

# 基于机器学习的轨道电路状态判断

初广前,李璐\*,张嘉驰,钱佳瑶

山东交通学院 轨道交通学院,山东 济南 250357

**摘要:**为准确判断轨道电路的状态,保障轨道交通的安全运行,研究无监督学习中的高斯混合模型(Gaussian mixed model, GMM)、有监督学习中的反向传播神经网络(back propagation neural network, BPNN)模型与逻辑回归(logistic regression, LR)分类模型等3种典型机器学习算法在轨道电路状态判断中的应用。将轨道电路分为占用状态和空闲状态,应用3种算法实现状态分类任务,并在实际测得的数据集上对比3种算法的分类性能。测试结果表明:3种算法均能实现轨道电路状态的准确分类。与BPNN模型和LR分类模型相比,GMM无需训练过程,可降低人工成本。

**关键词:**轨道电路;状态分类;GMM;BPNN;LR分类模型

**中图分类号:**U284.2

**文献标志码:**A

**文章编号:**1672-0032(2022)04-0018-08

**引用格式:**初广前,李璐,张嘉驰,等.基于机器学习的轨道电路状态判断[J].山东交通学院学报,2022,30(4):18-25.

CHU Guangqian, LI Lu, ZHANG Jiachi, et al. State judgement for track circuits based on machine learning[J]. Journal of Shandong Jiaotong University, 2022, 30(4): 18-25.

## 0 引言

截至2020年底,我国高速铁路运营里程达3.79万km,稳居世界第一,在初步建成“四纵四横”的高铁网络基础上,进一步规划了“八纵八横”高铁网络<sup>[1]</sup>。轨道电路是铁路运输中的重要组成部分,为保证铁路运行的安全性,需准确判断轨道电路的状态并进行预测。

诊断轨道电路故障一般分为人工诊断、数学模型诊断及人工智能诊断3种方法。人工诊断是指技术人员根据仪器检测的参数波动,依靠专业知识和经验判断故障,工作量大,效率和准确率均较低,并且存在安全隐患。汪培平<sup>[2]</sup>基于3V化经验准则判断轨道电路分路不良的情况,方法简单、易操作,但判断准确率不高。也可采用计轴方式,或增加钢轨轨面电压及短路电流、钢轨两侧端阻抗等方法解决轨道电路分路不良的问题<sup>[3-5]</sup>。数学模型诊断是指采用轨道电路网络、电气绝缘节、补偿电容等设备,通过构建电路数学模型研究轨道电路的调整状态、分路状态和断轨状态<sup>[6-7]</sup>。轨道电路故障诊断属于动态系统,具有复杂性兼非线性,很难建立数学模型,无法高效准确地诊断故障<sup>[8]</sup>。人工智能诊断是通过人工智能技术进行故障诊断<sup>[9]</sup>。可以采用群体智能算法诊断轨道电路故障:在轨道电路的故障诊断室,综合运用模拟退火算法和粒子群算法,具有较高的判断准确率,可克服传统粒子群算法易陷入局部最优解的缺点<sup>[10]</sup>。但群体智能算法需要海量的迭代步骤,难以达到全局最优解。

近年来,机器学习在轨道交通行业得到了广泛应用。Gibert等<sup>[11]</sup>在多任务学习框架中,结合多个检

收稿日期:2021-04-28

基金项目:山东交通学院博士科研基金项目(BS201902037)

第一作者简介:初广前(1970—),男,山东潍坊人,工学博士,主要研究方向为机器学习、轨道电路,E-mail:2557142148@qq.com。

\*通信作者简介:李璐(1989—),女,黑龙江佳木斯人,副教授,工学硕士,主要研究方向为铁路行车组织,E-mail:215018@sdjtu.edu.cn。

测器对铁路轨道监控,提高了铁路枕木和扣件缺陷检测的准确率。Stallkamp 等<sup>[12]</sup>将局部神经网络和决策树分类器应用到轨道电路故障检测中,正确检测率和定位率分别为 99%、92%。郑云水等<sup>[13]</sup>运用模糊神经网络理论诊断轨道电路的故障,并优化仿真模型,结果表明该模型具有较高的诊断准确率。吴志鹏<sup>[14]</sup>采用决策树 C4.5 算法诊断 ZPW-2000A 轨道电路故障。孙浩洋<sup>[15]</sup>对比分析 ZPW-2000A 无绝缘轨道电路设备故障的多个影响因素,均衡化处理历史运行数据,并结合故障树理论和隐半马尔可夫模型预测轨道电路故障。贺帅超<sup>[16]</sup>针对 25 Hz 相敏轨道电路故障,分析不同区段的轨道电路状态,基于神经网络和模糊逻辑系统搭建故障诊断系统。王瑞峰等<sup>[17]</sup>分析故障类型与故障征兆的联系并建立集合,用集对分析结合熵权法及隶属函数描述运行状态对应关系,建立模型反映轨道电路的运行状态及故障类型。牛行通<sup>[18]</sup>分析 25 Hz 相敏轨道电路的工作原理、常见故障及故障原因,用改进的蝙蝠算法优化模糊反向传播神经网络(back propagation neural network, BPNN)模型,提高轨道电路故障的诊断准确率。朱文博<sup>[19]</sup>采用基于改进决策树算法诊断轨道电路故障,并开发 1 套采用 VC++6.0 平台与 MFC 类库进行可视化界面编程的轨道电路故障诊断系统。田粉霞等<sup>[20]</sup>采用卷积神经网络(convolutional neural networks, CNN)诊断调谐区故障,筛选卷积层的局部最优参数,采用 dropout 方法避免过拟合现象,实现故障分类。谢旭旭等<sup>[21]</sup>根据四端网络建立无绝缘轨道电路等效模型,绘制故障诊断总体框图,确立合理的诊断结果层数结构,根据动态增添算法和粒子群算法优化框架,精简网络结构,用 My SQL 数据库、C# 语言及混合编程技术建立故障诊断系统。董煜<sup>[22]</sup>构建轨道电路四端网络模型,计算得到轨道电路的临界电压,构造初步故障诊断模型,用 BPNN、灰色关联分析和模糊综合评判诊断故障,通过输出结果构造基本概率赋值(basic probability assignment, BPA),建立故障诊断模型。

上述研究大多采用有监督学习模型,需要提前对样本进行人工分类及训练,增大了人力和物力成本。本文研究 3 种典型机器学习算法在轨道电路状态判断中的应用,以期为准判断轨道电路状态提供参考,保障轨道通车安全。

## 1 轨道电路工作原理

轨道电路由钢轨线路和钢轨绝缘组成,主要包括钢轨、钢轨绝缘、轨端接续线、送电端(轨道电源和限流器)、受电端(轨道继电器)等<sup>[23]</sup>,如图 1 所示。

根据轨道上是否有列车存在,轨道电路可分为线路空闲和线路占用 2 种情况:线路空闲时,继电器吸起,信号灯亮绿灯;线路占用时,信号灯亮红灯,后续列车停车,禁止进入轨道电路区间。轨道电路的工作原理为:当线路空闲时,轨道电路为通路,继电器中有电,继电器保持吸起状态;有列车进入轨道电路时,机车车辆轮对可导电,轮对也是轨道电路的组成部分,且轮对电阻较小,改变了轨道电路的电流,继电器落下,信号灯亮红灯。

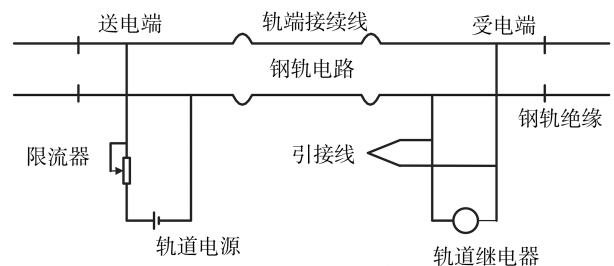


图 1 轨道电路结构示意图

## 2 典型机器学习分类模型

### 2.1 高斯混合模型

高斯混合模型(Gaussian mixture model, GMM)属于无监督机器学习模型,该模型采用多个服从高斯分布的线性组合刻画数据分布。当高斯分布的数目足够多时,可逼近任意分布的概率分布密度函数<sup>[24]</sup>。GMM 的概率分布

$$P(\mathbf{y}_n | \theta) = \sum_{k=1}^K \alpha_k \phi(\mathbf{y}_n | \theta_k), n = 0, 1, \dots, N,$$

式中:  $\mathbf{y}_n$  为观测样本,  $\mathbf{y}_n = [y_{n1} \ y_{n2} \ \cdots \ y_{nD}]^T$ , 其中,  $D$  为数据点的维度;  $N$  为样本数;  $K$  为服从高斯分布的线性组合数;  $\alpha_k$  为第  $k$  个服从高斯分布的线性组合系数,  $\sum_{k=1}^K \alpha_k = 1, \alpha_k \geq 0$ ;  $\phi(\mathbf{y}_n | \theta_k)$  为混合模型中的第  $k$  个分量高斯分布, 其中  $\theta_k$  为第  $k$  个分量高斯分布的参数,  $\boldsymbol{\mu}_k$  为均值,  $\boldsymbol{\Sigma}_k$  为协方差矩阵, 则  $\phi(\mathbf{y}_n | \theta_k) = \frac{1}{(2\pi)^{D/2} |\boldsymbol{\Sigma}_k|^{1/2}} \exp\left(-\frac{1}{2}(\mathbf{y}_n - \boldsymbol{\mu}_k)^T \boldsymbol{\Sigma}_k^{-1}(\mathbf{y}_n - \boldsymbol{\mu}_k)\right)$ 。

GMM 的核心问题是求解参数  $\{\alpha_k, \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k\}$ , 可采用最大期望(expectation maximization, EM)算法<sup>[25]</sup>。为了加快 EM 算法的收敛, 对输入数据进行预处理, 将输入数据映射至  $[-1, 1]$  内, 映射关系式为:

$$Y_n = \frac{2(y_{nD} - y_{\min})}{(y_{\max} - y_{\min})} - 1,$$

式中:  $y_{\min}, y_{\max}$  分别为样本数据中的最小值、最大值。

采用 EM 算法, 对 GMM 参数进行估计的步骤为:

- 1) 对参数  $\{\alpha_k, \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k\}$  随机赋值, 此处将其赋值为  $[0, 1]$  内的随机数;
- 2) 计算第  $k$  个分量模型对观测数据的响应程度, 计算公式为:

$$\hat{\gamma}_{nk} = \frac{\alpha_k \phi(\mathbf{y}_n | \theta_k)}{\sum_{k=1}^K \alpha_k \phi(\mathbf{y}_n | \theta_k)}, k = 1, 2, \dots, K; n = 1, 2, \dots, N;$$

- 3) 更新参数模型的求解参数  $\{\alpha_k, \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k\}$ , 公式分别为

$$\hat{\alpha}_k = \frac{\sum_{n=1}^N \hat{\gamma}_{nk}}{N}, k = 1, 2, \dots, K,$$

$$\hat{\boldsymbol{\mu}}_k = \frac{\sum_{n=1}^N \hat{\gamma}_{nk} \mathbf{y}_n}{\sum_{n=1}^N \hat{\gamma}_{nk}}, k = 1, 2, \dots, K,$$

$$\hat{\boldsymbol{\Sigma}}_k = \frac{\sum_{n=1}^N \hat{\gamma}_{nk} (\mathbf{y}_n - \hat{\boldsymbol{\mu}}_k) (\mathbf{y}_n - \hat{\boldsymbol{\mu}}_k)^T}{\sum_{n=1}^N \hat{\gamma}_{nk}}, k = 1, 2, \dots, K;$$

- 4) 判断是否满足迭代终止条件, 若不满足, 则返回步骤 2)。

当 GMM 参数收敛后, 模型构建完成, 可将每个样本最大  $\alpha_k$  对应的分模型作为判断结果。GMM 是无监督学习算法, 未知聚类后样本的标签, 可采用 1 种计算 GMM 分类准确率的算法:

- 1) 从原始样本  $\{y_n\}$  中找出包含某一标签  $l$  的所有样本集合  $\{y_n\}$ ;
- 2) 将该集合  $\{y_n\}$  作为 GMM 的输入, 取最大  $\alpha_k$  对应的分模型作为判断结果;
- 3) 取步骤 2) 中数目最多的分模型作为 GMM 对标签为  $l$  的样本的判断结果, 记数目为  $S_l$ ;
- 4) 统计所有标签, 计算判断准确率  $\eta = \sum_l S_l / N \times 100\%$ 。

## 2.2 BPNN

BPNN 为多层前馈神经网络, 非线性映射能力和泛化能力良好, 应用广泛。BPNN 运行过程中的 2 个重要步骤是正向传播和反向传播: 正向传播是由输入层, 经多层隐含层, 最后至输出层, 输入数据在每层都要经神经元激活函数处理; 反向传播过程则先对比预期结果与计算模型的输出结果, 再将二者之差反向传入神经网络, 不断调节链接强度和阈值, 降低误差, 直至满足收敛条件。BPNN 采用的神经网络结构如图 2 所示。BPNN 包含 1 层输入层, 3 层隐含层, 1 层输出层。输入层有 2 个神经元, 每层隐含层网络均有 10 个神经元, 输出层有 1 个神经元。

图2中 $x_j^{(i)}$ 为第 $i$ 个样本的第 $j$ 个神经元信息, $O^{(i)}$ 为第 $i$ 个样本对应的输出。某一样本可表示为 $\{x_1^{(i)}, x_2^{(i)}, t^{(i)}, O^{(i)}\}$ ,其中 $t^{(i)}$ 为该样本对应的真实标签(0或1)。

在整个神经网络的组成构架中,采用sigmoid函数作为神经元激活函数,表达式为:

$$f(x) = 1/(1 + e^{-(\mathbf{W}^T \mathbf{x} + \mathbf{b})}), \quad (1)$$

式中: $\mathbf{W}$ 为网络权值矩阵, $\mathbf{W} = [w_{ji}^{(p)}]$ , $w_{ji}^{(p)}$ 为第 $p-1$ 层中第 $i$ 个神经元与第 $p$ 层中第 $j$ 个神经元的链接权重; $\mathbf{x}$ 为输入向量; $\mathbf{b}$ 为网络阈值矩阵, $\mathbf{b} = [b_j^{(p)}]$ , $b_j^{(p)}$ 为第 $p$ 层中第 $j$ 个神经元的阈值。

训练样本前先对输入数据进行归一化预处理,再在模型中开始训练,保证输入数据不同维度间的差异不会过大。对数据进行归一化处理时,将输入数据映射到 $[-1, 1]$ 内,映射关系式为

$$X_i = \frac{2(x_j^{(i)} - x_{\min})}{(x_{\max} - x_{\min})} - 1,$$

式中: $x_{\min}$ 、 $x_{\max}$ 分别为输入数据中的最小值、最大值。

采用梯度下降法更新BPNN的权值<sup>[26]</sup>,公式为

$$\begin{aligned} \mathbf{W}(t+1) &= \mathbf{W}(t) - \eta \frac{\partial E(t)}{\partial \mathbf{W}(t)}, \\ \mathbf{b}(t+1) &= \mathbf{b}(t) - \eta \frac{\partial E(t)}{\partial \mathbf{b}(t)}, \end{aligned}$$

式中: $t$ 为训练次数; $E(t)$ 为总误差函数; $\eta$ 为步长因子, $\eta \in (0, 1)$ 。

对 $w_{ji}^{(p)}$ ,有

$$\frac{\partial E}{\partial w_{ji}^{(p)}} = x_{ji}^{(p)} \delta_j^{(p)},$$

式中: $E$ 为误差; $x_{ji}^{(p)}$ 为该链接对应的输入; $\delta_j^{(p)}$ 为第 $p$ 层第 $j$ 个神经元的误差项, $\delta_j^{(p)} = f' \sum_k w_{jk}^{(p+1)} \delta_k^{(p+1)}$ ,其中 $f'$ 为当前神经元的输出; $\delta_k^{(p+1)}$ 为输出层神经元的误差项, $\delta_k^{(p+1)} = f'(x_k)[t_k - f(x_k)]$ 。

采用冲量项的方法避免损失函数收敛到局部极小值<sup>[27]</sup>,冲量项的计算公式为:

$$\begin{aligned} \Delta w_{ji}(n) &= \eta \delta_j x_{ji} + \alpha \Delta w_{ji}(n-1), \\ \Delta b_j(n) &= \eta \delta_j + \alpha \Delta b_j(n-1), \end{aligned}$$

式中: $\alpha$ 为冲量系数, $\alpha \in (0, 1)$ 。

若BPNN隐含层节点过多,网络结构过于复杂,复杂网络的训练成本将成倍增加,产生过拟合现象,即在训练样本上准确率较高,但试验样本中准确率略低;若BPNN隐含层节点过少,网络结构过于简单,输入与输出的关系未准确表达,产生欠拟合现象。确定隐含层节点数<sup>[28]</sup>

$$m = \sqrt{n + l} + \gamma,$$

式中: $n$ 为输入层节点数, $l$ 为输出层节点数, $\gamma$ 为常数, $\gamma \in [1, 10]$ 。

因此,BPNN的训练步骤为:1)网络权值初始化,对输入层权值和输出层权值随机赋值,将网络权值与阈值随机赋值为 $[0, 1]$ 的随机数;2)计算隐含层输出值,将隐含层输出值作为输出层输入值带入式(1),得到输出层的输出结果;3)根据预期结果与输出层的输出结果计算均方根误差(root mean square




图2 神经网络结构示意图



error, RMSE), 根据 RMSE 采用梯度下降法更新各层网络权值与阈值; 4) 判断是否满足迭代终止条件, 若不满足, 则返回步骤 3)。

### 2.3 逻辑回归分类模型

逻辑回归(logistic regression, LR)分类模型是针对多类别分类的典型模型, 本文采用多项 LR 分类模型。假设离散变量取值集合为  $\{1, 2, \dots, K\}$ , 则多项 LR 分类模型<sup>[29]</sup>

$$\mathbf{h}_{\theta}(x^{(i)}) = \begin{bmatrix} p(y^{(i)} = 1 | x^{(i)}; \theta) \\ p(y^{(i)} = 2 | x^{(i)}; \theta) \\ \vdots \\ p(y^{(i)} = K | x^{(i)}; \theta) \end{bmatrix} = \frac{1}{\sum_{k=1}^K e^{\theta_k^T x^{(i)}}} \begin{bmatrix} \exp(\theta_1^T x^{(i)}) \\ \exp(\theta_2^T x^{(i)}) \\ \vdots \\ \exp(\theta_K^T x^{(i)}) \end{bmatrix}, \quad (2)$$

式中:  $\theta_k$  为模型参数,  $\theta_1, \theta_2, \dots, \theta_K \in \mathbf{R}^{n+1}$ ;  $p(y^{(i)} = k | x^{(i)}; \theta)$  为已知模型参数  $\theta$  时, 第  $i$  组数据属于  $k$  类的概率。  $\sum_{k=1}^K \exp(\theta_k^T x^{(i)})$  为归一化分布, 各项和为 1。

LR 分类模型的损失函数

$$J(\theta) = -\frac{1}{m} \sum_{i=1}^m \sum_{k=1}^K u\{y^{(i)} = k\} \log \frac{\exp(\theta_k^T x^{(i)})}{\sum_{l=1}^K \exp(\theta_l^T x^{(i)})},$$

式中:  $u\{\cdot\}$  为指示函数, 若输入参数内容为真, 返回数值为 1, 反之则返回 0。

训练模型参数使损失函数取得最小值。该损失函数不能采用解析解求得参数。采用梯度下降法求解模型参数的最优解, 损失函数的梯度表达式为

$$\theta_k := \theta_k - \varepsilon \nabla_{\theta_k} J(\theta),$$

式中  $\varepsilon$  为步长因子。

采用梯度下降法求解 LR 分类模型参数的步骤为: 1) 初始化模型参数, 将模型参数  $\theta_k$  随机赋值为  $[0, 1]$  的随机数; 2) 计算损失函数的梯度  $\nabla_{\theta_k} J(\theta)$ ; 3) 更新模型参数  $\theta_k$ ; 4) 判断所有的模型参数  $\theta_k$  是否收敛, 若不收敛, 则返回步骤 2)。

## 3 结果分析

对实际不同状态下的轨道电路进行数据读取和采集。在轨道末端选取数据采集点, 分别测量空闲和占用状态下轨道电路的电压和电流, 测得的数据散点如图 3 所示。

由图 3 可知: 空闲状态样本分布较密集, 电压主要集中在  $0.20 \sim 0.25$  V, 电流主要集中在  $60 \sim 80$  mA; 占用状态的样本分布较离散, 电流、电压跨度较大, 电压为  $0.3 \sim 0.7$  V, 电流为  $110 \sim 200$  mA。

### 3.1 GMM 分类结果

按 2.1 节要求, 对样本数据进行归一化预处理, 并将其作为 GMM 的输入。轨道电路有空闲和占用 2 个工作状态, 设定 GMM 中  $K = 2$ , 每个高斯分布有电压和电流 2 个维度, 设定收敛条件为相邻 2 次估计的参数变动范围小于  $10^{-10}$ , 可得 EM 算法估计次数与参数变化量的关系, 如图 4 所示。

经过 EM 算法处理后, 待估计参数经过 7 次估计后收敛, 其数值稳定, 不再发生变化, 计算所得参数为

$$\{\alpha_1, \mu_1, \Sigma_1\} = \begin{bmatrix} 0.5063, & \begin{bmatrix} 0.2216 & 0.1094 \\ 0.4485 & 0.0412 \end{bmatrix} \\ & \begin{bmatrix} 0.0412 & 0.1058 \end{bmatrix} \end{bmatrix},$$




图3 轨道电路测量数据散点示意图

$$\{\alpha_2, \mu_2, \Sigma_2\} = \begin{bmatrix} 0.4937, & -0.8813 & 0.0014 & 0.0017 \\ -0.8458 & 0.0017 & 0.0021 & \end{bmatrix}。$$

### 3.2 BPNN 分类结果

按 2.2 节要求,对样本数据进行归一化预处理并将其作为 BPNN 的输入,构建如图 2 所示的 BPNN 模型。输入层 2 个神经元分别对应每个样本的电压和电流。轨道电路态为空闲状态,神经网络模型输出参数为 0;轨道电路状态为占用状态,神经网络模型输出参数为 1。

对样本数据预处理后开始训练模型。设训练样本数占总样本数的 25%。 $\eta = 0.01, \alpha = 0.2$ , RMSE 与训练次数的关系如图 5 所示。

由图 5 可知:随训练次数的增加, RMSE 逐渐减小。训练次数小于 150 时,包含 2 层隐含层的神经网络的 RMSE 比包含 3 层隐含层的神经网络小;训练次数超过 150 时,结果相反;训练次数大于 200 时,两者的 RMSE 变化均不大,且趋近于 0.15,故设定训练次数为 1000 次。

最终识别结果为:在训练次数为 1000 的前提下,包含 2 层隐含层、3 层隐含层的 BPNN 判断准确率均为 100%。

### 3.3 不同模型判断结果对比

不同隐含层的 BPNN 模型、GMM 和 LR 分类模型的判断准确率如表 1 所示。

由表 1 可知:有监督学习模型的 BPNN(2 层隐含层、3 层隐含层)模型的识别率非常准确,LR 分类模型的识别准确率相对较低。无监督学习模型的 GMM 与 BPNN 模型的准确率相同。有监督学习模型需提前对模型进行分类和训练,GMM 可在节约成本的前提下,准确判断轨道电路的不同状态。




图 4 EM 算法估计次数与参数变化量示意图




图 5 RMSE 与训练次数的关系曲线

表 1 不同模型判断结果

模型类别	模型名称	判断准确率/%	备注
无监督学习模型	GMM	100	
有监督学习模型	BPNN 模型	100	2 层隐含层
		100	3 层隐含层
	LR 分类模型	93.2	

## 4 结语

研究无监督学习算法 GMM、有监督学习算法 BPNN 模型与 LR 分类模型 3 种典型机器学习算法在轨道电路状态判断中的应用,并在实测数据集上对模型进行训练与测试。结果表明:GMM 无需得到先验知识即可准确判断轨道电路的不同状态。试验数据来源于教学演示设备,可进一步采用现场实测数据提高 GMM 的普适性和鲁棒性。

### 参考文献:

[1] 中国国家统计局. 中国统计年鉴 2017[EB/OL]. [2021-03-15]. <http://www.stats.gov.cn/tjsj/ndsj/2017/indexch.htm>.  
 [2] 汪培平. 3 V 化 25 Hz 相敏轨道电路在分路不良区段的施工与调试[J]. 铁道通信信号, 2011, 47(5): 41-42.  
 [3] 时良仁. 站内轨道电路分路不良计轴检查设备设计与实现[D]. 上海: 上海交通大学, 2011.  
 SHI Liangren. Design and implementation of axle-counter inspection equipment for track circuit bad shunting in railway station [D]. Shanghai: Shanghai Jiaotong University, 2011.  
 [4] 石卫师. 基于计轴系统的轨道电路棕光带故障分析探讨[J]. 现代城市轨道交通, 2021(6): 24-28.  
 SHI Weishi. Analysis and discussion on brown light band fault of track circuit based on axle counter system[J]. Modern Urban

- Transit, 2021(6):24-28.
- [5] 魏源, 范东贺, 卢鑫. 基于轨道电路解决站内分路不良方案的研究[J]. 价值工程, 2014, 33(8):120-121.  
WEI Yuan, FAN Donghe, LU Xin. On plan of solving bad shunting of track circuit[J]. Value Engineering, 2014, 33(8): 120-121.
- [6] 池鹏举. ZPW-2000A 无绝缘轨道电路建模与仿真[D]. 成都:西南交通大学, 2017.  
CHI Pengju. Modeling and simulation of ZPW-2000A jointless track circuit[D]. Chengdu: Southwest Jiaotong University, 2017.
- [7] 王梓丞. 轨道电路传输模型与故障诊断方法研究[D]. 成都:西南交通大学, 2019.  
WANG Zicheng. Research on transmission model and fault diagnosis method of track circuit[D]. Chengdu: Southwest Jiaotong University, 2019.
- [8] 何潇, 郭亚琦, 张召, 等. 动态系统的主动故障诊断技术[J]. 自动化学报, 2020, 46(8):1557-1570.  
HE Xiao, GUO Yaqi, ZHANG Zhao, et al. Active fault diagnosis for dynamic systems[J]. Acta Automatica Sinica, 2020, 46(8): 1557-1570.
- [9] LATIFA O, ALEXANDRA D, THIERRY D. Fault diagnosis in railway track circuits using Dempster-Shafer classifier fusion [J]. Engineering Applications of Artificial Intelligence, 2010, 23: 117-128.
- [10] 陈光武, 高亚丽, 焦相萌. 基于自适应变异 SAPSO-LSSVM 的轨道电路故障诊断[J]. 北京交通大学学报, 2021, 45(2):1-7.  
CHEN Guangwu, GAO Yali, JIAO Xiangmeng. Track circuit fault diagnosis based on adaptive mutation SAPSO-LSSVM[J]. Journal of Beijing Jiaotong University, 2021, 45(2):1-7.
- [11] GIBERT X, PATEL V M, CHELLAPPA R. Deep multitask learning for railway track inspection[J]. IEEE Transactions on Intelligent Transportation Systems, 2017, 18(1): 153-164.
- [12] STALLKAMP J, SCHLIPSING M, SALMEN J, et al. Man vs. computer: benchmarking machine learning algorithms for traffic sign recognition[J]. Neural Networks, 2012, 32: 323-332.
- [13] 郑云水, 牛行通, 康毅军. 蝙蝠算法优化模糊神经网络的 25 Hz 相敏轨道电路故障诊断研究[J]. 铁道学报, 2018, 40(12):93-100.  
ZHENG Yunshui, NIU Xingtong, KANG Yijun. Fault diagnosis research for 25 Hz phase sensitive track circuit based on bat algorithm to optimize fuzzy neural network[J]. Journal of the China Railway Society, 2018, 40(12):93-100.
- [14] 吴志鹏. 基于决策树算法的 ZPW-2000A 轨道电路故障诊断[D]. 成都:西南交通大学, 2016.  
WU Zhipeng. Fault diagnosis of ZPW-2000A track circuit based on decision tree algorithm[D]. Chengdu: Southwest Jiaotong University, 2016.
- [15] 孙浩洋. 基于数据驱动的 ZPW-2000A 轨道电路故障预测方法的研究[D]. 兰州:兰州交通大学, 2020.  
SUN Haoyang. Research on fault prediction method of ZPW-2000A track circuit based on data drive[D]. Lanzhou: Lanzhou Jiaotong University, 2020.
- [16] 贺帅超. 基于模糊神经网络的 25 Hz 相敏轨道电路故障诊断研究[D]. 兰州:兰州交通大学, 2016.  
HE Shuaichao. Fault diagnosis research of 25 Hz phase sensitive track circuit based on fuzzy neural network[D]. Lanzhou: Lanzhou Jiaotong University, 2016.
- [17] 王瑞峰, 臧浩月. 基于集对分析和隶属函数的轨道电路故障诊断[J]. 云南大学学报(自然科学版), 2021, 43(3): 470-476.  
WANG Ruifeng, ZANG Haoyue. Fault diagnosis of track circuit based on set pair analysis and membership function[J]. Journal of Yunnan University(Natural Sciences Edition), 2021, 43(3):470-476.
- [18] 牛行通. 基于蝙蝠算法的模糊神经网络 25 Hz 相敏轨道电路故障诊断研究[D]. 兰州:兰州交通大学, 2018.  
NIU Xingtong. Study on 25 Hz phase sensitive track circuit fault diagnosis of fuzzy neural network based on bat algorithm [D]. Lanzhou: Lanzhou Jiaotong University, 2018.
- [19] 朱文博. 基于改进决策树的轨道电路故障诊断方法研究[D]. 成都:西南交通大学, 2017.  
ZHU Wenbo. Research on fault diagnosis for track circuits based on improved decision tree[D]. Chengdu: Southwest Jiaotong University, 2017.
- [20] 田粉霞, 杨世武, 崔勇, 等. 基于改进卷积神经网络的无绝缘轨道电路调谐区故障诊断[J]. 铁路计算机应用, 2020, 29(6):58-63.

- TIAN Fenxia, YANG Shiwu, CUI Yong, et al. Fault diagnosis of tuning zone of jointless track circuit based on improved convolutional neural network[J]. *Railway Computer Application*, 2020, 29(6): 58–63.
- [21] 谢旭旭,戴胜华. 基于深度信念网络的无绝缘轨道电路故障诊断研究[D]. 北京:北京交通大学,2020.  
XIE Xuxu, DAI Shenghua. Research on fault diagnosis for jointless track circuit based on deep belief network[D]. Beijing: Beijing Jiaotong University, 2020.
- [22] 董煜. 基于改进证据理论的25 Hz轨道电路故障诊断方法研究[D]. 兰州:兰州交通大学,2019.  
DONG Yu. Research on fault diagnosis method of 25 Hz track circuit based on improved evidence theory[D]. Lanzhou: Lanzhou Jiaotong University, 2019.
- [23] 刘玉芝,高静巧. 铁路信号基础[M]. 成都:西南交通大学出版社, 2018.
- [24] SOLLA S A, LEEN T K, MÜLLER K R. The infinite Gaussian mixture model[C]//*Advances in Neural Information Processing Systems 12*. Boston, USA: MIT Press, 2000: 554–560.
- [25] DEMPSTER A P, LAIRD N M, RUBIN D B. Maximum likelihood from incomplete data via the EM algorithm[J]. *Journal of the Royal Statistical Society: Series B (Methodological)*, 1977, 39(1): 1–38.
- [26] AMARI S I. Backpropagation and stochastic gradient descent method[J]. *Neurocomputing*, 1993, 5(4/5): 185–196.
- [27] SUTSKEVER I, MARTENS J, DAHL G, et al. On the importance of initialization and momentum in deep learning[C]//*Proceedings of the 30<sup>th</sup> International Conference on Machine Learning*. Atlanta: Journal of Machine Learning Research (W&CP), 2013, 28:1139–1147.
- [28] 沈花玉,王兆霞,高成耀,等. BP神经网络隐含层单元数的确定[J]. *天津理工大学学报*, 2008, 24(5): 13–15.  
SHEN Huayu, WANG Zhaoxia, GAO Chengyao, et al. Determining the number of BP neural network hidden layer units[J]. *Journal of Tianjin University of Technology*, 2008, 24(5): 13–15.
- [29] HERNDON H, CARAGEA D. A study of domain adaptation classifiers derived from logistic regression for the task of splice site prediction[J]. *IEEE Transactions on Nanobioscience*, 2016, 15(2): 75–83.

## State judgement for track circuits based on machine learning

CHU Guangqian, LI Lu<sup>\*</sup>, ZHANG Jiachi, QIAN Jiayao

*School of Rail Transportation, Shandong Jiaotong University, Jinan 250357, China*

**Abstract:** In order to precisely judge the state of track circuit and guarantee the safe operation of rail traffic, the utilization of three typical machine learning algorithms, such as the gaussian mixed model (GMM) of unsupervised learning, the back propagation neural network (BPNN) and the logistic regression (LR) classification model of supervised learning are studied. The track circuits are divided into the occupancy state and idle state. GMM, BPNN, and LR are applied to accomplish the state classification. The classification performance of three machine learning algorithms is compared based on practical data. The results show that the three algorithms can achieve accurate classification of track circuit states. Compared with BPNN and LR, GMM require no training process, which can greatly reduce labor costs.

**Keywords:** track circuit; state classification; GMM; BPNN; LR classification model

(责任编辑:王惠)