

DOI:10.12158/j.2096-3203.2021.02.024

基于深度置信网络的电网故障类型辨识

杨雯^{1,2}, 尹康涌^{2,3}, 鲍奕宇¹, 尹项根², 徐彪²

(1. 国网江苏省电力有限公司检修分公司, 江苏 南京 211106;

2. 强电磁工程与新技术国家重点实验室(华中科技大学), 湖北 武汉 430074;

3. 国网江苏省电力有限公司电力科学研究院, 江苏 南京 211103)

摘要: 高效可靠的电网故障分类有利于指导调控人员快速排查和消除故障、恢复系统供电, 对保障系统安全可靠运行具有重要意义。为了克服浅层智能方法对信号处理技术和人工经验的依赖以及对复杂电力系统特征提取和表达的不足, 文中基于故障录波信息, 提出一种基于深度置信网络的电网故障类型辨识方法。直接以故障发生后的各相电流/电压以及零序电流/电压作为网络输入, 从原始时域信号中自动学习和提取故障状态特征, 从而实现故障类型的辨识。IEEE 39 节点仿真系统案例和电网实际故障案例均表明该方法具有良好的故障特征提取能力, 在数据降维过程中能保持数据原本的特征, 且辨识结果不受过渡电阻、故障时刻、故障位置、负荷大小等因素的影响, 与传统人工神经网络模型相比其识别准确率更高。

关键词: 电力系统; 深度学习; 故障录波; 深度置信网络; 故障类型辨识

中图分类号: TM741

文献标志码: A

文章编号: 2096-3203(2021)02-0169-09

0 引言

电网发生故障时, 迅速判断故障元件并辨识故障类型是电网调控人员应急处置的关键任务, 有利于快速排查和消除故障、恢复系统供电, 对于保障系统安全可靠运行具有重要意义。

现有电网故障分类方法主要有工频量和暂态量 2 种。工频量分类方法易受接地电阻、系统运行方式的影响; 暂态量分类方法利用行波^[1-2]和故障暂态量^[3-4]等, 能有效摆脱工频因素限制。许多学者将新兴的数据分析方法与暂态量选相方法相结合, 提出了基于模糊理论^[5-6]、分形理论^[7-8]、小波变换^[9-10]、人工神经网络(artificial neural networks, ANN)^[11-12]等的故障类型辨识方法。其中 ANN 等人工智能方法由于其在非线性映射、自学习和自适应、泛化和容错等方面的优势而备受关注。文献[13]利用提升小波和神经网络构造了小波神经网络故障识别模型; 文献[14]提出多小波包系数熵和 ANN 相结合的输电线路故障分类方法。

随着电力大数据的发展, 反映设备状态的数据越来越大, 以 ANN 为代表的浅层学习方法主要存在以下缺陷: (1) 对复杂数据分布的映射能力有限且可能出现“维数灾”; (2) 太依赖于信号处理技术和人工诊断经验, 在故障特征不明显或者出现复杂连

锁故障时容易漏判或误判, 无法满足现代大电网的诊断需求。

深度学习的发展为解决上述问题提供了机遇。作为其典型代表, 深度置信网络(deep belief network, DBN)具有良好的数据特征提取和映射能力^[15-17], 可以通过多隐层网络从原始数据中学习, 特别适用于求解复杂的高维分类问题^[18]。目前已有 DBN 应用于文本表示^[19]、音频分类^[20]、发动机故障诊断^[21]、电力系统暂稳分析^[22-25]等。

文中提出基于 DBN 的电网故障类型辨识方法, 以故障录波信息为数据基础, 直接以故障发生后的各相电流/电压以及零序电流/电压作为网络输入, 从原始时域信号中自动学习和提取故障状态特征, 从而实现故障类型的辨识。针对 DBN 模型数据重构能力、逐层特征提取结果以及实际案例进行对比分析论证, 可知该模型具有良好的故障特征提取能力, 在数据降维过程中能保持数据原本的特征, 与 ANN 模型相比其识别准确率更高, 具有良好的应用前景。

1 DBN

1.1 限制波尔兹曼机及其学习过程

DBN 由多个限制波尔兹曼机(restricted boltzmann machine, RBM)堆叠而成, RBM 的结构及学习过程是 DBN 的重要基础^[15]。

RBM 是一种可通过输入数据集学习概率分布的随机生成神经网络。如图 1 所示, RBM 模型可由

收稿日期: 2020-10-23; 修回日期: 2020-11-17

基金项目: 国家重点研发计划智能电网技术与装备重点专项资助项目(2017YFB0902900)

视层 $\mathbf{v} = \{v_1, v_2, v_3, \dots, v_I\} \in \{0, 1\}$ 和隐含层 $\mathbf{h} = \{h_1, h_2, h_3, \dots, h_J\} \in \{0, 1\}$ 构成, 其中 I 和 J 分别为可视层和隐含层神经元的数目。对应的可视层和隐含层单元的阈值分别为 $\mathbf{a} = \{a_1, a_2, a_3, \dots, a_I\}$ 和 $\mathbf{b} = \{b_1, b_2, b_3, \dots, b_J\}$ 。相同层的神经元相互独立, 不同层的神经元全连接, 可视层神经元 v_i 与隐含层神经元 h_j 间通过权重 w_{ji} 连接。




图1 RBM模型的基本结构

Fig.1 Basic structure of the RBM model

因此, \mathbf{v} 和 \mathbf{h} 给定时, RBM 的能量函数为:

$$E(\mathbf{v}, \mathbf{h}) = - \sum_{i=1}^I a_i v_i - \sum_{j=1}^J b_j h_j - \sum_{j=1}^J \sum_{i=1}^I w_{ji} v_i h_j \quad (1)$$

由此可得到隐含层单元和可视层单元之间的联合概率分布为:

$$p(\mathbf{v}, \mathbf{h}) = \frac{e^{-E(\mathbf{v}, \mathbf{h})}}{\sum_{\mathbf{v}} \sum_{\mathbf{h}} e^{-E(\mathbf{v}, \mathbf{h})}} \quad (2)$$

可由此推导出可视层向量 \mathbf{v} 的独立分布为:

$$p(\mathbf{v}) = \sum_{\mathbf{h}} p(\mathbf{v}, \mathbf{h}) = \frac{\sum_{\mathbf{h}} e^{-E(\mathbf{v}, \mathbf{h})}}{\sum_{\mathbf{v}} \sum_{\mathbf{h}} e^{-E(\mathbf{v}, \mathbf{h})}} \quad (3)$$

RBM 的学习目标是让 RBM 网络表示的分布尽可能地拟合输入数据, 通过调节网络结构参数, 使概率 $p(\mathbf{v})$ 达到最大。用 $\theta = \{a_i, b_j, w_{ji}\}$ 表示网络的结构参数, 对式(3)进行极大似然估计即可求得网络的结构参数。参数求取过程中需采用交替吉布斯采样法从训练样本中进行采样。详细的交替吉布斯采样处理流程及完整的 RBM 学习算法可以参见文献[15]。

1.2 DBN 结构及其训练过程

完整的 DBN 由底层的堆叠 RBM 和顶层的分类器组成, 底层的堆叠 RBM 完成复杂数据的学习和特征提取, 顶层的分类器实现整个模型结构参数的微调和数据分类。图 2 是一个六层的 DBN 基本结构, 由最底层 RBM 的可视层接收输入数据, 依次通过 4 个堆叠 RBM 和 1 个分类器实现数据的特征提取和分类。

传统人工神经网络的训练方法已完全不适用于深度网络结构的学习和训练, Hinton 教授针对深

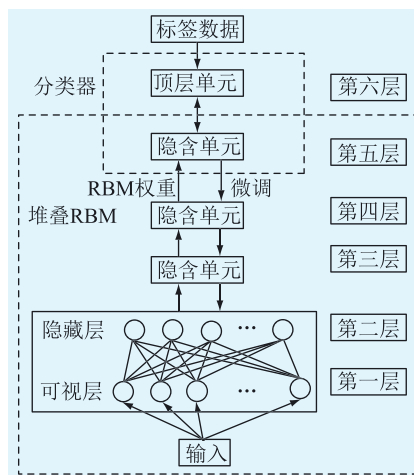


图2 DBN的基本结构

Fig.2 Basic structure of the DBN

度网络的训练难题, 提出将 DBN 的训练划分为 2 个阶段: 无监督的逐层预训练和有监督的微调^[15], 如图 3 所示。

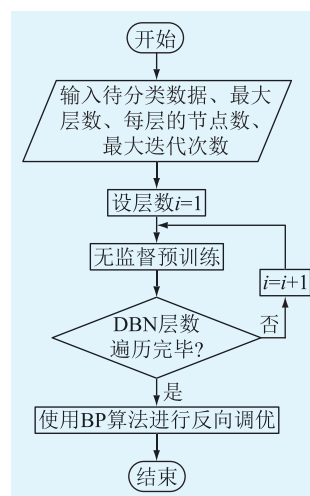


图3 DBN训练流程

Fig.3 Training process of DBN

DBN 的无监督逐层学习过程可理解为多个单独的 RBM 学习过程, 即首先将无标签的数据输入 RBM1 的可视层, 通过 RBM1 的正向映射, 得到隐含层单元 h_1 , 然后利用 h_1 重构可视层单元的状态, 并通过重构数据和原始数据的误差更新 RBM1 的结构参数。RBM1 的学习过程完成后, 把 RBM1 的隐含层单元 h_1 作为 RBM2 的可视层单元, 继续 RBM2 的学习过程。通过 RBM 的逐层堆叠, 整个网络可以有效地从原始故障数据中逐层提取特征, 快速高效地实现对复杂数据的映射和表达。

完成无监督的预训练过程后, 需要在 DBN 模型的最顶层添加标签数据, 对整个网络的参数进行有监督的微调。该过程一般采用误差反向传播 (back propagation, BP) 算法, 通过自上而下误差传输和积

累过程,实现对整个网络全局误差最小化的搜索,从而对整个网络的参数进行调整。有监督的微调过程使 DBN 网络的特征提取更贴合标签数据的类别属性,可以有效提高 DBN 网络分类的准确率。

2 基于 DBN 的电网故障类型辨识

2.1 故障类型编码

考虑电网的 10 种典型故障:单相接地故障 (AG、BG、CG),两相短路故障 (AB、BC、AC),两相短路接地故障 (ABG、BCG、ACG) 以及三相故障 (ABC),依次对其进行编码,如表 1 所示。

表 1 故障类型编码
Table 1 Coding for power grid fault types

故障类型	编码
AG	(1,0,0,0,0,0,0,0,0,0)
BG	(0,1,0,0,0,0,0,0,0,0)
CG	(0,0,1,0,0,0,0,0,0,0)
AB	(0,0,0,1,0,0,0,0,0,0)
BC	(0,0,0,0,1,0,0,0,0,0)
AC	(0,0,0,0,0,1,0,0,0,0)
ABG	(0,0,0,0,0,0,1,0,0,0)
BCG	(0,0,0,0,0,0,0,1,0,0)
ACG	(0,0,0,0,0,0,0,0,1,0)
ABC	(0,0,0,0,0,0,0,0,0,1)

2.2 故障样本形成

以图 4 所示 IEEE 39 节点系统为例,在 PSCAD 环境下搭建仿真模型并获取故障样本。图 4 中元件备注如下: B 为母线; L 为线路; L1817 为母线 B18 与母线 B17 之间的线路,依此类推。

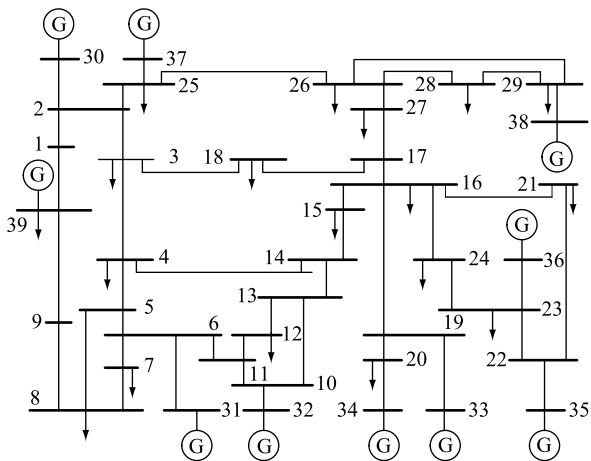


图 4 IEEE 39 节点系统

Fig.4 IEEE 39-bus system

为尽可能地丰富故障样本集,文中还考虑不同过渡电阻、不同负荷水平、不同故障初相角、不同故障位置等多种因素的影响。为此,在对线路 L1817

进行故障设置获取测试样本集时,除了 10 种故障类型,还考虑了以下设置:(1) 接地过渡电阻分别取 $0 \Omega, 20 \Omega, 100 \Omega, 300 \Omega$; (2) 相间过渡电阻分别取 $0 \Omega, 2 \Omega, 10 \Omega$; (3) 线路 L1817 全长 100 km,故障分别设置在距母线 B18 端 5 km, 35 km, 65 km, 95 km 处; (4) 母线 B18 上的负荷分别取 30%, 80%, 100%, 120% 的额定负荷; (5) 故障初相角以 A 相电压为参考,自 $0^\circ \sim 360^\circ$ 之间每隔 30° 取一值,共 12 组。

综合不同故障类型、过渡电阻、负荷情况、故障位置、故障初相角等因素的组合,共获得 11 520 个典型样本。

实际电力系统中故障录波器记录的信息主要包括线路两端 ABC 三相电流和三相电压,以及零序电流和零序电压的采样值。传统浅层学习方法须先从中提取时域、频域、小波域等故障特征,再利用分类器进行故障分类。为了克服浅层学习方法对信号处理技术和人工诊断经验的依赖,文中方法不经过其他特征提取,直接取故障后一周波内各相电流/电压以及零序电流/电压采样值作为 DBN 模型的特征量输入。为避免电流量和电压量不同量纲和数量级别的影响,对电流采样值和电压采样值分别进行线性归一化处理。

仿真测试模型的采样频率设为 3 000 Hz,系统频率是 60 Hz,因此每周波的采样点为 50,每个样本 800 个点,共形成 11 520 个 800 维的高维样本空间。

2.3 模型参数设置

由于输入样本的维数决定输入层的节点数,故障类别数决定输出层的节点数,因此 DBN 模型输入节点数设为 800,输出节点数设为 10。

RBM 可视层和隐藏层的节点数目不仅影响着 DBN 模型的训练时间和计算效率,也影响着模型分类的准确率。节点数过低时,无法提取有效特征;节点数过高时,模型的计算量又将大大增加^[13]。为了使 DBN 模型在对故障样本数据进行特征提取和表达的同时,有效降低数据维数和模型计算量,文中 DBN 模型采用六层结构,并将模型中 4 个隐含层的节点数分别设置为 400, 200, 100, 50。经过逐层压缩,最终形成 50 维特征向量进行分类。

以正态随机分布初始化 DBN 模型的权重 w 并进行归一化处理,阈值 a, b 初始化为 0。

逐层预训练阶段,将学习率和学习动量分别设为 0.1 和 0.5,预训练过程中最大迭代次数设为 150 次。反向微调阶段使用 BP 算法,最大迭代次数设为 100 次。

2.4 基于 DBN 的故障类型辨识流程

文中随机选取每个故障类型样本的 70% 作为训练集,对 DBN 模型参数进行训练,剩余的 30% 作为测试集对 DBN 模型的性能进行分析和测试。基于 DBN 的故障类型辨识流程如图 5 所示,步骤如下:(1) 采集原始故障数据样本,进行归一化处理按 7:3 分为训练集和测试集;(2) 建立多隐层的 DBN 模型,并初始化网络模型参数;(3) 利用训练集中的无标签样本,对 DBN 模型底部的堆叠 RBM 进行逐层预训练;(4) 在 DBN 模型顶层添加 Softmax 分类器,对故障类型状态进行编码,确定输出层节点数;(5) 利用有标签的样本,使用 BP 算法对预训练后的 DBN 模型的整个网络参数进行有监督微调,使网络性能趋近全局最优;(6) 保存训练好的 DBN 模型,并利用测试集中的数据样本对其性能进行测试,输出故障类型辨识结果。

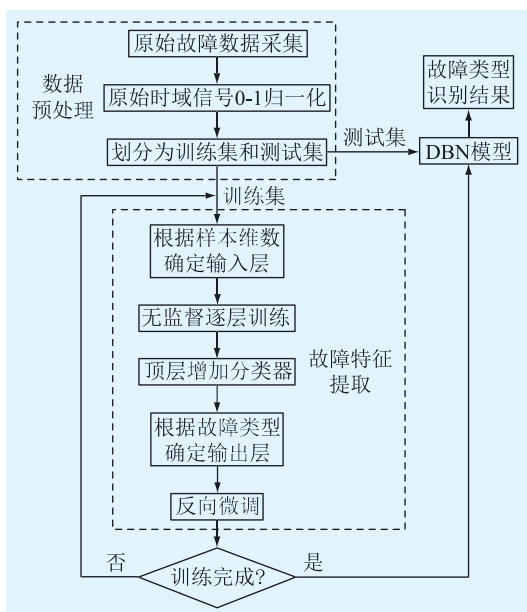


图 5 基于深度置信网络的故障类型辨识方法
Fig.5 Fault type identification based on DBN

3 DBN 模型故障特征提取能力分析

3.1 DBN 网络的数据重构能力

DBN 模型顶层分类器仅承担分类和识别的功能,其强大的特征提取能力主要取决于底层堆叠 RBM 的学习过程。如果将模型中 DBN 正向无监督学习过程看作由堆叠 RBM 进行逐层编码的过程,则反向逐层解码的过程可以看作是对 DBN 模型的输入数据进行重构的过程。因此通过比较原始输入数据与重构数据的差异,就可以有效分析 DBN 模型对数据的映射和表达能力。

在 DBN 中,激活函数 $\text{sig}(x) = 1/(1 + e^{-x})$ 通常


用来描述隐含层和可视层单元的激活概率。假设网络的输入数据为 x ,则可将 DBN 网络的编码函数定义为:

$$f(x) = \text{sig}(b + wx) \quad (4)$$


相应的解码函数为:

$$g(x) = \text{sig}(a + w^T x) \quad (5)$$

分别将样本数据输入到无监督学习后以及反向微调后的 DBN 网络中,将获得的重构数据与原始输入数据进行对比,如图 6 所示。



(a) 无监督学习后的 DBN 网络结果



(b) 反向微调后的 DBN 网络结果

图 6 输入曲线与重构曲线的对比

Fig.6 Comparison between the input curve and the reconstruction curve

对比图 6(a) 和 (b) 可知,未微调的 DBN 网络重构结果与原始数据存在较大偏差,而微调后,重构曲线基本与原始曲线重合,说明 DBN 模型训练的反向微调过程可以降低重构曲线与原始曲线的误差,更有利于网络的特征提取和表达。

从图 6(b) 可以看出,经过微调的 DBN 网络可以较好地重构原始输入曲线,原始输入数据经过堆叠 RBM 逐层的特征提取,虽然数据维度有所降低,但依然能够作为原始曲线的特征表达,在一定程度上说明 DBN 网络具有良好的特征提取能力和保持数据特征的能力。

用 x_i^j 表示原始输入数据; y_i^j 表示重构数据; $j = 1, 2, \dots, m; i = 1, 2, \dots, n$ 。其中 n 为数据样本的数

目, m 为数据的维数。

均方根误差 (root mean square error, RMSE) 表示重构数据与原始输入数据差值的平方根, 可用 E_{RMSE} 表示, 计算如下:

$$E_{\text{RMSE}} = \sqrt{\frac{\sum_{i=1}^n \sum_{j=1}^m (x_i^j - y_i^j)^2}{mn}} \quad (6)$$

失真度 (data distortion, DD) 表示重构数据与原始输入数据的差异大小, 文中采用相对均方差值来定义失真度, 可用 E_{DD} 表示, 计算如下:

$$E_{\text{DD}} = \left[\sum_{i=1}^n \sum_{j=1}^m (x_i^j - y_i^j)^2 \right] / \left[mn \sqrt{\sum_{i=1}^n \sum_{j=1}^m (x_i^j)^2} \right] \quad (7)$$

表 2 为输入数据和重构数据差异的定量评估结果, 经过 BP 算法微调后的 DBN 网络均方根误差和失真度均比未微调的重构网络小, 进一步说明了 DBN 模型训练中微调过程的必要性。

表 2 差异评估指标差异评估指标
Table 2 Difference assessment indexes

DBN 网络	E_{RMSE}	E_{DD}
未微调时	0.180 5	0.006 155
微调后	0.047 4	0.000 072

3.2 DBN 模型的逐层特征提取结果

由于原始故障数据和 DBN 模型逐层提取的故障特征维数都比较高, 不利于直接进行观察和对比, 因此文中采用主成分分析法从高维故障特征中提取前 3 个主成分 (分别为 PC1, PC2, PC3), 并在三维坐标轴中显示出来。利用 DBN 模型从原始输入数据中逐层提取故障特征的可视化结果, 如图 7 所示。

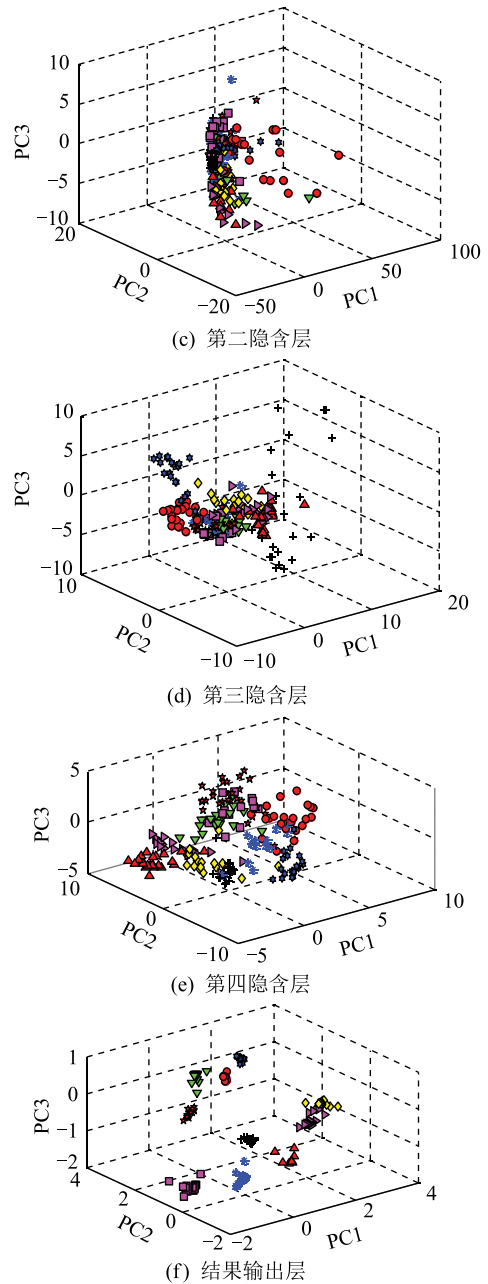
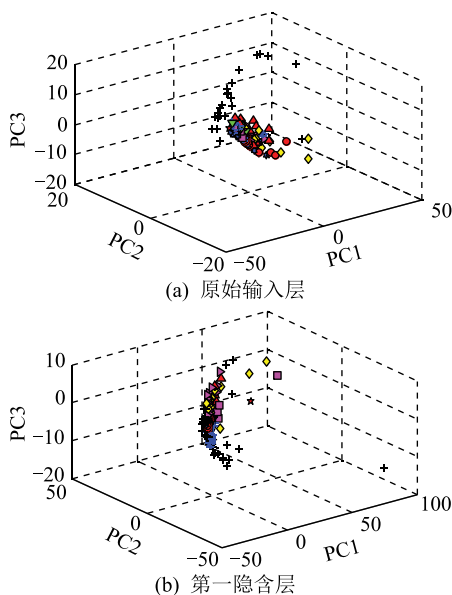


图 7 DBN 模型的逐层特征提取结果

Fig.7 Layer-by-layer feature extraction results of DBN

图 7 中, 输入层中 10 种故障类型的数据信号裹挟在一起, 无法进行区分和鉴别。经过堆叠 RBM 对输入数据逐层学习和提取之后, 同一故障类型的特征逐渐靠拢和聚集, 不同故障类型的特征向外发散, 并渐渐分离开, 通过 DBN 模型输出层的分类器后, 10 种故障类型的状态特征已被完全区分开。可以看出, 基于 DBN 的故障类型辨识方法摆脱了对信号处理技术和人工诊断经验的依赖, 无需繁杂的故障特征提取过程, 却能够自适应地从原始故障数据中逐层地进行学习, 并有效地提取故障特征, 且随着模型结构的加深, 故障特征的区别性越来越突出。

4 DBN 模型故障类型辨识结果分析

4.1 仿真案例辨识结果

为了评价文中方法对故障测试集的辨识效果,首先介绍故障类型辨识的评价标准。表 3 为经典的二维故障分类矩阵 H_2 。

表 3 二维故障分类矩阵

Table 3 Two-dimensional fault classification matrix

结果	正常数据	故障数据
检测正常	N_{TP}	N_{FP}
检测故障	N_{FN}	N_{TN}

在故障分类矩阵的基础上,用单一识别准确率 (single accuracy rate, SAR) 表征在某一故障类型下的所有样本中,被正确识别的样本数所占的比例,可用 A_{SAR} 表示,计算如下:

$$A_{SAR} = \frac{N_{TP}}{N_{TP} + N_{FN}} \times 100\% \quad (8)$$

总体准确率 (overall accuracy rate, ACR) 表征在所有样本中故障分类正确的样本数目所占的比例,可用 A_{ACR} 表示,计算如下:

$$A_{ACR} = \frac{N_{TP} + N_{TN}}{N_{TP} + N_{TN} + N_{FP} + N_{FN}} \times 100\% \quad (9)$$

将上述故障分类矩阵扩展到 10 种故障类型,并使用训练后的 DBN 模型对故障仿真测试集进行测试,得到输电线路的故障分类矩阵为:

$$H_{10} = \begin{bmatrix} AG & BG & CG & AB & BC & AC & ABG & BCG & ACG & ABC \\ AG & 224 & 0 & 0 & 1 & 0 & 2 & 3 & 0 & 2 & 0 \\ BG & 0 & 225 & 0 & 0 & 2 & 0 & 3 & 3 & 1 & 0 \\ CG & 0 & 0 & 224 & 0 & 1 & 2 & 0 & 2 & 2 & 0 \\ AB & 3 & 0 & 0 & 168 & 0 & 0 & 3 & 0 & 1 & 1 \\ BC & 0 & 1 & 1 & 0 & 167 & 0 & 1 & 3 & 1 & 0 \\ AC & 0 & 0 & 1 & 1 & 0 & 167 & 0 & 0 & 3 & 2 \\ ABG & 2 & 2 & 0 & 2 & 0 & 0 & 675 & 2 & 1 & 1 \\ BCG & 0 & 2 & 2 & 0 & 2 & 0 & 1 & 677 & 1 & 2 \\ ACG & 0 & 0 & 2 & 0 & 1 & 2 & 2 & 2 & 676 & 1 \\ ABC & 1 & 0 & 0 & 1 & 0 & 0 & 2 & 1 & 2 & 166 \end{bmatrix}$$

对其结果进行评估,各指标计算结果如表 4 所示。可以看出,不管是总体准确率 A_{ACR} 还是单一故障类型的识别率 A_{SAR} 均达到 95% 以上。故障样本集考虑了不同故障位置、故障初相角、过渡电阻以及系统带不同负荷等多种因素,说明 DBN 模型能够有效地从各种复杂工况中提取故障特征并进行分类识别,具有良好的适应性。

4.2 实际案例辨识结果

以图 8 所示的某区域电网实际故障为案例进一步说明 DBN 模型的可行性和有效性。

表 4 仿真案例辨识结果

Table 4 Identification results of simulation case %

类型	A_{SAR}	类型	A_{SAR}
AG	97.39	AC	96.53
BG	97.83	ABG	97.83
CG	97.39	BCG	98.12
AB	97.10	ACG	97.97
BC	96.53	ABC	95.95

注:对于所有故障类型, A_{ACR} 计算结果均为 97.60%。

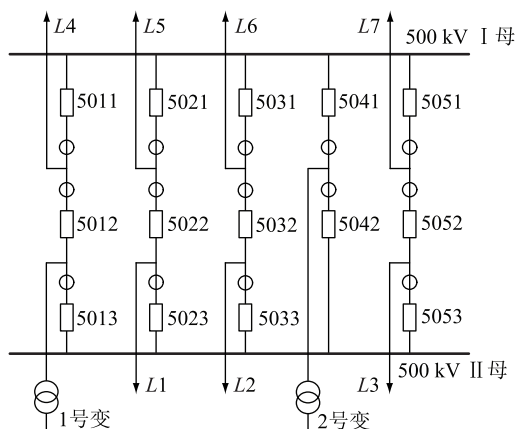


图 8 某区域电网的部分接线

Fig.8 Schematic network of a regional power grid

分别构建网络中输电线路的 DBN 模型,由于实际电网的故障样本较少,此次训练样本来自该系统的 PSASP 故障仿真数据,测试样本来自故障信息系统中 5 次短路故障的故障录波实际数据,DBN 模型的辨识结果如表 5 所示。

表 5 实际案例辨识结果

Table 5 Identification results of real fault cases

序号	案例时间	线路	实际故障类型	DBN 测试结果
1	2015-03-08	L1	CG	CG
2	2015-12-19	L6	BG	BG
3	2016-09-28	L4	AG	AG
4	2017-11-03	L7	BC	BC
5	2018-04-16	L4	AG	AG

可以看出,文中方法能够准确识别实际电网中输电线路的故障。虽然仿真所得故障样本与实际系统之间存在一定的差异,但仿真样本考虑了不同过渡电阻、负荷大小、故障时刻、故障位置等的影响,而经过训练的 DBN 模型依然能够对实际电网中的故障类型进行准确辨识,进一步证明了 DBN 模型强大的学习能力与泛化能力。

4.3 与 ANN 模型的对比分析

为了进行对比分析,文中构建了 2 组 ANN 模型对故障仿真样本进行学习和测试。ANN1 采用与 DBN 一致的 800-400-200-100-50-10 六层结构,而

ANN2 则采用 800-400-10 的单隐层结构,2 个 ANN 的训练方式均采用 BP 算法,与 DBN 的有监督微调过程一样,最大迭代次数设为 100 次。3 种模型均在配置 2.3 GHz 双核处理器,2 G 内存的计算机上利用 Matlab 编程实现,为了避免算法偶然性和随机性的影响,取 10 次结果中 A_{ACR} 指标的平均值作比较。模型的识别结果及性能对比如表 6 所示。

表 6 不同方法的结果对比

Table 6 Comparison of results from different method

方法	$A_{ACR}/\%$	平均训练时间/s	样本平均分类时间/s
DBN	97.60	204.768	0.021
ANN1	88.96	178.532	0.020
ANN2	92.00	88.524	0.017

从识别准确率来看,DBN 模型比 ANN1 模型高。根据实验设置,DBN 模型与 ANN1 模型采用相同的网络深度和网络结构,有监督的训练过程也相同,而两者的辨识结果和辨识性能却展现出很大的差别,说明 DBN 模型的逐层预训练过程有效优化了模型的网络参数,能够为有监督的微调过程提供一个较好的初值。而 ANN1 模型的参数却采用随机初始化的方法,并在初始化之后直接采用 BP 算法进行训练,模型很容易收敛到局部最小值,因而识别准确率较低。

此外,DBN 模型与 ANN2 模型相比识别准确率也更高,这说明浅层的 ANN2 模型难以从复杂数据特征中有效提取高层次特征,而 DBN 模型的深层结构能够从原始输入数据中逐层提取故障特征,将原始的 800 维特征逐层抽象成 50 维特征,再利用 softmax 分类器进行分类,可以克服浅层神经网络对复杂数据学习和映射能力的不足,获得比浅层结构更好的识别和分类效果。

从 ANN1 和 ANN2 的比较结果可以看出,单纯增加模型层数,利用传统的模型训练方法并不能有效提高故障类型辨识的准确性。这也进一步反映了 DBN 模型及其训练方法在分类特征提取方面的优越性。

从模型性能来看,DBN 模型由于增加了逐层预训练的学习过程,其平均训练时间与具有同样结构的 ANN1 模型相比较长,但两者对样本的平均分类时间差别不大。而 ANN2 模型与 ANN1 相比层数少,因此其模型训练及分类时间相对而言最短。然而,由于 DBN 模型训练过程是离线完成的,保存模型参数后应用于故障类型识别,因此不会对模型在线应用的时效性产生影响。

综合识别准确率和模型性能来看,在保障识别

准确率的情况下,DBN 模型的性能最好,平均仅需 0.021 s 即可实现故障类型的判别,能够满足在线故障诊断的要求。

5 结语

文中将深度学习应用于电网故障诊断中,提出了基于 DBN 的电网故障类型辨识方法,以故障录波信息的各相电流/电压及零序电流/电压作为原始输入,从故障类型编码、样本数据获取、模型参数设置、网络学习等各方面给出了电网故障类型辨识的完整流程,最后通过 DBN 网络的数据重构能力、逐层特征提取可视化结果以及故障类型辨识结果分析模型的性能。IEEE 39 节点仿真系统算例和电网实际故障案例表明基于 DBN 的电网故障类型辨识方法具有良好的故障特征提取能力,在数据降维过程中能保持数据原本的特征,且辨识结果不受过渡电阻、故障时刻、故障位置、负荷大小等因素的影响,与传统 ANN 模型相比识别准确率更高。

下一步的主要工作是研究网络层数、隐含层节点数量、学习率、学习动量等对网络训练速度、回归效果、识别效果的影响,就如何确定 DBN 网络结构及参数给出经验,并将文中提出的故障类型辨识方案集成到现有电网故障诊断系统中,为在线调度提供辅助决策支持。

参考文献:

- [1] 薛士敏,崔淼. 基于形态学梯度算法的微电网行波保护方案[J]. 电力系统保护与控制,2019,47(2):31-39.
XUE Shimin, CUI Miao. Current traveling wave based protection scheme for microgrids using morphological gradient algorithm[J]. Power System Protection and Control, 2019, 47(2): 31-39.
- [2] 郑玉平,司鑫尧,吴通华,等. 特高压半波长交流输电线路的行波保护[J]. 电力系统自动化,2020,44(18):124-131.
ZHENG Yuping, SI Xinyao, WU Tonghua, et al. Travelling wave protection of UHV half-wavelength AC transmission lines[J]. Automation of Electric Power Systems, 2020, 44(18): 124-131.
- [3] 付华,刘公权,邢亮. 基于同步挤压小波变换的故障行波测距方法[J]. 电力系统保护与控制,2020,48(2):18-24.
FU Hua, LIU Gongquan, XING Liang. Fault traveling wave ranging method based on synchrosqueezing wavelet transform[J]. Power System Protection and Control, 2020, 48(2): 18-24.
- [4] 段建东,张保会,张胜祥. 利用线路暂态行波功率方向的分布式母线保护[J]. 中国电机工程学报,2004,24(6):7-12.
DUAN Jiandong, ZHANG Baohui, ZHANG Shengxiang. A distributed bus protection using transient traveling wave power directions of transmission lines[J]. Proceedings of the CSEE, 2004, 24(6): 7-12.
- [5] 闻旭,李春明. 基于模糊逻辑的可控串补线路故障分类[J].

- 电力系统保护与控制,2016,44(5):122-127.
- YAN Xu,LI Chunming. Fuzzy-logic-based fault classification in a series compensated transmission line[J]. Power System Protection and Control,2016,44(5):122-127.
- [6] 童晓阳,罗忠运. 基于模糊支持向量机的输电线路故障模糊分类方法及其降维显示[J]. 高电压技术,2015,41(7):2276-2282.
- TONG Xiaoyang,LUO Zhongyun. Transmission line faults classification method based on fuzzy support vector machine and reducing-dimension display[J]. High Voltage Engineering,2015,41(7):2276-2282.
- [7] 房亚因,杨柳,龚仁敏,等. 一种基于网格分形理论的电力系统故障选相方法[J]. 浙江电力,2018,37(8):28-34.
- FANG Yanan,YANG Liu,GONG Renmin, et al. A fault phase selection method for power system based on mesh fractal theory[J]. Zhejiang Electric Power,2018,37(8):28-34.
- [8] 杨丹,刘沛,王冬青,等. 基于分形理论的输电线路故障检测和选相[J]. 电力系统自动化,2005,29(15):35-39,88.
- YANG Dan,LIU Pei,WANG Dongqing, et al. Detection of faults and phase-selection using fractal techniques[J]. Automation of Electric Power Systems,2005,29(15):35-39,88.
- [9] 肖文龙,王维博,刘勇,等. 基于小波分析理论的特高压输电线路故障选相研究[J]. 电力系统保护与控制,2016,44(17):90-96.
- XIAO Wenlong,WANG Weibo,LIU Yong, et al. Research of fault phase selection on UHV transmission lines based on wavelet analysis[J]. Power System Protection and Control,2016,44(17):90-96.
- [10] 黄建明,李晓明,瞿合祚,等. 考虑小波奇异信息与不平衡数据集的输电线路故障识别方法[J]. 中国电机工程学报,2017,37(11):3099-3107,3365.
- HUANG Jianming,LI Xiaoming,QU Hezuo, et al. Method for fault type identification of transmission line considering wavelet singular information and unbalanced dataset[J]. Proceedings of the CSEE,2017,37(11):3099-3107,3365.
- [11] 李达,薛卿,孔德健,等. 基于 PSO-BP 算法的高压输电线路故障分类[J]. 电气自动化,2018,40(6):42-44.
- LI Da,XUE Qing,KONG Dejian, et al. Fault classification of high voltage transmission line based on PSO-BP algorithm[J]. Electrical Automation,2018,40(6):42-44.
- [12] 魏东,龚庆武,来文青,等. 基于卷积神经网络的输电线路区内外故障判断及故障选相方法研究[J]. 中国电机工程学报,2016,36(S1):21-28.
- WEI Dong,GONG Qingwu,LAI Wenqing, et al. Research on internal and external fault diagnosis and fault-selection of transmission line based on convolutional neural network[J]. Proceedings of the CSEE,2016,36(S1):21-28.
- [13] 杨光亮,乐全明,郁惟镛,等. 基于小波神经网络和故障录波数据的电网故障类型识别[J]. 中国电机工程学报,2006,26(10):99-103.
- YANG Guangliang,YUE Quanming,YU Weiyong, et al. A fault classification method based on wavelet neural networks and fault record data[J]. Proceedings of the CSEE,2006,26(10):99-103.
- [14] 李东敏,刘志刚,蔡军,等. 基于多小波包系数熵和人工神经网络的输电线路故障类型识别方法[J]. 电网技术,2008,32(24):65-69.
- LI Dongmin,LIU Zhigang,CAI Jun, et al. Transmission lines fault recognition method based on multi-wavelet packet coefficient entropy and artificial neural network[J]. Power System Technology,2008,32(24):65-69.
- [15] HINTON G E,OSINDERO S,TEH Y W. A fast learning algorithm for deep belief nets[J]. Neural Computation,2006,18(7):1527-1554.
- [16] 李宁,费守江,刘国亮,等. 基于深度信念网络的计量装置故障溯源研究[J]. 智慧电力,2020,48(7):118-124.
- LI Ning,FEI Shoujiang,LIU Guoliang, et al. Fault traceability of metering device based on deep belief network[J]. Smart Power,2020,48(7):118-124.
- [17] 魏艳霞,许锐琦,殷豪. 基于深度信念网络的配变台区跳闸预测[J]. 智慧电力,2020,48(6):119-124.
- WEI Yanxia,XU Ruiqi,YIN Hao. Trip prediction of distribution transformer station based on deep belief network[J]. Smart Power,2020,48(6):119-124.
- [18] HUANG G B,LEE H,LEARNED-MILLER E. Learning hierarchical representations for face verification with convolutional deep belief networks[C]//2012 IEEE Conference on Computer Vision and Pattern Recognition. Providence, RI, USA. IEEE,2012:2518-2525.
- [19] HINTON G,SALAKHUTDINOV R. Discovering binary codes for documents by learning deep generative models[J]. Topics in Cognitive Science,2011,3(1):74-91.
- [20] HINTON G,DENG L,YU D, et al. Deep neural networks for acoustic modeling in speech recognition;the shared views of four research groups[J]. IEEE Signal Processing Magazine,2012,29(6):82-97.
- [21] LINX S,LI B W,YANG X Y. Engine components fault diagnosis using an improved method of deep belief networks[C]//2016 7th International Conference on Mechanical and Aerospace Engineering (ICMAE). London, UK. IEEE,2016:454-459.
- [22] 胡伟,郑乐,闵勇,等. 基于深度学习的电力系统故障后暂态稳定评估研究[J]. 电网技术,2017,41(10):3140-3146.
- HU Wei,ZHENG Le,MIN Yong, et al. Research on power system transient stability assessment based on deep learning of big data technique[J]. Power System Technology,2017,41(10):3140-3146.
- [23] 朱乔木,党杰,陈金富,等. 基于深度置信网络的电力系统暂态稳定评估方法[J]. 中国电机工程学报,2018,38(3):735-743.
- ZHU Qiaomu,DANG Jie,CHEN Jinfu, et al. A method for power system transient stability assessment based on deep belief networks[J]. Proceedings of the CSEE,2018,38(3):735-743.

- [24] 刘俊,孙惠文,吴柳,等. 电力系统暂态稳定性评估综述[J]. 智慧电力,2019,47(12):44-53,122.

LIU Jun, SUN Huiwen, WU Liu, et al. Overview of transient stability assessment of power systems[J]. Smart Power, 2019, 47(12):44-53,122.

- [25] 蔡国伟,张启蒙,杨德友,等. 基于改进深度置信网络的电力系统暂态稳定评估研究[J]. 智慧电力,2020,48(3):61-68.

CAI Guowei, ZHANG Qimeng, YANG Deyou, et al. Research on power system transient stability assessment based on improved deep belief network[J]. Smart Power, 2020, 48(3):

61-68.

作者简介:



杨雯

杨雯(1993),女,硕士,工程师,从事电力系统变电运维及继电保护相关工作(E-mail:409708265@qq.com);

尹康涌(1992),男,硕士,工程师,从事电力系统安全技术,电力系统变电运维及继电保护相关工作;

鲍奕宇(1992),男,学士,助理工程师,从事电力系统故障诊断相关工作。

Fault types identification of power grid based on deep belief network

YANG Wen^{1,2}, YIN Kangyong^{2,3}, BAO Yiyu¹, YIN Xianggen², XU Biao²

(1. State Grid Jiangsu Electric Power Co., Ltd. Maintenance Branch, Nanjing 211106, China; 2. State Key Laboratory of Advanced Electromagnetic Engineering and Technology (Huazhong University of Science and Technology), Wuhan 430074, China; 3. State Grid Jiangsu Electric Power Co., Ltd. Research Institute, Nanjing 211106, China)

Abstract: Efficient and reliable fault classification is beneficial to guide the dispatchers in finding and removing the fault quickly, thus restoring system power supply promptly, so the classification is of great significance for ensuring the safe and reliable operation of the system. A fault classification method based on deep belief network is proposed to overcome deficiencies of traditional fault classification, such as shallow intelligent methods' dependence on signal processing technology and artificial experience, and the lack of feature extraction and expression for complex power system. The raw data of each phase current-voltage and zero sequence current-voltage are taken as the network input, and the features of fault state are automatically learned and extracted from the original time-domain signals to realize the fault type identification. The simulation results of the IEEE 39-bus system and real fault cases of power grid show that the proposed fault type identification method has good capability of fault feature extraction. Besides, the proposed method keeps the original characteristics of data in the process of dimensionality reduction, and it is not affected by factors including transition resistance, fault time, fault location and load size. Therefore, it identifies fault types more accurately than other traditional artificial neural networks do.

Keywords: power system; deep learning; fault recorder information; deep belief network; fault types identification

(编辑 方晶)