

## 基于 DBN-HD 的车载设备故障诊断\*

魏 伟<sup>1</sup>, 赵小强<sup>2,3</sup>, 范亮亮<sup>4</sup>

(1. 兰州交通大学新能源与动力工程学院 兰州, 730070)

(2. 兰州理工大学电气工程与信息工程学院 兰州, 730050)

(3. 兰州理工大学国家级电气与控制工程实验教学中心 兰州, 730050)

(4. 中国铁路兰州局集团有限公司兰州电务段 兰州, 730050)

**摘要** 针对列车超速防护(automatic train protection,简称 ATP)系统车载设备故障诊断主要依靠人工经验以及效率低的问题,提出了深度置信网络-汉明距离(deep belief network-Hamming distance,简称 DBN-HD)车载故障诊断模型。首先,利用 DBN 无监督地提取车载故障数据的抽象特征,获得原始数据的低维表示形式,将其输入附加在顶层的分类器输出诊断结果;其次,比较实际输出与期望输出之间的 HD,将 HD 作为误差采用反向传播(back propagation,简称 BP)算法自顶向下地微调 DBN 权值,完成模型训练;最后,利用某局集团公司电务段车载故障数据分析和验证模型参数对模型性能的影响。研究表明,与支持向量机(support vector machine,简称 SVM)、反向传播神经网络(back propagation neural network,简称 BPNN)和 DBN 进行对比,本研究提出的 DBN-HD 模型具有更高的正确率和运行效率,适用于实际车载设备故障诊断。

**关键词** 车载设备;故障诊断;深度置信网络;汉明距离

**中图分类号** TH17;TP183;U284.4

### 引 言

随着铁路行业的高速发展,高速铁路运行的安全性备受社会关注,ATP 车载设备作为列车运行控制系统的重要组成部分,控制列车运行的速度、距离等要素,一旦发生故障将会严重影响列车的行车安全及运行效率<sup>[1-2]</sup>。为满足现代化高速铁路的发展需求,建立精确有效的车载故障诊断系统具有重要的意义。

近年来,对 ATP 车载设备建模诊断主要包括贝叶斯网络、文本挖掘和神经网络等方法。梁潇等<sup>[3]</sup>收集现场历史故障数据,融合粗糙集理论优化了贝叶斯网络结构,实现故障识别。贝叶斯网络多依赖先验知识,以分布独立假设为前提,当数据属性之间相关度较高时,预测效果不佳。赵阳等<sup>[4]</sup>利用概率隐语义分析(probabilistic latent semantic analysis,简称 pLSA)提取车载安全计算机文本数据特征,用贝叶斯网络完成故障诊断。Wang 等<sup>[5]</sup>依据车载设备的维护数据,结合隐狄利克雷分配(latent Dirichlet allocation,简称 LDA)和卡方统计,提出一种融合语义特征的 2 级故障特征提取方法,采用 SVM 分类器

和分级策略定位车载设备故障。pLSA 和 LDA 属于无监督模型,主题数目不易确定且主题生成具有随机性,这些都会影响故障诊断的精度。牛宏侠等<sup>[6]</sup>将故障诊断转换为模式识别的数学问题,利用粗糙集和改进布谷鸟算法优化 BP 神经网络,完成车载应答器传输模块(balise transmission module,简称 BTM)设备的故障识别。张彩凤等<sup>[7]</sup>建立基于 BP 的多故障诊断模型,通过动态调整粒子群的参数来优化 BP 网络,提高故障识别精度。BP 神经网络在处理复杂的非线性问题时,容易陷入局部最小值,从而导致网络训练失败。另外,随着网络层数的加深,BP 神经网络的收敛速度变慢,影响故障诊断的效率。

DBN 是由 Hinton 等<sup>[8]</sup>提出的深度学习网络,其以随机神经网络为基础,由多层受限玻尔兹曼机(restricted boltzmann machine,简称 RBM)堆叠而成,通过逐层特征提取,将非线性的高维数据形成更适合模式分类的抽象特征,克服了 BPNN 和 Hopfield 网络容易陷入局部最小值的问题,常被用于语音识别、网络入侵检测等任务<sup>[9-10]</sup>。目前,DBN 在故

\* 国家自然科学基金资助项目(62263021);甘肃省科技计划资助项目(22JR11RA141)

收稿日期:2020-08-18;修回日期:2021-01-11

障诊断中多用于滚动轴承、电力变压器等领域<sup>[11-13]</sup>。

笔者将DBN引入车载故障诊断,结合汉明距离提出DBN-HD故障诊断模型。首先,通过DBN自主学习故障现象的特征信息,发掘故障数据间的隐含特征,完成DBN预训练;其次,利用汉明距离度量实际输入与期望输出之间的误差,采用BP算法微调DBN-HD网络权值,当达到设定迭代次数或误差小于设定阈值时,停止训练;最后,以某局集团公司电务段车载故障数据为数据集进行验证,将本研究模型与SVM,BPNN和DBN模型进行对比分析,实验结果表明了所提模型的有效性。

### 1 DBN模型

图1为DBN网络结构及训练过程。DBN是一个概率生成模型<sup>[8]</sup>,由多层无监督的RBM网络和一层BP网络组成,其训练过程包括预训练和微调2个阶段。

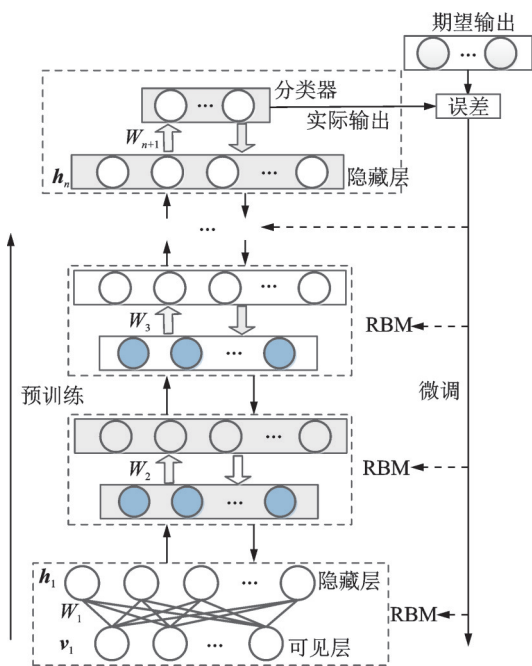


图1 DBN网络结构及训练过程

Fig.1 Structure and training process of DBN net

预训练采用贪婪学习的方式,无监督地训练每一层RBM网络,输入数据作为1层RBM可见层的输入 $v_1$ ,隐藏层输出 $h_1$ 作为2层RBM可见层的输入 $v_2$ ,以此类推得到第 $n$ 层RBM隐藏层输出 $h_n$ 。单层RBM结构如图2所示。

图2中: $n$ 为RBM可见层神经元个数; $m$ 为隐藏层的神经元个数; $W_{ij}$ 为第 $i$ 个可见层和第 $j$ 个隐藏层之间的权值; $v=[v_1, v_2, \dots, v_n]$ 为可见层状态; $h=[h_1, h_2, \dots, h_m]$ 为隐藏层状态。当神经元为二值状态,即 $v \in \{0, 1\}; h \in \{0, 1\}$ 时,RBM能量函数为




图2 RBM结构

Fig.2 Structure of RBM

$[h_1, h_2, \dots, h_m]$ 为隐藏层状态。当神经元为二值状态,即 $v \in \{0, 1\}; h \in \{0, 1\}$ 时,RBM能量函数为

$$E(v, h|\theta_{ij}) = -\sum_{i=1}^n a_i v_i - \sum_{j=1}^m b_j h_j - \sum_{i=1}^n \sum_{j=1}^m v_i w_{ij} h_j \quad (1)$$

其中: $v_i$ 为可见层第 $i$ 个单元的状态; $h_j$ 为隐藏层第 $j$ 个单元的状态; $a, b$ 分别为可见层和隐藏层之间的偏置值。

记RBM参数 $\theta_{ij}=(w_{ij}, a_i, b_j)$ ,可得联合概率分布为

$$P(v, h|\theta_{ij}) = e^{-E(v, h|\theta_{ij})} / \sum_{v, h} e^{-E(v, h|\theta_{ij})} \quad (2)$$

由于RBM层间全连接层内为无连接的特殊结构,层内各神经元激活状态之间条件独立,因此已知可见层神经元状态,第 $j$ 个隐藏层神经元的激活概率为

$$P(h_j = 1|v) = \sigma(b_j + \sum_{i=1}^n v_i w_{ij}) \quad (3)$$

其中: $\sigma()$ 为激活函数。

同理,已知隐藏层神经元状态,第 $i$ 个可见层神经元的激活概率为

$$P(v_i = 1|h) = \sigma(a_i + \sum_{j=1}^m w_{ij} h_j) \quad (4)$$

选取sigmoid函数为激活函数,即

$$\sigma(x) = 1/(1 + e^{-x}) \quad (5)$$

可见,式(5)将输入数据 $v \in [-\infty, +\infty]$ 压缩在 $[0, 1]$ 的范围内,表示各个神经元激活状态的概率。

将式(2)中隐藏层节点 $h$ 所有状态求和,得可见层节点集合的边缘分布概率为

$$P(v|\theta) = \sum_h e^{-E(v, h|\theta)} / \sum_{v, h} e^{-E(v, h|\theta)} \quad (6)$$

式(6)分母 $\sum_{v, h} e^{-E(v, h|\theta)}$ 不易计算,采用极大似然估计方法(maximum likelihood estimate,简称MLE)

最大概率的拟合训练数据,即

$$\theta_{ij}^* = \arg \max_{\theta} \sum_{t=1}^T \log P(v^{(t)}|\theta_{ij}) \quad (7)$$

采用梯度下降法,求解式(7)得参数  $\theta_{ij} = (w_{ij}, a_i, b_j)$  的更新规则为

$$\theta_{ij}^{n+1} = \theta_{ij}^n + \epsilon \left( \langle v_i h_j \rangle_{P_{data}} - \langle v_i h_j \rangle_{P_{model}} \right) \quad (8)$$

其中: $\epsilon$ 为学习效率; $P_{data}$ 为训练数据集的数学期望; $P_{model}$ 为近似训练样本的模型数学期望。

$P_{model}$ 呈指数关系,不易计算。Hinton 提出对比散度(contrastive divergence,简称 CD)算法<sup>[14]</sup>,根据式(3)和式(4)条件概率分布,将式(8)中模型期望的计算转换为重构模型的数学期望,并证明 CD 算法迭代 1 次时就能得到很好的效果。因此,式(8)模型参数的更新法则为

$$\theta_{ij}^{n+1} = \theta_{ij}^n + \epsilon \left( \langle v_i h_j \rangle_{P_{data}} - \langle v_i h_j \rangle_{P_{remodel}} \right) \quad (9)$$

其中: $P_{remodel}$ 为重构模型定义的数学期望。

根据式(9)使用大量无标签的数据来逐层无监督地训练每一层 RBM,从低至高逐层提取高维、深层及主要的特征,确保特征向量在层内映射达到最优,最大化保留特征原始信息。

预训练结束后,整个 DBN 的网络参数值会处于全局最优解附近,但却不是最优解,通过 DBN 顶层设置的某种分类器输出分类结果<sup>[15]</sup>,比较标签数据和分类器输出数据之间的误差,利用 BP 算法将误差自顶向下传播至每一层 RBM,有监督的微调 DBN 权值,使整个 DBM 达到最优。

## 2 车载故障描述

### 2.1 车载设备组成

车载设备、地面设备和 GSM-R 网络组成了列车运行控制系统(Chinese train control system,简称 CTCS)<sup>[16]</sup>。车载设备主要包括 CTCS3-300T, CTCS3-300H, CTCS3-300S, CTCS2-200H 和 CTCS2-200C 这 5 种型号。CTCS3 级车载设备是具有我国自主知识产权的列车控制系统体系,适用于 300~350 km/h 的干线铁路。笔者以 CTCS3-300T 型号的车载设备为例,完成车载故障诊断。CTCS3-300T 型车载设备结构如图 3 所示。

300T 车载设备主要由列车超速防护控制单元(automatic train protection control unit,简称 ATP-CU),BTM,C2 主机控制单元(CTCS-2 control unit,简称 C2CU)、测距测速单元(speed and distance measurement unit,简称 SDU)、人机显示界面(driver-machine interface,简称 DMI)、安全数字接口单元(vital digital input/output unit,简称 VDX)

和全球移动通讯铁路系统(global system for mobile communications-railway,简称 GSM-R)等组成<sup>[17]</sup>,广泛用于武广、沪杭、京沪及兰新等高速铁路。

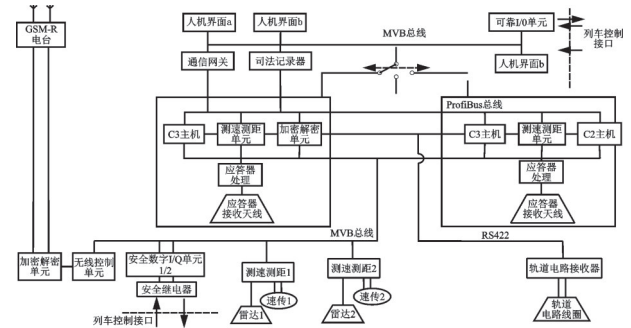


图 3 CTCS3-300T 型车载设备结构  
Fig.3 Structure of CTCS3-300T on-board equipment

### 2.2 车载故障数据

300T 车载设备故障数据来源于应用程序事件(application events,简称 AE)log 文件和电务人员记录的故障统计表。AElog 文件由 ATPCU 生成,记录列车某一时刻的运行信息,包括日期、时间、系统时间戳以及运行状况,如果发生故障,会记录故障现象;故障统计表记录了列车运行期间发生的故障现象、处理过程、处理结果以及故障原因。本研究的数据来源于某局集团公司电务段 2017—2019 年 CTCS3-300T 型车载设备 ATPCU 自动记录的 AElog 文件和人工记录故障统计表。

对比分析 AElog 文件和人工记录的故障统计表,整理出 1 124 条有效训练数据,每条数据详细记录了故障时间、地点、现象和电务人员或设备供应商分析的故障原因。经研究发现,ATP 车载设备故障呈多样性,任意一种故障可能由多个故障特征体现,同一特征亦可能反映不同的故障类别<sup>[18]</sup>。为了更准确地建立诊断模型,将故障数据进行归类,车载设备故障数据分类统计如图 4 所示。




图 4 车载设备故障数据分类统计  
Fig.4 Classification statistics of on-board equipment fault data

虽然车载设备故障种类繁多,但主要包括车地通信、ATPCU相关、BTM相关、列车接口及测距测速等故障类型。结合多发故障,统计出车载设备常见的9种故障现象和13种故障原因,分别如表1、2所示。

表1 故障现象  
Tab.1 Fault phenomenon

| 序号 | 故障现象                  |
|----|-----------------------|
| 1  | ATP失效/无法正常启动          |
| 2  | BTM数据错误               |
| 3  | DMI与主机通信中断            |
| 4  | 车地通信中断/无线通信超时/无法连接RBC |
| 5  | 制动测试不通过               |
| 6  | C3切换C2失败/C3异常降级C2     |
| 7  | 应答器报文错误               |
| 8  | 无线通信超时                |
| 9  | 降速/停车                 |

表2 故障原因  
Tab.2 Fault causes

| 序号 | 故障原因           |
|----|----------------|
| 1  | 启动BSA错误        |
| 2  | 永久BSA错误        |
| 3  | BTM端口无效        |
| 4  | BTM校验超时        |
| 5  | VDX端口无效/报文无效   |
| 6  | SDU模块故障/ODO无服务 |
| 7  | 移动终端TM故障       |
| 8  | RBC相关故障        |
| 9  | GSM-R网络异常      |
| 10 | AB系软件代码不一致     |
| 11 | 全零应答器          |
| 12 | 继电器状态错误/反馈超时   |
| 13 | 车载软件/硬件故障      |

### 3 基于DBN-HD的车载故障诊断模型设计

#### 3.1 故障现象向量与故障原因向量

当列车运行控制系统发生故障时,故障现象可以直接被司机观察到或者通过DMI显示屏显示,定义故障现象向量为

$$s = [s_1, s_2, \dots, s_i, \dots, s_n]$$

其中: $n$ 为故障现象种类总数; $s_i \in \{0, 1\}$ ,表示故障现象状态,当属于此类现象时, $s_i = 1$ ,否则 $s_i = 0$ 。

例如表2中,“BTM数据错误,列车停车”可以

表示为

$$s = [0, 1, 0, 0, 0, 0, 0, 0, 1]$$

同理,定义故障原因向量为

$$r = [r_1, r_2, \dots, r_i, \dots, r_m]$$

其中: $m$ 为故障原因类型总数; $r_i \in \{0, 1\}$ ,表示故障原因状态,即属于此类现象时, $r_i = 1$ ,否则 $r_i = 0$ 。

例如表3中,故障原因是“由硬件设备故障引起BTM端口无效”可以表示为

$$r = [0, 0, 1, 0, 0, 0, 0, 0, 0, 0, 0, 0, 1]$$

综上,一条历史故障数据可由 $s, r$ 这2个向量组合而成,如“因BTM端口无效导致BTM数据错误造成列车停车”可以表示为

$$[s, r] =$$

$$[0, 1, 0, 0, 0, 0, 0, 0, 1, 0, 0, 1, 0, 0, 0, 0, 0, 0, 0, 0, 1]$$

由此可见,车载故障诊断就是在已知故障现象的前提下,找出最可能的故障原因,即

$$r^* = \arg \max_r P(r|s) \quad (10)$$

从数学角度来说,属于条件概率的求解问题,以故障现象向量 $s$ 作为DBN的输入样本,即 $x = s$ ,DBN充分提取故障现象向量的特征,并输出向量 $y$ ,向量 $y$ 的每个元素都是一个在 $[0, 1]$ 范围内的非负实值,即 $y_i \in \{0, 1\}$ ,表示某类故障原因的概率。

#### 3.2 顶层分类器设计

DBN完成训练后,通过顶层附加的分类器输出,假设使用softmax分类器,即概率值最大的状态输出为1,其他状态输出为0,得到的向量为故障原因向量 $r$ 。通过前面的分析可以知道,实际的车载故障可能是由一个或多个故障原因引起,而这种分类器仅得到一个故障原因,因此需要改进顶层分类器。

设DBN实际输出为

$$y = [y_1, y_2, \dots, y_i, \dots, y_k]$$

其中: $k$ 为输出单元数,且 $1 \leq i \leq k$ 。

$$\text{令 } r_i = \begin{cases} 1 & (y_i \geq \Delta) \\ 0 & (\text{其他}) \end{cases}$$

其中: $\Delta$ 为一个概率阈值。

若 $y_i$ 大于等于阈值 $\Delta$ ,则 $r_i = 1$ ,否则 $r_i = 0$ ,得到

$$r^* = [r_1^*, r_2^*, \dots, r_i^*, \dots, r_k^*]$$

由此,实现一个或多个故障原因的诊断。

#### 3.3 汉明距离与评价指标

本研究模型输入、输出向量均为0,1组成的二值序列,表示故障现象与故障原因的对应关系,因此



引入汉明距离来度量故障现象向量与故障原因向量之间的差异。汉明距离又称为信号距离,是一种基于统计理论度量二值化序列相似程度的判别标准<sup>[19]</sup>,常用于信号编码一致性的测试,其按位运算,计算速度快且内存消耗小。

设 2 个二值向量  $c$  和  $d$ , 则汉明距离为两向量逐位做异或运算, 并求和, 即

$$D(c, d) = \sum_{i=1}^n c_i \oplus d_i \quad (11)$$

例如, 某故障现象为列车 DMI 显示屏报告“BTM 数据错误”, 由表 2 知, 该故障现象向量为

$$s = [0, 1, 0, 0, 0, 0, 0, 0, 0, 0]$$

该故障原因为“车载设备硬件故障引起 BTM 端口无效”, 由表 3 知, 该故障原因向量为

$$r = [0, 0, 1, 0, 0, 0, 0, 0, 0, 0, 0, 1]$$

若车载故障诊断模型输出为

$$r^* = [0, 0, 1, 0, 0, 0, 0, 0, 0, 0, 0, 0]$$

由式(11)可得

$$D(r, r^*) = \sum_{i=1}^k r_i \oplus r^*_i = 1 \quad (12)$$

$r$  与  $r^*$  汉明距离为 1, 表示一个故障原因诊断错误, 比较分析可知, 未诊断出 BTM 硬件故障这一引发原因; 同理,  $r$  与  $r^*$  汉明距离为 0, 说明实际输出与期望输出一致, 故障原因诊断全面且正确。因此, 定义模型诊断准确率 (Accuracy) 为

$$\text{Accuracy} = N^*/N \quad (13)$$

其中:  $N^*$  为汉明距离为 0 的测试样本个数;  $N$  为测试样本总数。

### 3.4 故障诊断实现过程

笔者提出的 DBN-HD 车载故障诊断流程如图 5 所示, 主要包括以下 5 个方面。

#### 3.4.1 数据预处理

收集数据, 定义故障现象向量和故障原因向量, 划分为训练集和测试集。

#### 3.4.2 预训练

RBM 预训练采用 CD-1 算法求解参数  $\theta_{ij} = (\omega_{ij}, a_i, b_j)$ , CD-1 学习算法为先输入故障现象向量  $s = [s_1, s_2, \dots, s_i, \dots, s_n]$ , 设置学习效率  $\epsilon$  和迭代次数  $l$ , 并将参数  $\theta_{ij} = (\omega_{ij}, a_i, b_j)$  置为 0, 然后通过运算输出  $\theta = (\mathbf{W}, \mathbf{a}, \mathbf{b})$ 。其训练步骤如下:

- 1) 将故障现象向量  $s = [s_1, s_2, \dots, s_i, \dots, s_n]$  赋值给可见层  $v_i$ ;
- 2) 由式 (3) 计算隐藏层的特征向量  $h_j^{(t)} \sim p(h_j|v^{(t)})$ ;

3) 由式 (4) 计算可见层的特征向量  $v_i^{(t+1)} \sim p(v_i|h^{(t)})$ ;

4) 由式 (8) 求得参数  $\theta_{ij} = (\omega_{ij}, a_i, b_j)$  的更新梯度, 并由式 (9) 进行参数更新, 得到

$$\begin{cases} \omega_{ij} = \omega_{ij}^t + [\rho(h_j|v^{(0)})v_i^{(0)} - \rho(h_j|v^{(k)})v_i^{(k)}] \\ a_i^{(t+1)} = a_i^{(t)} + v_i^{(0)} - v_i^k \\ b_j^{(t+1)} = b_j^{(t)} + [\rho(h_j|v^{(0)}) - \rho(h_j|v^{(k)})] \end{cases} \quad (14)$$

5) 若  $t < k$ , 则  $t = t + 1$ , 转至步骤 2; 否则保存参数, 结束。

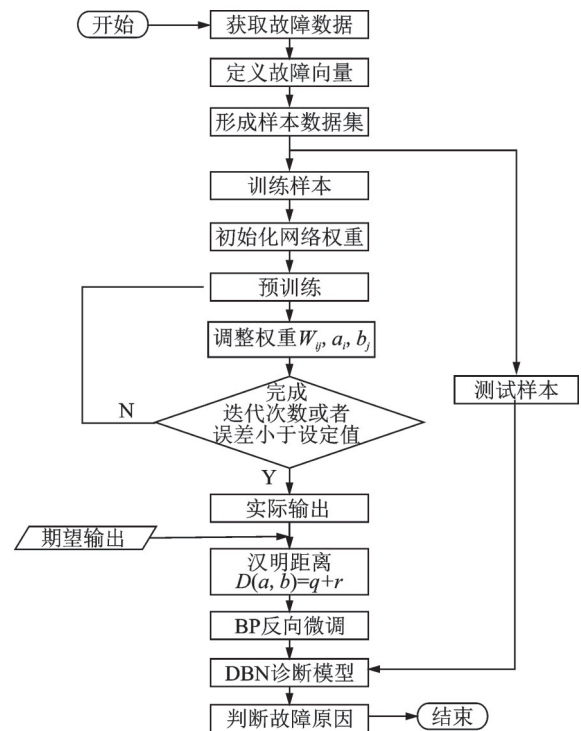


图 5 DBN-HD 车载故障诊断流程

Fig.5 Process of DBN-HD on-board fault diagnosis

#### 3.4.3 权值微调

比较模型输出故障原因与实际故障原因向量的汉明距离, 采用 BP 算法回传误差, 微调模型参数。BP 反向微调算法为先输入故障现象向量  $s = [s_1, s_2, \dots, s_i, \dots, s_n]$ , 设置学习效率  $\epsilon$  和迭代次数  $l$ , 并设置参数  $\theta = (\mathbf{W}, \mathbf{a}, \mathbf{b})$ , 然后通过运算输出最优参数  $\theta^* = (\mathbf{W}^*, \mathbf{a}^*, \mathbf{b}^*)$ 。其训练步骤如下。

1) 计算故障原因向量  $r = [r_1, r_2, \dots, r_k]$ 。

2) 比较输出故障原因向量  $r = [r_1, r_2, \dots, r_k]$  与实际故障原因向量  $r^* = [r_1^*, r_2^*, \dots, r_k^*]$  的汉明距离  $D(r, r^*)$ , 若  $D(r, r^*)$  不等于 0, 计算误差

$$\delta_k \leftarrow r_k^* (1 - r_k^*) (r_k - r_k^*) \quad (15)$$

3) 由输出误差  $\delta_k$  计算 DBN 的每个隐藏单元  $h$  的输出误差

$$\delta_h \leftarrow r_h^* (1 - r_h^*) \sum_k \theta_{kh} \delta_k \quad (16)$$

其中： $r_h^*$ 为隐藏层的实际输出。

4) 更新模型参数  $\theta_{ij}$

$$\theta_{ij} \leftarrow \theta_{ij} + \Delta \theta_{ij} \quad (17)$$

其中： $\theta_{ij} = \epsilon \delta_i s_j$ ,  $\epsilon$ 为学习效率。

5) 若  $t < k$ , 则  $t = t + 1$ , 转至步骤 2; 否则保存参数, 结束。

### 3.4.4 故障诊断

将测试数据输入到训练完成的 DBN-HD 模型中, 获得每条测试数据的故障原因向量。

### 3.4.5 准确率分析

比较输出故障原因与实际故障原因的汉明距离, 判断模型性能。

## 4 车载故障诊断仿真分析

### 4.1 仿真环境及数据预处理

笔者在 Windows10 64 位的系统下, 利用 Matlab R2019a 对常见车载故障进行诊断实验, 以某局集团公司电务段 2017—2019 年车载设备故障实例和测试数据为原始数据, 预处理生成 1 124 条样本数据, 其中 824 条用于网络训练, 300 条用于模型测试。

### 4.2 网络参数设置

故障现象向量和故障原因向量的维数分别确定网络输入、输出节点个数为 9 和 13 个, 初始参数  $\theta_{ij} = (\omega_{ij}, a_i, b_j)$  为 0。文献[20]讨论了 DBN 参数设置原则, 笔者结合特定故障诊断任务, 采用变量替换法, 综合考虑故障诊断正确率和运行效率, 最终确定 DBN 训练学习效率为 0.1, BP 微调学习效率为 0.1, 批量大小设置为 100, 网络输出阈值为 0.4, 即概率大于等于 40% 判定为输出。设置 4 层隐藏层, 每层神经元个数分别取 20, 30, 30 和 20, DBN 模型参数设置如表 3 所示。

### 4.3 网络深度、RBM 训练次数与仿真结果的关系

DBN-HD 模型诊断精度易受到网络深度和训练次数的影响, 本节讨论两者之间的关系。首先统一其他参数, 然后设置不同 RBM 层数, 得到 6 种不同的 DBN 网络, 不同 RBM 层数的 DBN 如表 4 所示。

表 3 DBN 模型参数

Tab.3 Parameters of DBN

| DBN 参数        | 数值  |
|---------------|-----|
| DBN 训练学习率     | 0.1 |
| BP 反向微调学习率    | 0.1 |
| CD 算法迭代次数     | 1   |
| 输入节点数         | 9   |
| 隐藏层 $h_1$ 节点数 | 20  |
| 隐藏层 $h_2$ 节点数 | 30  |
| 隐藏层 $h_3$ 节点数 | 30  |
| 隐藏层 $h_4$ 节点数 | 20  |
| 输出节点数         | 13  |
| 网络输出阈值        | 0.4 |
| RBM 训练次数      | 500 |
| BP 微调训练次数     | 100 |

表 4 不同 RBM 层数的 DBN

Tab.4 DBN with different RBM layers

| DBN  | 隐藏层层数 | 网络结构                   |
|------|-------|------------------------|
| 网络 1 | 1     | 9-30-13                |
| 网络 2 | 2     | 9-20-30-13             |
| 网络 3 | 3     | 9-20-30-20-13          |
| 网络 4 | 4     | 9-20-30-30-20-13       |
| 网络 5 | 5     | 9-20-30-30-30-20-13    |
| 网络 6 | 6     | 9-20-30-30-30-30-20-13 |

隐藏层层数与模型性能的关系见图 6。由图 6(a)可知, 随着隐藏层层数的增加, 模型诊断准确率逐步增高, 当 RBM 层数达到 4 层以上时, 准确率提高幅度不再明显, 并且网络深度越深, 模型训练时间越多, 考虑时间成本, 笔者选取 4 层 RBM 网络结构。图 6(b)为网络 3 和网络 4 的均方差随训练次数的变化曲线。由图可见, 其具有以下特征: ①网络 4 比网络 3 的初始均方差更低; ②随着 BP 网络微调训练次

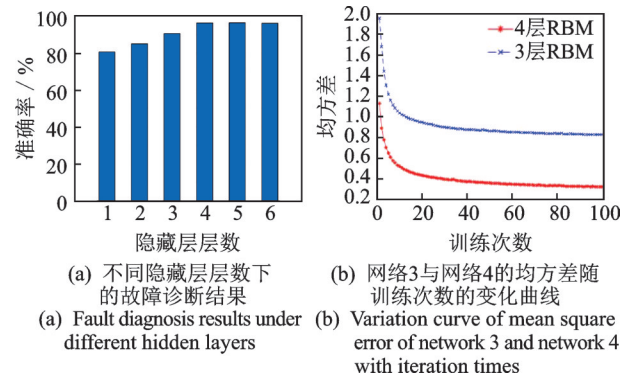


图 6 网络层数与模型性能的关系

Fig.6 Relationship between network layers and model performance

数的增加,网络4比网络3均方差小0.4左右。这说明深层网络预训练后的各权重值更接近全局最优解,且深层网络的特征提取能力比浅层网络更强。

以网络4为例,控制RBM训练次数反复实验。RBM训练次数对模型性能的影响如图7所示。由图可知,随着RBM训练次数的增加,诊断准确率不




图7 RBM训练次数对模型性能的影响

Fig.7 Effect of RBM iteration times on model performance

断上升,当训练次数在500次时,准确率最高为96.3%,随后准确率出现下降,出现过拟合现象。因此,RBM训练次数取500次为最优。

#### 4.4 实验对比

为了证明笔者提出DBN-HD模型的有效性,筛选出数据集中最常见的3种故障,即车地通信、AT-PCU相关和BTM相关故障,选择SVM,BPNN和DBN等模型和本研究模型作对比分析。SVM采用LIVSVM<sup>[21]</sup>工具包实现,设置C-SVC类型,核函数选取径向基函数,其控制因子 $g=0.01$ ,惩罚因子 $C=10$ ;BPNN和DBN采用4层结构,输入层、输出层及隐藏层神经元个数与DBN-HD相同。表5为不同模型的故障诊断正确率与运行时间比较,由表可见,DBN-HD在各类型故障诊断正确率均高于其他3种模型,能有效应用于车载故障的诊断。

表5 不同模型的故障诊断正确率与运行时间比较

Tab.5 Comparison of fault diagnosis accuracy and running time of different models

| 故障类型    | SVM   |      | BPNN  |      | DBN   |     | DBN-HD |      |
|---------|-------|------|-------|------|-------|-----|--------|------|
|         | 正确率/% | t/s  | 正确率/% | t/s  | 正确率/% | t/s | 正确率/%  | t/s  |
| 车地通信    | 88.7  |      | 92.5  |      | 98.2  |     | 98.3   |      |
| ATPCU相关 | 80.1  | 1.25 | 82.7  | 11.2 | 96.1  | 14  | 96.7   | 12.9 |
| BTM相关   | —     |      | 84.3  |      | 89.6  |     | 95.5   |      |
| 平均      | —     |      | 86.5  |      | 94.6  |     | 96.8   |      |

从应用角度进一步分析,车地通信故障主要包括RBC故障、GSM-R网络中断和STM天线故障等,多由单一原因造成,各个模型识别率都相对较高,DBN-HD达到98.3%;ATPCU相关故障常由DMI显示报告“ATP启动失败”和“DMI通信中断”等,不同故障表现出相似的故障现象,故障特征不易提取,处理这类故障时,深度学习效果优于浅层机器学习,DBN-HD模型比SVM模型准确率高出16%左右;BTM相关故障多由2种故障复合而成,SVM仅依据故障特征完成故障数据分类,无法识别2种或2种以上的故障原因,不能满足实际应用。DBN-HD模型改进了顶层分类器,通过设置输出阈值,可得到1种或多种故障原因,从而实现多故障原因诊断。另外,DBN-HD以实际输出与期望输出之间的汉明距离作为误差调整网络权值,降低了计算复杂度,运行效率高于DBN模型。

## 5 结束语

本研究提出的DBN-HD车载故障诊断模型,兼

顾了无监督学习和有监督学习的优点,具有强大的特征提取能力,通过改进网络输出方式,实现了多故障原因诊断。同时,模型引入汉明距离度量输出误差,增加了网络权值的微调效率,减少了运行时间。通过分析网络深度、RBM训练次数等参数与准确率的关系,调优网络结构和参数设置,并与其他3种故障诊断模型作对比,实验结果表明本研究模型提高了故障诊断的精度及运行效率,可为铁路电务部门车载设备故障诊断提供有力的技术支持。

## 参 考 文 献

- [1] ZHANG Y, WANG H F, YUAN T, et al. Hybrid online safety observer for CTCS-3 train control system on-board equipment[J]. IEEE Transactions on Intelligent Transportation Systems, 2019, 20(3): 925-934.
  - [2] 江磊,王小敏,刘一骊,等.基于动态贝叶斯网络的CTCS3-300T列控车载系统运行可靠性及可用性评估[J].铁道学报,2020,42(3):85-92.
- JIANG Lei, WANG Xiaomin, LIU Yiliu, et al. DBN-based operational reliability and availability evaluation of CTCS3-300T on board system[J]. Journal of the China

- Railway Society, 2020, 42(3):85-92.(in Chinese)
- [3] 梁潇, 王海峰, 郭进, 等. 基于贝叶斯网络的列控车载设备故障诊断方法[J]. 铁道学报, 2017, 39(8): 93-100.  
LIANG Xiao, WANG Haifeng, GUO Jin, et al. Bayesian network based fault diagnosis method for on-board equipment of train control system[J]. Journal of the China Railway Society, 2017, 39(8):93-100.(in Chinese)
- [4] 赵阳, 徐田华. 基于文本挖掘的高铁信号系统车载设备故障诊断[J]. 铁道学报, 2015, 37(8):53-59.  
ZHAO Yang, XU Tianhua. Text mining based fault diagnosis for vehicle on-board equipment of high speed railway signal system[J]. Journal of the China Railway Society, 2015, 37(8):53-59.(in Chinese)
- [5] WANG F, XU T H, TANG T, et al. Bilevel feature extraction-based text mining for fault diagnosis of railway systems[J]. IEEE Transactions on Intelligent Transportation Systems, 2017, 18(1):49-58.
- [6] 牛宏侠, 郭子钰, 陈光武. 基于RS-ICS-BP的列控车载BTM故障诊断[J]. 北京交通大学学报, 2020, 44(2):52-57.  
NIU Hongxia, GUO Ziyu, CHEN Guangwu. Fault diagnosis of on-board BTM based on RS-ICS-BP [J]. Journal of Beijing Jiaotong University, 2020, 44(2): 52-57.(in Chinese)
- [7] 张彩凤, 米根锁, 李泓锦. 改进 PSO-BP 方法在 ATP 车载设备多故障诊断中的应用研究[J]. 测控技术, 2019, 38(2):56-60,64.  
ZHANG Caifeng, MI Gensuo, LI Hongjin. Application of improved PSO-BP method in multiple fault diagnosis of ATP vehicle equipment [J]. Measurement & Control Technology, 2019, 38(2): 56-60, 64.(in Chinese)
- [8] HINTON G E, OSINDERO S, TEH Y W. A fast learning algorithm for deep belief nets[J]. Neural Computation, 2006, 18(7):1527-1554.
- [9] 谢跃, 梁瑞宇, 包永强, 等. 融合改进梅尔谱特征和深信念网络的语音测谎算法[J]. 声学学报, 2019, 44(2): 214-220.  
XIE Yue, LIANG Ruiyu, BAO Yongqiang, et al. Deception detection with spectral features base on deep belief network[J]. Acta Acustica, 2019, 44(2):214-220. (in Chinese)
- [10] BALAKRISHNAN N, RAJENDRAN A, PELUSI D, et al. Deep belief network enhanced intrusion detection system to prevent security breach in the internet of things [J]. Internet of Things, 2021, 14: 100112.
- [11] 顾佳, 黄明, 关岳. 高速列车牵引变流器故障诊断研究[J]. 振动、测试与诊断, 2020, 40(5):997-1002.  
GU Jia, HUANG Ming, GUAN Yue. Fault diagnosis of traction converter for high-speed train [J]. Journal of Vibration, Measurement & Diagnosis, 2020, 40(5): 997-1002.(in Chinese)
- [12] 李益兵, 王磊, 江丽. 基于 PSO 改进深度置信网络的滚动轴承故障诊断[J]. 振动与冲击, 2020, 39(5): 89-96.  
LI Yibing, WANG Lei, JIANG Li. Rolling bearing fault diagnosis based on DBN algorithm improved with PSO[J]. Journal of Vibration and Shock, 2020, 39(5): 89-96.(in Chinese)
- [13] 皮骏, 刘鹏, 马圣, 等. 基于 MGA-BP 网络的航空轴承故障诊断[J]. 振动、测试与诊断, 2020, 40(2): 381-388.  
PI Jun, LIU Peng, MA Sheng, et al. Aero-engine bearing fault diagnosis based on MGA-BP neural network [J]. Journal of Vibration, Measurement & Diagnosis, 2020, 40(2):381-388.(in Chinese)
- [14] HINTON G E. A practical guide to training restricted boltzmann machines[M]. Berlin: Springer Berlin Heidelberg, 2012:5-6.
- [15] RUMELHART D E, HINTON G E, WILLIAMS R J. Learning representations by back-propagating errors [J]. Nature, 1986, 323(6088):533-536.
- [16] 唐涛. 列车运行控制系统安全评估方法[M]. 北京: 中国铁道出版社, 2019:254-255.
- [17] ZANG Y, SHANGGUAN W, CAI B, et al. Methods for fault diagnosis of high-speed railways: a review[J]. Proceedings of the Institution of Mechanical Engineers, Part O: Journal of Risk and Reliability, 2019, 233(5): 908-922.
- [18] SHI L, CHEN L. Hazard recognition and reliability analysis of CTCS-3 on-board subsystem[J]. Computer Communications, 2020, 151:145-153.
- [19] 沈连丰, 李正权. 信息理论与编码基础[M]. 北京: 科学出版社, 2010:76-77.
- [20] 高强, 马艳梅. 深度信念网络(DBN)网络层次数量的研究及应用[J]. 科学技术与工程, 2016, 16(23):234-238,262.  
GAO Qiang, MA Yanmei. Research and application of the level of the deep belief network(DBN)[J]. Science Technology and Engineering, 2016, 16(23): 234-238, 262.(in Chinese)
- [21] CHANG C C, LIN C J. LIBSVM: a library for support vector machines [J]. ACM Transactions on Intelligent Systems and Technology, 2011, 2(3):1-27.



**第一作者简介:**魏伟,男,1987年10月生,讲师。主要研究方向为自然语言处理、列控系统车载设备故障诊断。

E-mail:weir\_0719@163.com