DOI：10.13890/j.issn.1000-128X.2024.02.013

基于深度高斯过程的永磁牵引电机匝间短路分级评估方法

戴计生[1,2]，胡德安[1]，徐海龙[2]，朱文龙[2]，廖启术[2]
（1.湖南大学 机械与运载工程学院，湖南 长沙 410082；
2.株洲中车时代电气股份有限公司，湖南 株洲 412001）

摘　要：定子绕组匝间短路是影响永磁牵引电机安全稳定运行的主要故障之一，受运行工况、供电与电机本体不平衡的影响，现有方法难以实现永磁牵引电机匝间短路在线精准评估，这成为永磁电机推广应用迫切需要解决的关键技术难题。因此，文章提出一种基于多特征融合的深度高斯过程永磁牵引电机匝间短路分级评估方法：首先通过建立永磁牵引电机匝间短路故障模型，提取电流不平衡、电流三次谐波与 *dq* 电流的二次谐波特征；然后采用一种双随机变分推断深度高斯过程（Doubly Stochastic Deep Gaussian Processes, DSDGP）方法对提取特征进行融合训练建模，实现永磁牵引电机匝间短路劣化状态在线分级评估；最后通过永磁电机匝间短路试验与现场案例进行算法验证。结果表明，文章所提方法在多特征融合条件下的评估准确率达到95%以上，相较于支持向量机（support vector machine, SVM）和反向传播神经网络（back-propagation neural, BPN）等分类方法，具有准确率高，适用于变工况、小样本的工程实际应用环境等优点，解决了永磁牵引电机匝间短路早期故障检测及故障严重程度评估的行业难题。

关键词：永磁牵引电机；多维特征融合；匝间短路；分级评估；深度高斯过程

中图分类号：TM351　　**文献标志码：**A　　**文章编号：**1000-128X（2024）02-0108-10

0　引言

牵引系统是轨道交通车辆的“心脏”，绿色高效是轨道交通牵引系统发展的永恒目标，而永磁电机牵引系统具有损耗低、效率高、启动特性好、加速性能强、噪声低等显著优势，是牵引系统的发展方向[1]。在轨道交通运用环境下，永磁牵引电机存在运行温度变化范围宽、复杂轨面环境下负载冲击大的情况，且频繁工作于启/停、急加速、惰行、重投、急减速等工况，在电、磁、热、力等复合交变载荷长期作用下易出现机械、电气和永磁体等故障[2]。据统计，电气故障发生的概率更大[3]。牵引电机定子匝间短路故障是电气故障的主要类型，会随着故障发展最终导致永磁电机完全烧损，严重时还可能影响列车的运营秩序，带来生命财产损失[4]，因此及时地诊断永磁电机匝间短路故障具有重要的工程价值。

目前针对牵引电机匝间短路的故障诊断主要有基于机理模型、信号处理与数据驱动3类方法，其中基于机理模型的方法是通过建立牵引电机匝间短路机理模型，利用模型推理出合适阈值并与实际输出进行比对决策诊断故障[5]。文献[6]通过设计基于电流追踪算法的感应电压观测器，精确估计电机在不同运行点和故障严重程度下定子电阻改变时的反电动势，并与健康状态下的参考值进行比较来实现故障诊断。基于物理模型的方法在匝间短路特征提取及检测结果方面具有良好的可解释性，但在实际应用中通常需要设置一个较大的阈值，而电机匝间短路初期特征值较小，可能难

基金项目：国家重点研发计划项目(2022YFB4300600)；中国国家铁路集团有限公司科技研究开发计划（K2022J032）
通信作者：戴计生，男，博士，正高级工程师，主要从事轨道交通与新能源状态监测、故障诊断与预测方面的研究；E-mail: daijs@csrzic.com
引用格式：戴计生, 胡德安, 徐海龙, 等. 基于深度高斯过程的永磁牵引电机匝间短路分级评估方法[J]. 机车电传动, 2024(2): 108-117.DOI: 10.13890/j.issn.1000-128X.2024.02.013.
Citation：DAI Jisheng, HU Dean, XU Hailong, et al. Grading evaluation method for inter-turn short circuit of permanent magnet traction motor based on deep Gaussian processes[J]. Electric drive for locomotives,2024(2): 108-117.DOI:10.13890/j.issn.1000-128X.2024.02.013.

以触发阈值从而导致故障漏报。

基于信号处理的匝间短路诊断方法是通过信号处理的方法提取所选电机电压、电流等信号的故障特征进行诊断，常用信号处理方法以傅里叶变换、小波分析、盲源分离、经验模态分解等为主[7-9]。文献[10]通过电机定子电流经验模态分解得出一系列固有模态函数，采用二次时频分布提取故障特征，实现稳态条件下与暂态条件下的故障检测。在实际应用中永磁牵引电机采用 PWM（pulse width modulation）变频供电，由于受到速度力矩频繁变化的影响，牵引电机定子电流谐波相对于定频、正弦波供电的工业电机而言成分更加丰富，容易出现故障误报或漏报的情况。

随着人工智能的发展，与传统故障检测方法相比，基于数据驱动的方法展现出明显优势。文献[11-12]提出将神经网络运用到电机故障诊断，并有效提高了诊断准确率。文献[13]提出一种基于模糊逻辑的永磁电机故障检测方法，使用调整的负序电流来有效降低负载波动时的误报率。文献[14]提出一种基于支持向量机的牵引电机故障分类模型，通过试验验证了所提模型可以很好地识别牵引电机故障。文献[15]引入批量归一化算法提高神经网络泛化能力和诊断精确性，所提方法可精确地诊断出复杂工况下的永磁同步电机绕组故障。文献[16]通过构建优化卷积神经网络实现对电机超载、匝间短路及相间短路的非侵入式检测及分类。基于数据驱动的方法往往需要数据的支撑：一种是用作训练的历史数据，可通过试验仿真、现场数据积累等方式扩充；另一种是作为输入特征的特征量，这类数据往往较难获取。

考虑到这些方法的优势与局限性，本文提出一种基于DSDGP的永磁牵引电机匝间短路分级评估方法。DSDGP是一种非参数化的深度结构模型，与神经网络之类的参数化结构模型相比，采用DSDGP无须事先设定网络结构和参数，可以避免在训练过程中出现局部最优的情况，因此在少样本的场景下可以得到较为准确的故障分级分类结果。另外，考虑到输入特征维数对模型的影响，本文所提DSDGP分级评估模型将融合通过匝间短路模型提取的电流不平衡、三次谐波与 dq 电流二次谐波特征作为输入特征，以解决匝间短路早期故障检测与故障严重程度辨识的难题，大大减少了故障误报、漏报的概率。

1　永磁牵引电机匝间短路建模及其故障特征

正常的永磁牵引电机在三相坐标系下的电气方程为

$$\boldsymbol{V}_{\mathrm{uvw}}=\boldsymbol{R}_{\mathrm{s}}\boldsymbol{i}_{\mathrm{uvw}}+\frac{\mathrm{d}}{\mathrm{d}t}(\boldsymbol{L}_{\mathrm{s}}\boldsymbol{i}_{\mathrm{uvw}}+\boldsymbol{\lambda}_{\mathrm{PM,\,uvw}}) \tag{1}$$

式中：$\boldsymbol{V}_{\mathrm{uvw}}$为永磁牵引电机的三相电压，$\boldsymbol{V}_{\mathrm{uvw}}=[V_{\mathrm{u}}\ V_{\mathrm{v}}\ V_{\mathrm{w}}]^{\mathrm{T}}$；$\boldsymbol{R}_{\mathrm{s}}$为电机相电阻，$\boldsymbol{R}_{\mathrm{s}}=\begin{bmatrix}R_{\mathrm{s}}&0&0\\0&R_{\mathrm{s}}&0\\0&0&R_{\mathrm{s}}\end{bmatrix}$；$\boldsymbol{i}_{\mathrm{uvw}}$为电机的三相电流，$\boldsymbol{i}_{\mathrm{uvw}}=[i_{\mathrm{u}}\ \ i_{\mathrm{v}}\ \ i_{\mathrm{w}}]^{\mathrm{T}}$；$\boldsymbol{L}_{\mathrm{s}}$为电机相电感，$\boldsymbol{L}_{\mathrm{s}}=\begin{bmatrix}L&M&M\\M&L&M\\M&M&L\end{bmatrix}$，其中，$L$为永磁电机每相绕组的自感，$M$为永磁电机两相绕组的互感；$\boldsymbol{\lambda}_{\mathrm{PM,\,uvw}}$为永磁电机的三相永磁磁链，$\boldsymbol{\lambda}_{\mathrm{PM,\,uvw}}=[\boldsymbol{\lambda}_{\mathrm{PM,\,u}}\ \boldsymbol{\lambda}_{\mathrm{PM,\,v}}\ \boldsymbol{\lambda}_{\mathrm{PM,\,w}}]$，其中，$\boldsymbol{\lambda}_{\mathrm{PM,\,u}}$、$\boldsymbol{\lambda}_{\mathrm{PM,\,v}}$和$\boldsymbol{\lambda}_{\mathrm{PM,\,w}}$分别为永磁电机U、V、W三相的永磁磁链；$t$为时间。

当永磁电机发生匝间短路故障时，电机绕组内部简化示意图如图1所示。

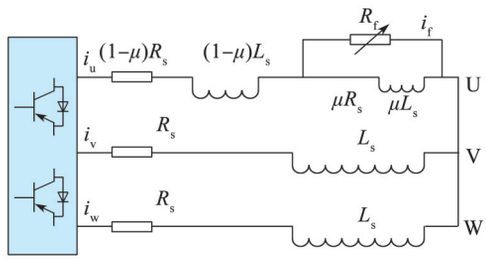


图1　永磁电机匝间短路故障等效示意图

Fig. 1　Schematic diagram of equivalent fault of inter-turn short circuit in permanent magnet motors

图1中，R_{f}为定子线圈中短路绕组的匝间等效绝缘电阻，i_{f}为短路线圈的环流。当R_{f}足够大时可认为电机无匝间短路故障；当$R_{\mathrm{f}}=0$时电机线圈彻底短路。忽略铁心磁饱和及其他非线性因素影响的电气方程[17]为

$$\boldsymbol{V}_{\mathrm{uvwf}}=\boldsymbol{R}_{\mathrm{sf}}\boldsymbol{i}_{\mathrm{uvwf}}+\frac{\mathrm{d}}{\mathrm{d}t}(\boldsymbol{L}_{\mathrm{sf}}\boldsymbol{i}_{\mathrm{uvwf}}+\boldsymbol{\lambda}_{\mathrm{PM,\,uvwf}})+\boldsymbol{V}_{0,\,\mathrm{uvwf}} \tag{2}$$

式中：$\boldsymbol{V}_{\mathrm{uvwf}}$与$\boldsymbol{i}_{\mathrm{uvwf}}$分别为匝间短路故障下永磁牵引电机的三相电压和三相电流，$\boldsymbol{V}_{\mathrm{uvwf}}=[\boldsymbol{V}_{\mathrm{u}}\ \ \boldsymbol{V}_{\mathrm{v}}\ \ \boldsymbol{V}_{\mathrm{w}}]^{\mathrm{T}}$，$\boldsymbol{i}_{\mathrm{uvwf}}=[\boldsymbol{i}_{\mathrm{u}}\ \ \boldsymbol{i}_{\mathrm{v}}\ \ \boldsymbol{i}_{\mathrm{w}}\ \ \boldsymbol{i}_{\mathrm{f}}]^{\mathrm{T}}$；$\boldsymbol{R}_{\mathrm{sf}}$与$\boldsymbol{L}_{\mathrm{sf}}$分别为匝间短路故障下永磁电机的三相等效电阻与电感，$\boldsymbol{R}_{\mathrm{sf}}=\begin{bmatrix}R_{\mathrm{s}}&0&0&-\mu R_{\mathrm{s}}\\0&R_{\mathrm{s}}&0&0\\0&0&R_{\mathrm{s}}&0\\\mu R_{\mathrm{s}}&0&0&-\mu R_{\mathrm{s}}-R_{\mathrm{f}}\end{bmatrix}$，$\boldsymbol{L}_{\mathrm{sf}}=\begin{bmatrix}L&M&M&-\mu L\\M&L&M&-\mu M\\M&M&L&-\mu M\\\mu L&\mu M&\mu M&-\mu^2 L\end{bmatrix}$，其中，$\mu$为被短路的线圈匝数占比；$\boldsymbol{\lambda}_{\mathrm{PM,\,uvwf}}$为匝间短路故障下永磁电机的永磁体磁链，$\boldsymbol{\lambda}_{\mathrm{PM,\,uvwf}}=[\boldsymbol{\lambda}_{\mathrm{PM,\,u}}\ \ \boldsymbol{\lambda}_{\mathrm{PM,\,v}}\ \ \boldsymbol{\lambda}_{\mathrm{PM,\,w}}\ \ \boldsymbol{\lambda}_{\mathrm{PM,\,f}}]$，其中，$\boldsymbol{\lambda}_{\mathrm{PM,\,f}}$为电机故障回路的磁链；$\boldsymbol{V}_{0,\,\mathrm{uvwf}}$为零序电压矩阵，$\boldsymbol{V}_{0,\,\mathrm{uvwf}}=[V_0\ \ V_0\ \ V_0\ \ 0]$。

由$\boldsymbol{R}_{\mathrm{sf}}$与$\boldsymbol{L}_{\mathrm{sf}}$可知匝间短路的永磁电机的三相等效电阻与电感值都出现不平衡，这会导致电机的三相电流值出现不平衡，因此可选取电机电流的不平衡特性作为永磁电机匝间短路劣化评估的第1个特征，不平衡特征的计算方法为

$$i_{\text{unbalance}}=\frac{\left(\max(\text{RMS}(i_{\text{u}}),\text{RMS}(i_{\text{v}}),\text{RMS}(i_{\text{w}}))-\min(\text{RMS}(i_{\text{u}}),\text{RMS}(i_{\text{v}}),\text{RMS}(i_{\text{w}}))\right)/2}{\left((\text{RMS}(i_{\text{u}})+\text{RMS}(i_{\text{v}})+\text{RMS}(i_{\text{w}})\right)/3} \tag{3}$$

式中：RMS(·)表示均方根函数。

对于星形联结的永磁电机绕组，有 $i_{\text{u}}+i_{\text{v}}+i_{\text{w}}=0$。因此，由式(2)可得

$$V_0=\frac{1}{3}\mu R_{\text{s}}i_{\text{f}}+\frac{1}{3}\mu(L+2M)\frac{\text{d}i_{\text{f}}}{\text{d}t}-\frac{\text{d}\lambda_{\text{PM},0}}{\text{d}t} \tag{4}$$

式中：$\lambda_{\text{PM},0}$为电机三相合成永磁磁链。

正常电机的故障电流 $i_{\text{f}}=0$，因此 V_0 仅取决于式(4)的最后一项，此时 $\lambda_{\text{PM},0}$ 计算公式为

$$\lambda_{\text{PM},0}=\frac{\lambda_{\text{PM,u}}+\lambda_{\text{PM,v}}+\lambda_{\text{PM,w}}}{3}=\sum_{n=1,3,5,\cdots}^{m=3n}\lambda_{\text{PM},m}\cos(m\theta-\theta_m) \tag{5}$$

式中：n 为每相磁链的谐波阶数；m 为 $\lambda_{\text{PM},0}$ 的谐波阶数；θ 为电角度；θ_m 为第 m 阶谐波与基波之间的相位差。

根据式(5)可知，在正常的永磁电机中，电流信号中3次及3次整数倍谐波由于幅值相同、相位一致，在中性线无通路情况下无法闭合，因而零序分量为0。但是当电机定子的某一相发生匝间短路故障时，将破坏电机的平衡关系，在匝间回路中产生局部回流，这会导致电机出现3n次的奇数谐波。与高次谐波相比，3次谐波的幅值一般较大，因此，本文选取电机电流的3次谐波作为永磁牵引电机匝间短路劣化评估的第2个特征。

正常永磁电机基于同步旋转 d-q 坐标系的电压方程为：

$$\left.\begin{aligned}V_d&=R_{\text{s}}i_d+\frac{\text{d}}{\text{d}t}(L_di_d)-\omega_{\text{e}}L_qi_q\\V_q&=R_{\text{s}}i_q+\frac{\text{d}}{\text{d}t}(L_qi_q)+\omega_{\text{e}}L_di_d+\omega_{\text{e}}\lambda_{\text{PM}}\end{aligned}\right\} \tag{6}$$

式中：V_d，V_q，i_d，i_q分别为电压、电流的d轴、q轴分量；L_d，L_q分别为d轴、q轴电感；ω_{e}为同步角速度；λ_{PM}为d-q坐标系下永磁体磁链。

根据正常情况下的d-q电压与式(6)，可得出电机出现匝间短路故障时的d-q电压V'_d与V'_q为：

$$\left.\begin{aligned}V'_d=&R_{\text{s}}i_d+\frac{\text{d}}{\text{d}t}(L_di_d)-\omega_{\text{e}}L_qi_q-\frac{2}{3}R_{\text{s}}\mu i_{\text{f}}\cos\theta-\\&\frac{2}{3}\omega_{\text{e}}L_q\mu i_{\text{f}}\sin\theta-\frac{2}{3}L_q\mu\frac{\text{d}}{\text{d}t}(i_{\text{f}})\cos\theta+\frac{2}{3}\omega_{\text{e}}L_q\mu i_{\text{f}}\sin\theta\\V'_q=&R_{\text{s}}i_q+\frac{\text{d}}{\text{d}t}(L_qi_q)+\omega_{\text{e}}L_di_d+\omega_{\text{e}}\lambda_{\text{PM}}+\frac{2}{3}R_{\text{s}}\mu i_{\text{f}}\sin\theta-\\&\frac{2}{3}\omega_{\text{e}}L_d\mu i_{\text{f}}\cos\theta+\frac{2}{3}L_q\mu\frac{\text{d}}{\text{d}t}(i_{\text{f}})\sin\theta+\frac{2}{3}\omega_{\text{e}}L_q\mu i_{\text{f}}\sin\theta\end{aligned}\right\} \tag{7}$$

根据文献[18]可知，出现匝间短路后的d-q电流i'_d与i'_q为：

$$\left.\begin{aligned}i'_d&=i_d-\frac{2}{3}\frac{\lambda_{\text{PM,u}}}{R_{\text{f}}}\mu^2\sin\theta\cos\theta=i_d-\frac{1}{3}\frac{\lambda_{\text{PM,u}}}{R_{\text{f}}}\mu^2\sin(2\theta)\\i'_q&=i_q-\frac{2}{3}\frac{\lambda_{\text{PM,u}}}{R_{\text{f}}}\mu^2\sin\theta\cos\theta=i_q-\frac{1}{3}\frac{\lambda_{\text{PM,u}}}{R_{\text{f}}}\mu^2\sin(2\theta)\end{aligned}\right\} \tag{8}$$

根据式(8)可知，匝间短路使d-q电压发生直流量的偏移，同时也引入了2次谐波。因此本文选取d-q电流的二次谐波作为永磁牵引电机匝间短路劣化识别的第3个特征。

通过建立永磁电机的匝间短路故障模型，提取了电机定子电流三相不平衡、三次谐波与d-q电流的二次谐波作为匝间短路劣化识别的故障特征。在轨道交通实际应用中，大部分工况下IGBT驱动的变频电机的转速均为时变，变化的转速会对控制模式产生影响，进而对本文提出的3个特征产生影响，因此要实现永磁电机匝间短路精准分级评估，避免出现误报漏报等事故的发生，单纯依靠设定各个故障特征阈值是无法实现的。因此本文提出一种基于数据驱动的永磁牵引电机匝间短路分级评估方法，该方法可通过融合提取的多个故障特征，对永磁牵引电机匝间短路劣化状态进行精确分级评估。

2 永磁牵引电机匝间短路分级评估方法

本章将构建一种基于DSDGP的永磁牵引电机匝间短路分级评估模型，它是一种非参数化的概率分布模型，可避免出现局部最优。首先搭建了基于稀疏高斯过程（sparse Gaussian process, SGP）的匝间短路分级评估模型，进而将网络结构叠加构成基于DSDGP的多层匝间短路分级评估模型。

2.1 基于SGP的分级评估方法

假设数据集$\{\boldsymbol{X},\boldsymbol{Y}\}$中有$N$组训练数据，其中：$\boldsymbol{X}=[x_1,x_2,\cdots,x_N]^{\text{T}}$和$\boldsymbol{Y}=[y_1,y_2,\cdots,y_N]^{\text{T}}$分别代表匝间短路模型的输入特征与牵引电机匝间短路劣化状态，则有

$$\boldsymbol{Y}=g(\boldsymbol{X})+\boldsymbol{\varepsilon} \tag{9}$$

式中：$\boldsymbol{\varepsilon}$为高斯白噪声，即$\boldsymbol{\varepsilon}\sim N(\boldsymbol{0},\sigma_n^2\boldsymbol{I})$，其中，$N(\cdot)$表示服从正态分布，$\sigma_n^2$代表高斯噪声的方差，$\boldsymbol{I}$为$N$维单位矩阵。

假设测试数据点为$\{x^*,g(x^*)\}$，则训练数据集与测试点之间存在关系

$$\begin{pmatrix}\boldsymbol{Y}\\g(x^*)\end{pmatrix}\sim N\left[\begin{pmatrix}\boldsymbol{0}\\\boldsymbol{0}\end{pmatrix},\begin{pmatrix}K(\boldsymbol{X},\boldsymbol{X})+\sigma_n^2\boldsymbol{I}&K(\boldsymbol{X},x^*)\\K(x^*,\boldsymbol{X})&K(x^*,x^*)\end{pmatrix}\right] \tag{10}$$

式中：$K(\cdot)$表示协方差函数。

高斯过程的训练复杂度为$O(N^3)$。SGP利用辅助输入$\boldsymbol{Z}=[z_1,z_2,\cdots,z_M]^{\text{T}}$和辅助输出$\boldsymbol{u}=[u_1,u_2,\cdots,u_M]^{\text{T}}$来降低训练复杂度，其中$M$表示辅助数据数量，且$M\ll N$。SGP的联合概率密度为

$$p(\boldsymbol{Y},\boldsymbol{f},\boldsymbol{u};\boldsymbol{X},\boldsymbol{Z})=p(\boldsymbol{Y}|\boldsymbol{f})p(\boldsymbol{f},\boldsymbol{u};\boldsymbol{X},\boldsymbol{Z}) \tag{11}$$

式中：$\boldsymbol{f}$为N维标准高斯过程无噪声的输出。

2.2　基于DGP的分级评估方法

稀疏高斯过程通过选取合适的核函数来拟合输入输出之间的关系，在实际中核函数较难确定，而深度结构的隐藏层可“自动调整”核函数以提升高斯过程的学习能力[19]。

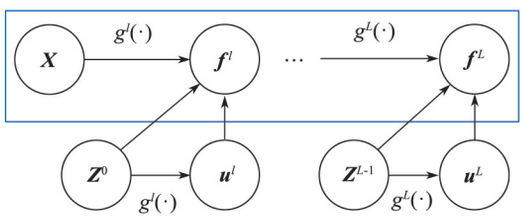


图2　深度高斯过程原理图

Fig. 2　Principle diagram of deep Gaussian process

图 2 为 1 个 L 层的深度高斯过程（deep Gaussian process, DGP），图中$\boldsymbol{f}^l$为SGP的无噪声输出，$\boldsymbol{Z}$为SGP引入的辅助输入，$\boldsymbol{u}^l$为SGP引入的辅助输出，$g^l(\cdot)$为第l层的SGP。因此，1个L层的DGP是由L个SGP组成的深度结构，$\boldsymbol{f}^l$在作为第l层输出的同时也作为第l+1层的输入，即

$$g^l(\boldsymbol{f}^{l-1})=\mathrm{GP}(\boldsymbol{0},\ K^l(\boldsymbol{f}^{l-1},\ \boldsymbol{f}^{l-1})) \tag{12}$$

式中：GP(·)指服从高斯过程分布。

第L层输出层的边缘似然函数为

$$q(\boldsymbol{f}^L)=\int\prod_{l=1}^{L-1}q(\boldsymbol{f}^l;\ \boldsymbol{f}^{l-1},\ \boldsymbol{Z}^{l-1})\,\mathrm{d}\boldsymbol{f}^l \tag{13}$$

在稀疏高斯过程中，可以通过最小化变分后验和真实后验之间的关系来优化参数，等价于最大化模型证据下界（Evidence Lower Bound，ELBO）来优化模型参数，DGP的ELBO为

$$L_{\mathrm{DGP}}\geqslant\lg p(\boldsymbol{Y})=\mathrm{E}_{q(\boldsymbol{f}^L)}\lg p(\boldsymbol{Y}|\boldsymbol{f}^L)-\sum_{l=1}^{L}\mathrm{KL}\left[q(\boldsymbol{u}^l)\|p(\boldsymbol{u}^l)\right] \tag{14}$$

式中：KL(·)为KL散度函数；L_{DGP}表示DGP的ELBO；E表示数学期望。

通过对ELBO进行优化可求解参数，具体为

$$\theta^{\mathrm{DGP}}=\{\{\boldsymbol{\mu}^l\}_{l=1}^{L},\{\boldsymbol{\Sigma}^l\}_{l=1}^{L},\{\boldsymbol{Z}^l\}_{l=0}^{L-1},\{\sigma_{\mathrm{ard}}^l\}_{l=1}^{L},\{\sigma_n^l\}_{l=1}^{L}\} \tag{15}$$

式中：θ^{DGP}表示DGP所有参数集合；$\boldsymbol{\mu}$表示变分后验的均值；$\boldsymbol{\Sigma}$表示变分后验的协方差；σ_{ard}表示核函数参数；σ_n表示高斯噪声参数。

求得所有参数后，在测试阶段，输入新的测试点x*即可得到输出$q(\boldsymbol{f}^{*L})$，即

$$q(\boldsymbol{f}^{*L})=\int\prod_{l=1}^{L-1}q(\boldsymbol{f}^{*l};\boldsymbol{f}^{*l-1},\boldsymbol{Z}^{*l-1})\,\mathrm{d}\boldsymbol{f}^{*l} \tag{16}$$

2.3　基于DSDGP的分级评估方法

SGP的稀疏过程会减少DGP模型每层内各个变量的相关性，导致求得的ELBO难以得到可解析的值，因此本文通过使用单变量高斯得到的边缘分布的无偏样本来对ELBO进行优化，即采用双随机深度高斯过程。

通过对DGP前$L-1$层的每层进行采样得到一次高斯白噪声$\boldsymbol{\xi}_i^l=N(\boldsymbol{0},\boldsymbol{I})$，然后结合采样的高斯白噪声对每层的边缘似然进行采样，即

$$\hat{\boldsymbol{f}}_i^l=\boldsymbol{m}(\hat{f}_i^{l-1})+\boldsymbol{\xi}_i^l\otimes\sqrt{\boldsymbol{S}(\hat{f}_i^{l-1},\hat{f}_i^{l-1})} \tag{17}$$

式中：$\hat{f}_i^l$表示对每层高斯过程输出f的重采样；$\boldsymbol{m}$表示每层边缘似然的均值；$\boldsymbol{S}$表示每层边缘似然的协方差；⊗表示内积。

在得到每层新的边缘分布$q(\hat{\boldsymbol{f}}^l)$后，结合输出层的边缘分布和ELBO即可优化模型参数。

通过对变分后验分布进行采样得到一个近似的后验期望，这是第一重随机；当要在大数据集下采用该方法时，需要使用小批量处理方法对训练数据进行再采样，这是第二重随机，因此该方法为双随机深度高斯过程。

在测试阶段，使用输出层采样后的变分分布即可得到测试结果，即

$$q(\boldsymbol{f}_*^L)=\frac{1}{K}\sum_{k=1}^{K}q(\boldsymbol{f}_*^L;\boldsymbol{f}_*^{(k)^{L-1}},\boldsymbol{Z}^{L-1}) \tag{18}$$

式中：$\boldsymbol{f}_*^L$表示测试样本的输出；K表示后验采样数。

3　试验与现场验证

3.1　永磁牵引匝间短路故障试验台

试验采用某型号匝间短路劣化状态永磁牵引电机，电机额定功率为192 kW，磁极对数为4，电机采用Y型接法，每相线圈采用双列并绕方式。试验时在电机某定子线圈的头端与尾部抽出线头，具体的引出位置如图3所示，试验制作的永磁匝间短路样机如图4所示。由图3可知，通过在U相槽两头尾线端抽出线头L_1与L_2，并在L_1与L_2之间外接不同阻值的电阻来模拟匝间短路故障从正常到严重的整个过程。具体的外接电阻阻值与对应的故障程度如表1所示。

试验采用两电机对拖的牵引传动试验台，具体如图5所示。通过被试电机与陪试电机配合，实现电机转矩的加载与速度的控制。在整个试验过程中，被试永磁电机转速在200 r/min到3 800 r/min范围内，以100 r/min的间隔进行速度控制，同时控制陪试电机力矩从空载、半载到满载输出，通过各转速与力矩组合进行试验。牵引控制单元DCU（driver control unit）实时采集电机电流、转速及中间电压等信号，基于这些信号进行分析，提取电机电流平衡特性、电流的三次谐波与d-q电流的二次谐波用于DSDGP模型训练，验证本文方法的有效性及识别精度。

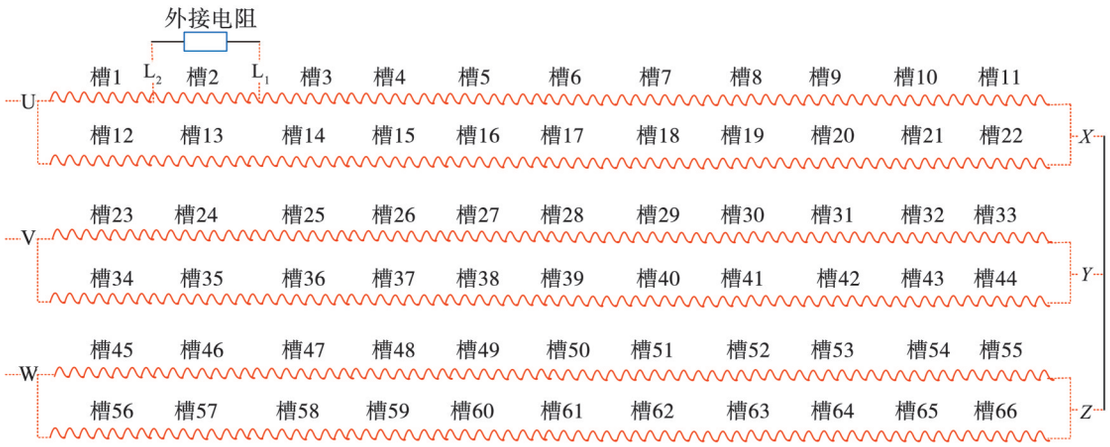


图3 永磁电机线圈抽头示意图

Fig. 3 Schematic diagram of coil tap of permanent magnet motor



图4 永磁电机匝间短路样机

Fig. 4 Prototype of permanent magnet motor inter-turn short circuit

表1 永磁电机抽头外接不同阻值与故障严重程度对应关系

Table 1 Correspondence between external resistance of permanent magnet motor tap and fault severity

短路电阻阻值	故障严重程度
无穷大（不接电阻，开路）	正常
外接1.50 Ω电阻	故障1
外接1.00 Ω电阻	故障2
外接0.50 Ω电阻	故障3
外接0.25 Ω电阻	故障4



图5 永磁电机匝间短路样机对拖试验台

Fig. 5 Towing test bench for prototype of permanent magnet motor inter-turn short circuit

3.2 匝间短路劣化状态分级分类试验

3.2.1 试验数据

电机试验数据包括空载、半载、满载3种工况下正常、故障1、故障2、故障3、故障4共5种故障等级。本节试验以原始特征量转速、A相电流有效值、B相电流有效值、C相电流有效值及电机短路模型所提取特征量（电流不平衡特性、电流三次谐波与*d*-*q*电流二次谐波）作为输入特征，以故障等级作为输出变量。在不同工况下，从5种不同故障等级的数据中随机选出150组数据作为训练集，选出20组数据作为测试集（训练集与测试集中的数据无交集），得到训练数据750组，测试数据100组。同时，采用SVM和BPN方法进行对比试验。

3.2.2 输入特征维度变化结果

在半载工况下验证不同输入特征维度对分级准确性的影响，具体如表2所示。

表2 不同输入特征维度的分类结果对比

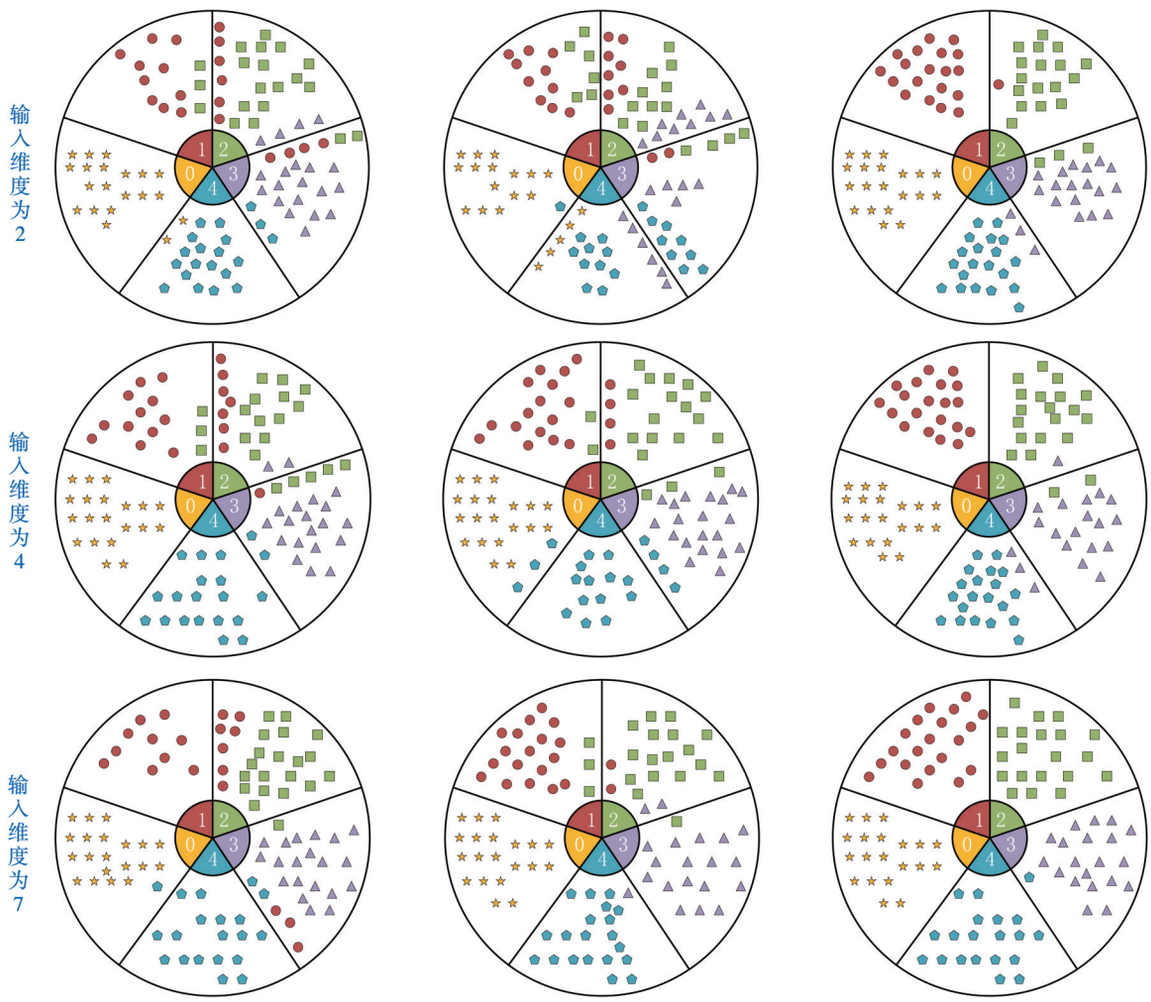
Table 2 Comparison of classification results under different input feature dimensions

输入维度	SVM		BPN		DSDGP	
	误判数	正确率	误判数	正确率	误判数	正确率
2	24	76%	50	50%	7	93%
3	21	79%	26	74%	7	93%
4	20	80%	16	84%	6	94%
5	18	82%	15	85%	4	96%
6	16	84%	13	87%	2	98%
7	14	86%	9	91%	1	99%

由表2可知，随着输入特征维度的增加，不同分类方法的正确率都逐渐增加。当只使用前4维实际测量的特征量时，3种模型的正确率均相对较低；随着后3维输入特征被使用，3种模型的正确率均得到提升。结果表明，采用本文模型所求得的特征量可以提升分类模型的正确率，有助于对牵引电机匝间短路劣化状态进行准确分级。

不同输入维度下的分级评估散点图如图6所示，可更直观地对比不同条件下的分级评估结果。图6中0~4

区域分别表示匝间短路劣化状态的5个等级，各区域中不同形状的散点表示采用本文方法针对100个测试样点所得到的分级结果。可以看出同一种评估方法随着输入维度的提升，其评估结果中各区域的散点图由散乱趋于统一。该图表明采用本文模型求得的输入特征可有效提升匝间短路分级评估的准确率。



(a) SVM　　(b) BPN　　(c) DSDGP

●故障1；■故障2；▲故障3；⬟故障4；★正常。

图6　不同输入维度下3种方法评估结果

Fig. 6　Evaluation results of three methods under different input dimensions

3.2.3　不同工况评估结果

在空载、半载、满载3种运行工况下进行分类试验，每种工况选取750组数据为训练集，100组数据为测试集，输入特征维度为7维，3种工况下的对比结果如表3所示。

表3　不同工况下的分类结果对比

Table 3　Comparison of classification results under different operating conditions

方法	空载		半载		满载	
	误判数	正确率	误判数	正确率	误判数	正确率
SVM	12	88%	14	86%	14	86%
BPN	15	85%	9	91%	12	88%
DSDGP	5	95%	1	99%	4	96%

由表3可知，在3种不同工况下，本文所提方法的准确率最高，且均不低于95%。SVM是一种二分类算法，在解决二分类问题时往往具有较好的表现，本文属于多分类场景，因此SVM分类准确率较差；BPN是一种参数化模型，在训练过程中存在局部最优、过拟合等问题，会对分类结果产生影响；DSDGP是一种求解从输入到输出的概率分布的过程，因此没有过多的参数求解，也可避免过拟合现象，在实际应用中表现更优。

半载工况时3种方法在不同故障等级下的分类效果对比如图7所示，图7可更直观地对比分类结果。

在某种故障等级下，假设该种故障标签为1（即期望输出为1），其他类型故障标签为0。将100组测试样本依次每20个分为1组，分别对应5种故障等级。由图

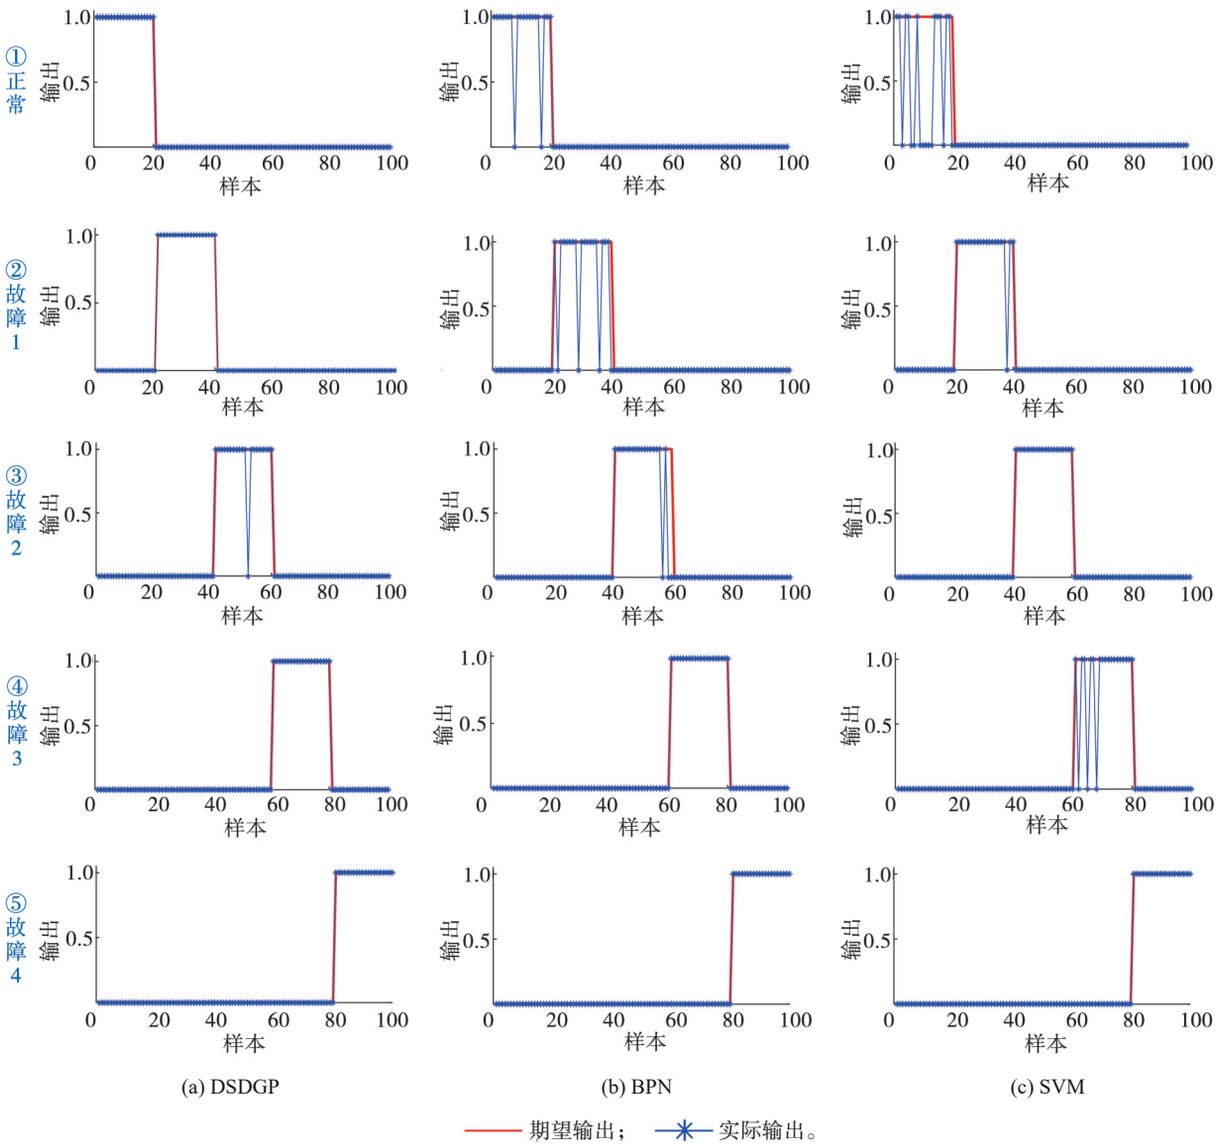


图7　3种方法在不同故障等级下的分类结果

Fig. 7　Classification results of 3 methods under different fault grades

7可知，DSDGP的实际输出与期望输出基本一致，准确率远高于BPN与SVM。

综合表3与图7的对比结果可知，在不同运行工况下，DSDGP均可保持较高的准确率，在3种工况下的平均准确率达到96.7%；在同一种运行工况下，DSDGP在分类难度较大的低严重程度故障类型中依然可以保持较高的准确率。

3.2.4　训练集大小影响结果

在机器学习中，对一个结构固定模型的准确率影响最大的是训练样本的多少。为了研究训练集大小对分类结果的影响，本节通过对比试验研究了在不同训练集大小条件下分类模型的效果，试验以半载工况为例，训练集输入特征为7维，测试样本共100组。3种方法在不同训练样本数下的分类准确率如图8所示，图8中，横坐标5×50是指训练集中包含5种类型故障，每种50组数据。

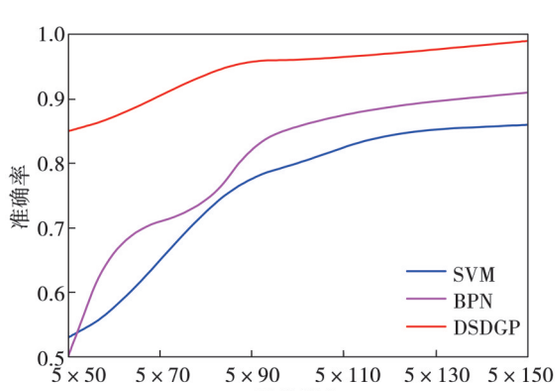


图8　3种方法在不同训练样本数下的分类准确率

Fig. 8　Classification accuracy of 3 methods under different training sample sizes

由图8可知，在不同规模的训练集下，DSDGP的准确率都远高于BPN与SVM。特别是在训练数据较少时，SVM与BPN仅有50%左右的分类准确率，而

DSDGP 可以达到 85% 以上，说明本文所提方法在小样本下依然可以保持较高的准确率，具有较好的应用前景。

3 种方法在不同训练样本数下的分级评估散点图如图 9 所示，通过图 9 可更直观地对比不同训练样本数的影响。

由图 9 可知，在训练样本数相同时，DSDGP 各分级区域内的散点更为统一，尤其在训练样本数较少时，DSDGP 的集中趋势明显优于另外 2 种方法，验证了本文所提方法的分级评估效果相对优异，可以得到较为准确的分级评估结果。

另外，由图 8 和图 9 可知，3 种方法的分类准确率均随训练样本的增多而变高，说明训练样本数量对 3 种方法的影响均较大，因此，在实际应用中，需要通过仿真试验或现场运用积累足够的数据量来提高模型的准确率。

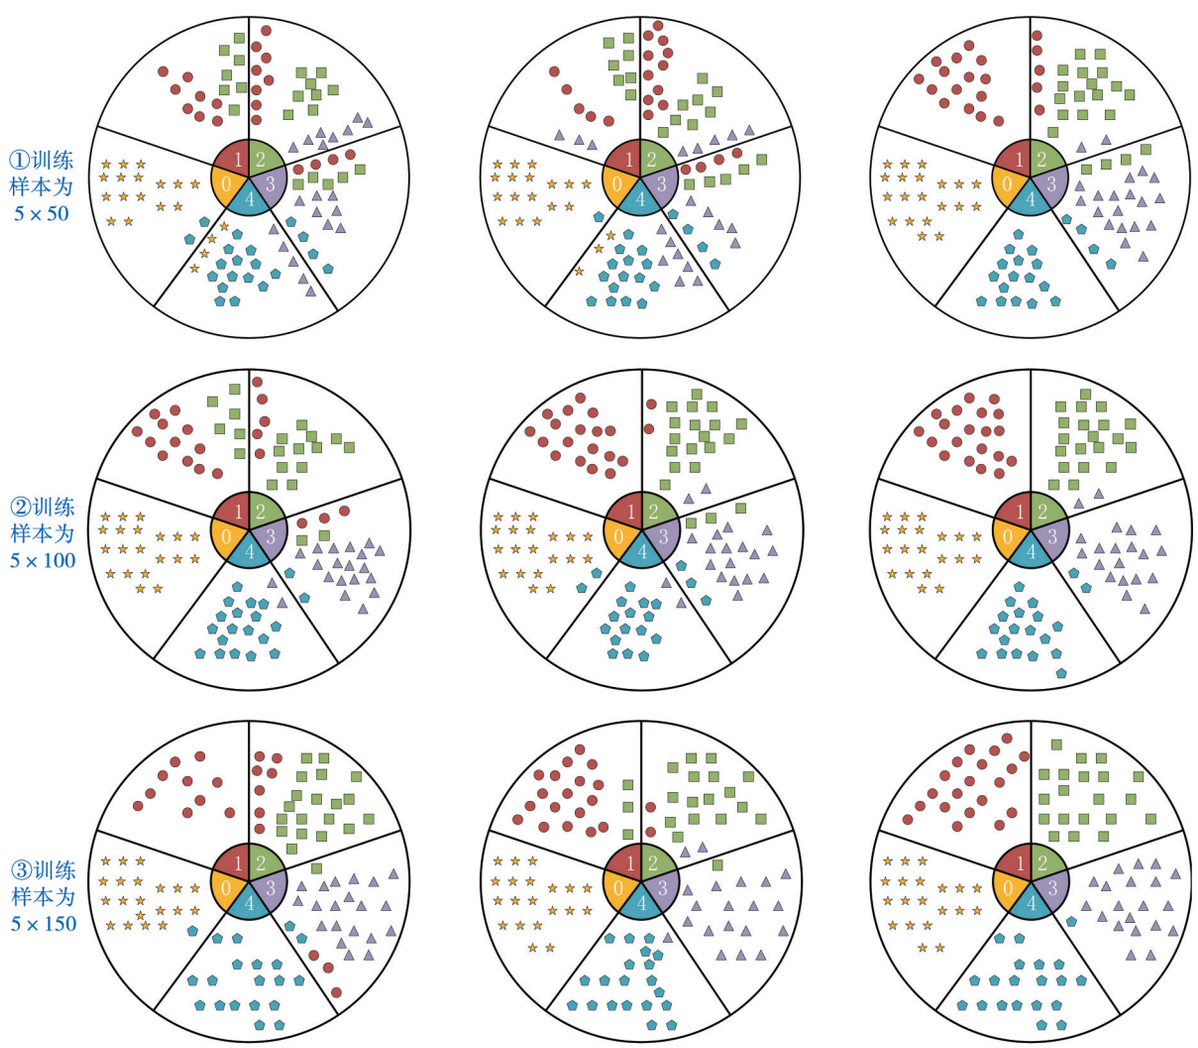
综上可知，本文采用匝间短路模型所求得的特征量有助于提升各种分类模型的准确率，且本文所提分类方法在不同工况下均能得到准确的结果。

3.3　现场验证

为进一步验证本文所提方法，进行了现场验证。

某型号的永磁电机在列车现场运行时，出现 2 起电机绝缘故障：2016 年 9 月 24 日，列车报牵引变流器过流故障；2020 年 8 月 23 日，列车报主电路接地故障。通过对上述 2 次故障时刻前后所记录的故障实时数据进行分析，提取了电机电流不平衡、电流三次谐波与 *d*-*q* 电流的二次谐波特征输入到训练好的 DSDGP 模型中，得到故障等级的评估结果为故障 4，即匝间短路故障的最严重程度。

之后，对故障电机进行拆解，情况如图 10 所示。由图 10 可知，电机定子线圈均发生严重线圈短路故障，这进一步验证了本文所提方法的有效性。



(a) SVM　　(b) BPN　　(c) DSDGP

故障1；　故障2；　故障3；　故障4；　正常。

图 9　不同输入维度下 3 种方法评估结果

Fig. 9　Evaluation results of 3 methods under different input dimensions



图 10　永磁牵引电机故障拆解图

Fig. 10　Dismantling diagram of permanent magnet traction motor for faults detection

4　结语

永磁牵引电机定子绕组匝间短路故障是影响永磁牵引电机推广与应用急需解决的关键难题之一，本文提出了一种基于多特征融合的DSDGP永磁牵引电机匝间短路分级评估方法，首先通过建立永磁牵引电机匝间短路故障模型，提取电机电流不平衡、电流3次谐波与 *d-q* 电流的2次谐波的匝间短路特征作为输入，然后对DSDGP的永磁牵引电机匝间短路分级评估模型进行训练。最后通过搭建永磁牵引电机匝间短路劣化发展过程的试验台，以及诊断评估永磁电机现场绝缘故障案例，验证了本文提出的DSDGP方法在多特征融合条件下，可实现永磁牵引电机匝间短路评估准确率95%以上。与SVM与BPN相比，本文方法准确率高，更适用于永磁电机现场工况多变、少故障样本的情况。本文提出多特征融合的DSDGP方法进行分级评估，充分利用了基于模型、数据驱动及信号处理等故障诊断方法的优势，实现永磁牵引电机匝间短路早期故障预警与匝间短路状态的分级评估，降低了实际应用中绝缘问题导致的安全风险，保障了永磁牵引列车运行的稳定性与安全性。

参考文献：

[1] 冯江华. 轨道交通永磁电机牵引系统关键技术及发展趋势[J]. 机车电传动, 2018(6): 9-17.
FENG Jianghua. Key technology and development trend of permanent magnet motor traction system for rail transit[J]. Electric drive for locomotives, 2018(6): 9-17.

[2] 田春春. 城市轨道交通车辆永磁牵引系统应用研究[J]. 交通世界, 2021(增刊2): 23-24.
TIAN Chunchun. Application research on permanent magnet traction system for urban rail transit vehicles[J]. Transpo world, 2021(Suppl 2): 23-24.

[3] 柯思勤. 永磁电机故障诊断和容错技术概述[J]. 大功率变流技术, 2017(2): 11-16.
KE Siqin. Review on fault diagnosis and fault tolerant control for permanent magnet electrical machines[J]. High power converter technology, 2017(2): 11-16.

[4] 吴国沛, 余银犬, 涂文兵. 永磁同步电机故障诊断研究综述[J]. 工程设计学报, 2021, 28(5): 548-558.
WU Guopei, YU Yinquan, TU Wenbing. Review of research on fault diagnosis of permanent magnet synchronous motor [J]. Chinese journal of engineering design, 2021, 28(5): 548-558.

[5] 张周磊, 李垣江, 李梦含, 等. 基于深度学习的永磁同步电机故障诊断方法[J]. 计算机应用与软件, 2019, 36(10): 123-129.
ZHANG Zhoulei, LI Yuanjiang, LI Menghan, et al. Fault diagnosis method of permanent magnet synchronous motor based on depth learning[J]. Computer applications and software, 2019, 36(10): 123-129.

[6] SARIKHANI A, MOHAMMED O A. Inter-turn fault detection in PM synchronous machines by physics-based back electromotive force estimation[J]. IEEE transactions on industrial electronics, 2013, 60(8): 3472-3484.

[7] LIANG Hong, CHEN Yong, LIANG Siyuan, et al. Fault detection of stator inter-turn short-circuit in PMSM on stator current and vibration signal[J]. Applied sciences, 2018, 8 (9): 1677.

[8] MOOSAVI S S, ESMAILI Q, DJERDIR A, et al. Inter-turn fault detection in stator winding of PMSM using wavelet transform[C]//IEEE. 2017 IEEE Vehicle Power and Propulsion Conference. Belfort: IEEE, 2017: 1-5.

[9] SIDDIQUI K M, BAKHSH F I, AHMAD R, et al. Advanced signal processing based condition monitoring of PMSM for stator-inter turn fault[C]//IEEE. 2021 IEEE 8th Uttar Pradesh Section International Conference on Electrical, Electronics and Computer Engineering. Dehradun: IEEE, 2021: 1-4.

[10] ROSERO J A, ROMERAL L, ORTEGA J A, et al. Short-circuit detection by means of empirical mode decomposition and wigner – ville distribution for PMSM running under dynamic condition[J]. IEEE transactions on industrial electronics, 2009, 56(11): 4534-4547.

[11] 王红君, 刘冬生, 岳有军. 基于小波分析和神经网络的电机故障诊断方法研究[J]. 电气传动, 2010, 40(3): 69-73.
WANG Hongjun, LIU Dongsheng, YUE Youjun. Study of the fault diagnosis method based on wavelet time and frequency analysis and the neural network in the motor[J]. Electric drive, 2010, 40(3): 69-73.

[12] QUIROGA J, CARTES D A, EDRINGTON C S, et al. Neural network based fault detection of PMSM stator winding short under load fluctuation[C]//IEEE. 2008 13th International Power Electronics and Motion Control Conference. Poznan: IEEE, 2008: 793-798.

[13] QUIROGA J, LIU Li, CARTES D A. Fuzzy logic based fault detection of PMSM stator winding short under load

fluctuation using negative sequence analysis[C]//IEEE. 2008 American Control Conference. Seattle, WA: IEEE, 2008: 4262-4267.

[14] 张坤鹏, 李昊, 安春兰, 等. 融合能量熵编码和分类模型的牵引电机故障诊断[J]. 铁道学报, 2023, 45(9): 64-73.
ZHANG Kunpeng, LI Hao, AN Chunlan, et al. Fault diagnosis of traction motor based on fusion of energy entropy coding and classification model[J]. Journal of the China railway society, 2023, 45(9): 64-73.

[15] 刘蔚, 李万铨, 王明峤, 等. 复杂工况下的永磁同步电机典型绕组故障在线诊断[J]. 电工技术学报, 2024, 39(6): 1764-1776.
LIU Wei, LI Wanquan, WANG Mingqiao, et al. Online diagnosis of typical winding faults in permanent magnet synchronous motors under complex working conditions[J]. Transactions of China electrotechnical society, 2024, 39(6): 1764-1776.

[16] 刘琦昊, 许盛之, 俞梅, 等. 基于神经网络的非侵入式电机故障检测方法[J]. 科学技术与工程, 2022, 22(6): 2326-2333.
LIU Qihao, XU Shengzhi, YU Mei, et al. A non-intrusive motor fault detection method based on convolutional neural network[J]. Science technology and engineering, 2022, 22 (6): 2326-2333.

[17] HANG Jun, ZHANG Jianzhong, CHENG Ming, et al. Online interturn fault diagnosis of permanent magnet synchronous machine using zero-sequence components[J]. IEEE transactions on power electronics, 2015, 30(12): 6731-6741.

[18] FANG Jie, SUN Yining, WANG Yibing, et al. Improved ZSVC-based fault detection technique for incipient stage inter-turn fault in PMSM[J]. IET electric power applications, 2019, 13(12): 2015-2026.

[19] DAMIANOU A. Deep Gaussian processes and variational propagation of uncertainty[D]. Sheffield: University of Sheffield, 2015.

Grading evaluation method for inter-turn short circuit of permanent magnet traction motor based on deep Gaussian processes

DAI Jisheng[1,2], HU Dean[1], XU Hailong[2], ZHU Wenlong[2], LIAO Qishu[2]

(1. College of Mechanical and Vehicle Engineering, Hunan University, Changsha, Hunan 410082, China;
2. Zhuzhou CRRC Times Electric Co., Ltd., Zhuzhou, Hunan 412001, China)

Abstract: The inter-turn short circuit of stator winding is one of the main faults affecting the safe and stable operation of permanent magnet traction motors. Affected by operating conditions, power supply and motor body imbalance, existing methods are difficult to achieve online accurate evaluation of inter-turn short circuit of permanent magnet traction motors. This has become a key technical problem that urgently needs to be solved for the widespread application of permanent magnet motors. Therefore, this paper proposed a grading evaluation method for inter-turn short circuit in permanent magnet traction motors based on multi-feature fusion of deep Gaussian processes. Firstly, by establishing a fault model for inter-turn short circuit in permanent magnet traction motors, features such as current unbalance, third harmonic currents and second harmonic feature of *dq* currents were extracted. Then, a doubly stochastic deep Gaussian processes (DSDGP) method was adopted to fuse and train the extracted features, achieving online grading evaluation of inter-turn short circuit degradation in permanent magnet traction motors. Finally, the algorithm was validated through permanent magnet motor inter-turn short circuit tests and field cases. The results show that the proposed method achieves an evaluation accuracy of over 95% under the condition of multi-feature fusion. Compared with classification methods such as support vector machine (SVM) and back-oropagation neural network (BPN), it exhibits high accuracy and suitability for engineering practical environments with variable operating conditions and small samples, addressing industry challenges in early fault detection and severity evaluation of inter-turn short circuits in permanent magnet traction motors.

Keywords: permanent magnet traction motor; multi-feature fusion; inter-turn short circuit; graded evaluation; deep Gaussian processes

收稿日期：2023-09-01；修回日期：2024-02-05