式,网络没有修正作用。

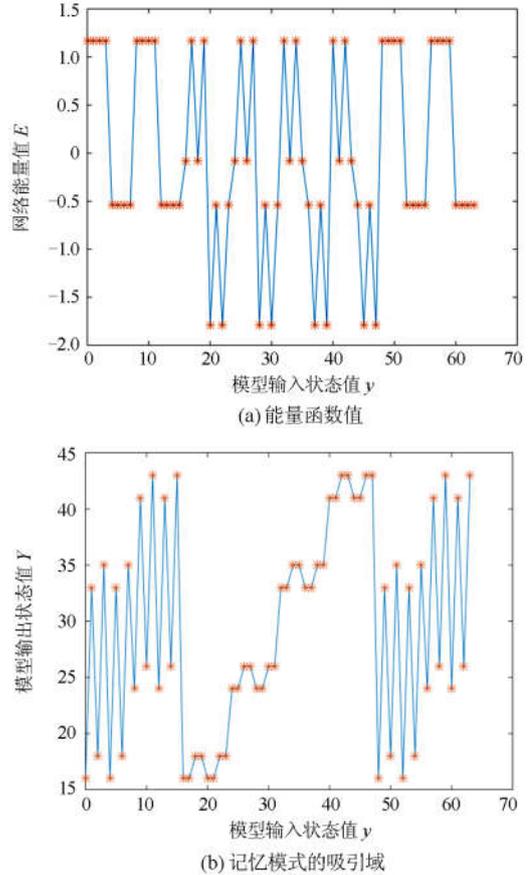


图 8 保护动作遥信数据的清洗

Fig. 8 Cleaning of the protection action remote signal data

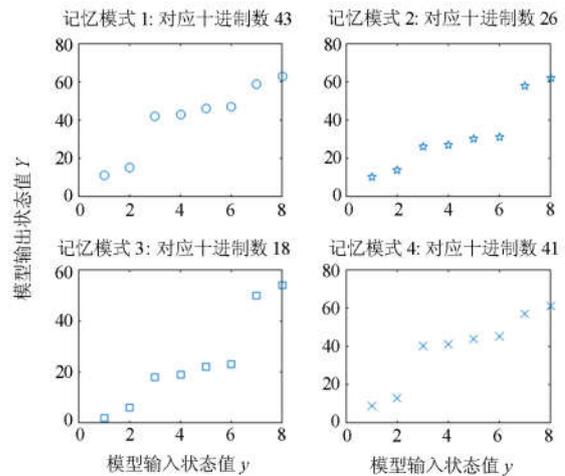


图 9 保护动作遥信数据的吸引域

Fig. 9 Attraction domain of the protection action remote signal data

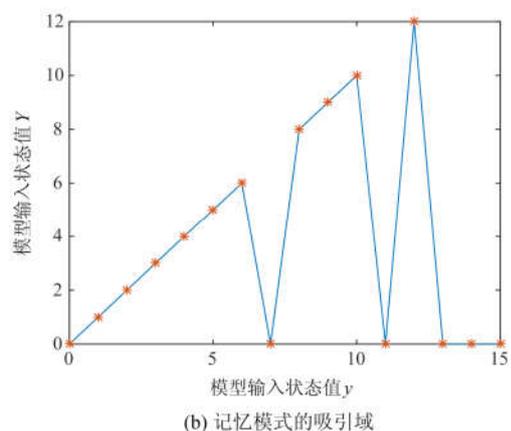
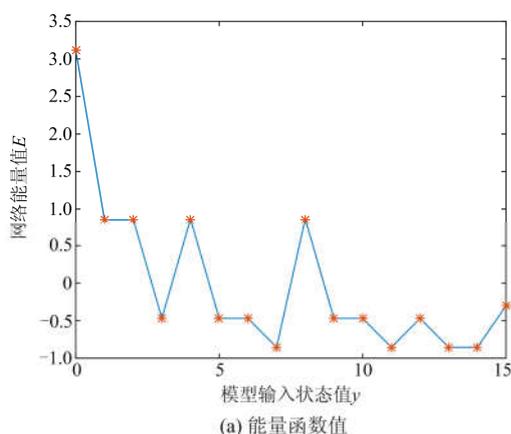


图 10 跳闸遥信数据组的清洗

Fig. 10 Cleaning of the tripping remote data

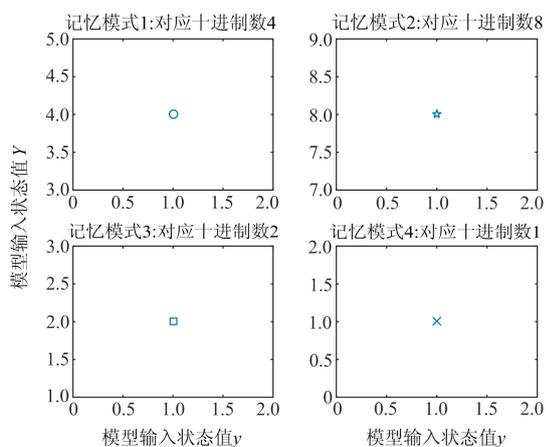


图 11 跳闸遥信数据吸引域

Fig. 11 Attraction domain of the tripping remote data

所以, 通过穷举法对故障过程遥信数据组、保护动作遥信数据和跳闸遥信数据组清洗过程的分析, 3 个清洗过程都会存在虚假吸引子, 在运用清洗算法前, 应该对处理的数据进行过滤, 避免原始数据被修正到虚假吸引子上。3 个清洗过程中, 保

护动作遥信数据的吸引域范围最大, 为 8 种模式, 跳闸遥信数据吸引域最小, 为其本身, 实际上已经失去数据修正能力。

3.4 故障案例分析

1) 单一故障的诊断

接线图如图 5 所示的某市电网 500 kV 输电线路发生区内故障, 故障过程为: 18:26 市调监控发现 AB 线事故跳闸, 重合不成功, 线路主保护均动作。

利用本文算法, 捕获故障发生后的遥信变位数据, 通过 DHNN 模型数据清洗后, 把遥信数据映射到故障诊断空间。通过最小距离法在故障诊断空间内对故障数据点进行归类, 其诊断结果如图 12 所示。

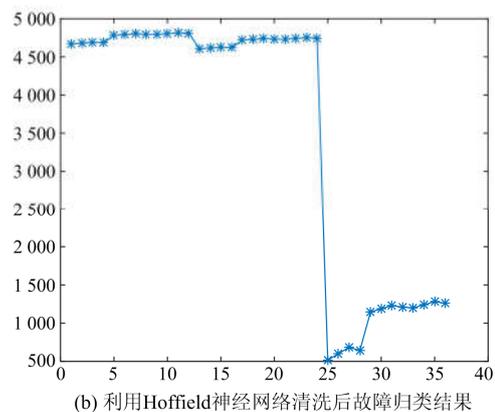
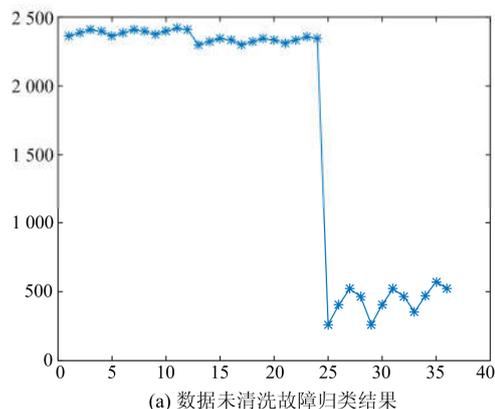


图 12 利用最优编码集故障归类结果

Fig. 12 Fault classification results using standard fingerprint database

从图 12 可以看出, 图 12(a) 未经过 Hoffield 神经网络清洗, 使得误变位数据参与归类算法的计算, 所以第 25 类故障和第 29 类故障比较接近, 造成误归类。从图 12(b) 中可以看出, 归类结果为 25, 准确归类到实际的故障类型, “重合不成功故障切除、本地保护动作、A 相接地”。所以, 本文指纹编码诊断结果为: AB 线故障、本地保护动作、重合不成功故障切除, 和人工分析结果一致。

2) 复杂故障的诊断

本文引用文献[26]某地一次真实故障，验证该技术方法。如图 13 所示，220 kV 变电站 1 到变电站 2 的 L2551 线发生单相接地故障，两侧断路器的高频保护动作，变电站 2 侧 2402 号断路器跳闸，但变电站 1 侧 2205 号断路器拒动，引起变电站 1 的 1 号母线失灵保护动作，跳开母联 2210 号断路器和 2204 号断路器，但变电站 1 的 2203 号断路器拒动作，引起 L2553 变电站 4 侧距离保护动作，跳变电站 4 的 2301 号断路器，至此故障切除。

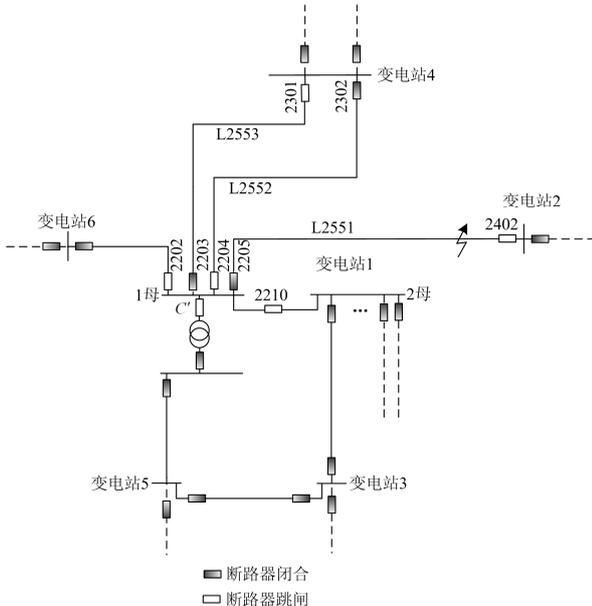


图 13 复杂故障诊断实例

Fig. 13 Example of complex fault diagnosis

图 13 为复杂的连锁故障的诊断，故障诊断的

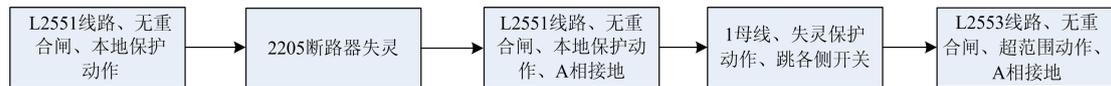


图 14 故障结果呈现

Fig. 14 Fault result presentation

4 结论

本文把离散 Hopfield 神经网络模型应用于电网故障诊断算法前端的数据清洗，通过离散 Hopfield 神经网络训练及计算特性分析和仿真分析得出以下结论：

1) 建立了由遥信二进制到多维故障诊断空间的编码映射方式，并通过标准遥信信息和 K-means 聚类的方法求取了最优编码集，作为故障诊断空间的归类类型。

一次设备分别包括了：L2551 线路两侧、1 母线和 L2553 线路单侧。所以以变电站内部采集的遥信数据分别进行诊断。在故障诊断空间内，利用各故障一次设备的最优编码集和 DHNN 模型对故障进行归类，归类结果如表 3 所示。

表 3 故障诊断结果

Table 3 Fault diagnosis result

诊断设备	故障编码	诊断内容	时间/ms
C 变电站、L2551 线路	(20,1073,1200)	L2551 线路、无重合闸、本地保护动作、无故障类型	110
变电站 2、L2551 线路	(20,1073,557)	L2551 线路、无重合闸、本地保护动作、A 相接地	130
C 变电站、2205 断路器	(487,345)	2205 断路器失灵	120
C 变电站、1 母线	(768,987)	1 母线、失灵保护动作、跳各侧开关	240
变电站 4、L2553 线路	(84,65,557)	L2553 线路、无重合闸、超范围动作、A 相接地	360

从表 3 可以看出，通过本文的编码映射，把图中复杂连锁故障过程中产生的大量的遥信变位信息转换成了故障诊断空间的类型编码，在其过程中通过 Hoffield 神经网络模型对各编码进行了清洗，然后把类型编码显示为调度人员能够理解的文字描述，再通过时间顺序进行关联。最后形成了故障过程文字描述的因果链如图 14 所示，通过因果链完整地描述了整个故障过程，实现了只要复杂故障发生立即呈现诊断结果的实时诊断过程。其故障诊断结果和实际系统的故障过程一致。

2) 为了对故障诊断算法的前端数据进行清洗以提高诊断正确率，应对相关故障遥信数据进行分组分别进行清洗，固定记忆模式，把不同的模式修正为记忆模式。

3) 故障过程遥信数据组、保护动作遥信组和跳闸类型数据组的吸引域各不相同，跳闸类型数据组的吸引域只有一个点，只能反映记忆模式，保护动作遥信组吸引域最大，修正范围最大。所以应该按照修正范围对故障遥信数据进行过滤，避免误修正。

4) 无论修正域的大小，没有发生差错的遥信数

据均能够正确反映, 故障过程遥信数据组、保护动作遥信组数能够进行部分的修正。

5) 将原始遥信先通过本文所建立的离散 Hopfield 神经网络模型进行数据清洗, 再应用于本文所提的电网故障诊断方法进行诊断, 可提高诊断的准确度。

基于遥信数据故障编码技术及 DHNN 校正的电网故障诊断方法在电网故障诊断领域具有较好的应用前景。

参考文献

- [1] 黄彦, 黄劼, 陈凌, 等. 基于多数据源校验的电网 EMS 数据质量在线监控方法及其实现[J]. 电力系统保护与控制, 2017, 45(17): 130-135.
HUANG Yan, HUANG Jie, CHEN Ling, et al. Research of EMS data quality control based on multiple data source calibration[J]. Power System Protection and Control, 2017, 45(17): 130-135.
- [2] 王海云, 田莎莎, 张再驰, 等. 基于负荷预测与关联规则修正的不良数据辨识方法[J]. 电力系统保护与控制, 2017, 45(23): 24-33.
WANG Haiyun, TIAN Shasha, ZHANG Zaichi, et al. A new bad data identification method based on load forecasting and the correction of association rule[J]. Power System Protection and Control, 2017, 45(23): 24-33.
- [3] 徐洪伟, 李伟, 叶海明, 等. 基于信息流监测与解析的遥控缺陷诊断技术应用[J]. 电力系统保护与控制, 2017, 45(23): 136-142.
XU Hongwei, LI Wei, YE Haiming, et al. Application of remote control defect diagnosis technology based on information flow monitoring and analysis[J]. Power System Protection and Control, 2017, 45(23): 136-142.
- [4] GOPAKUMAR P, MALLIKAJUNA B, REDDY M J B, et al. Remote monitoring system for real time detection and classification of transmission line faults in a power grid using PMU measurements[J]. Protection and Control of Modern Power Systems, 2018, 3(3): 159-168. DOI: 10.1186/s41601-018-0089-x.
- [5] 张楠, 杨镜非, 周毅. 电力系统故障诊断遥信量遗漏分析[J]. 电气自动化, 2014(3): 94-97.
ZHANG Nan, YANG Jingfei, ZHOU Yi. An analysis of remote data omission in fault diagnosis of power systems[J]. Electric Automation, 2014(3): 94-97.
- [6] 张旭, 魏娟, 赵冬梅, 等. 一种用于电网故障诊断的遥信信息解析方法[J]. 中国电机工程学报, 2014, 34(22): 3824-3833.
ZHANG Xu, WEI Juan, ZHAO Dongmei, et al. Research course and prospects of power grid fault diagnosis[J]. Power System Technology, 2013, 37(10): 2745-2753.
- [7] 陈靖秋. 基于信息融合的电力系统不确定性故障诊断的研究[D]. 成都: 西南交通大学, 2014.
CHEN Jingqiu. Study of fault diagnosis in uncertain power system on information fusion[D]. Chengdu: Southwest Jiaotong University, 2014.
- [8] 邓国新. 地区电网故障诊断系统中对错误信息辨识的研究[D]. 北京: 华北电力大学, 2008.
DENG Guoxin. Research of wrong information identification on the fault diagnosis system for regional power grid[D]. Beijing: North China Electric Power University, 2008.
- [9] 杨海晶. 基于柔性 SCADA 的电网复杂故障诊断方法的研究[D]. 保定: 华北电力大学, 2009.
YANG Haijing. Research on power system complex fault diagnosis methods based on flexible SCADA[D]. Baoding: North China Electric Power University, 2009.
- [10] 崔智婕. 保护信息逻辑模型及其推理方法的研究[D]. 北京: 华北电力大学, 2011.
CUI Zhijie. Research on protection model based on logic and reasoning methods[D]. Beijing: North China Electric Power University, 2011.
- [11] 张莉. 考虑信息不确定性的电力系统故障诊断方法研究[D]. 北京: 华北电力大学, 2010.
ZHANG Li. The research on power system fault diagnosis method considering the information uncertainty[D]. Beijing: North China Electric Power University, 2009.
- [12] 文福拴, 韩祯祥. 计及警报信息时间特性的故障诊断模型[J]. 电力系统自动化, 1999, 23(17): 6-9.
WEN Fushuan, HAN Zhenxiang. A new fault diagnosis model capable of dealing with the temporal information of alarm messages[J]. Automation of Electric Power Systems, 1999, 23(17): 6-9.
- [13] 张耀天, 何正友, 赵静, 等. 基于粗糙集理论和朴素贝叶斯网络的电网故障诊断方法[J]. 电网技术, 2007, 31(1): 37-43.
ZHANG Yaotian, HE Zhengyou, ZHAO Jing, et al. A power network fault diagnosis method based on rough set theory and naïve Bayesian networks[J]. Power System Technology, 2007, 31(1): 37-43.
- [14] 党德玉, 沈晶. 一种电网调度中心的故障信息识别方法[J]. 电力系统自动化, 2002, 26(18): 54-56.
DANG Deyu, SHEN Jing. An alarm and fault message filtering approach for power dispatching center[J]. Automation of Electric Power Systems, 2002, 26(18): 54-56.
- [15] HOPFIELD J J. Neural networks and physical systems with emergent collective computational abilities[J].

- Proceedings of the National Academy of Sciences, 1982, 79(8): 2554-2558.
- [16] ZHENG P, TANG W, ZHANG J. A simple method for designing efficient small-world neural networks[J]. Neural Networks, 2010, 23(2): 155-159.
- [17] LEE D L. Pattern sequence recognition using a time-varying Hopfield network[J]. IEEE Transactions on Neural Networks, 2002, 13(2): 330-342.
- [18] PAJARES G, GUIJARRO M, RIBEIRO A. A Hopfield neural network for combining classifiers applied to textured images[J]. Neural Networks, 2010, 23(1): 144-153.
- [19] AONISHI T, KOMATSU Y, KURATA K. Self-consistent signal-to-noise analysis of Hopfield model with unit replacement[J]. Neural Networks, 2010, 23(10): 1180-1186.
- [20] HILLAR C, MEHTA R, KOEPEL K. A Hopfield recurrent neural network trained on natural images performs state-of-the-art image compression[C] // 2014 IEEE International Conference on Image Processing (ICIP), October 27-30, 2014, Paris, France: 4092-4096.
- [21] 殷璇, 王生. 基于离散 Hopfield 神经网络的字母识别研究[J]. 计算机与数字工程, 2011, 39(1): 35-38.
YIN Xuan, WANG Sheng. Researches on letter distinguish based on discrete Hopfield neural network[J]. Computer and Digital Engineering, 2011, 39(1): 35-38.
- [22] 金灿. 基于离散 Hopfield 神经网络的数字识别实现[J]. 计算机时代, 2012 (3): 1-3.
JIN Can. On numerical recognition using discrete Hopfield neural network[J]. Computer Era, 2012(3): 1-3.
- [23] 史兴宇, 邓洪敏, 林宇锋, 等. 基于人工神经网络的数字识别[J]. 计算机应用, 2017, 37(增刊 1): 187-189.
SHI Xingyu, DENG Hongmin, LIN Yufeng, et al. Figure identification based on artificial neural network[J]. Journal of Computer Applications, 2017, 37(S1): 187-189.
- [24] 周雪婷. 基于离散 Hopfield 神经网络的车牌字符识别技术研究[D]. 长沙: 湖南师范大学, 2015.
ZHOU Xueting. License plate character based on discrete Hopfield neural networks recognition technology[D]. Changsha: Hunan Normal University, 2015.
- [25] SOMPOLINSKY H. The theory of neural networks: the Hebb rule and beyond[C] // Heidelberg Colloquium on Glassy Dynamics, Springer, 1987, Berlin, Heidelberg, 485-527.
- [26] JIANG Y, HU H, ZHANG Y, et al. Fault section estimation in bulk power grid based on discrete event system[C] // Proceedings of International Conference on Sustainable Power Generation and Supply, September 8-9, 2012, Hangzhou, China: 1-6.

收稿日期: 2018-12-02; 修回日期: 2019-02-27

作者简介:

肖飞(1976—), 男, 博士研究生, 高级工程师, 主要研究方向为电网运行与控制; E-mail: xiaofei@sh.sgcc.com.cn

杨建平(1969—), 男, 高级工程师, 主要研究方向为自动控制; E-mail: yangjp@sh.sgcc.com.cn

邓祥力(1973—), 男, 博士研究生, 副教授, 主要研究方向为电力系统继电保护。E-mail: xiangli_deng@163.com

(编辑 周金梅)