

基于整车 EMC 标准测试和机器学习的反向诊断方法



雷剑梅^{1,2} 曾令秋^{1,3} 牟洁² 陈立东¹ 王淙¹ 柴勇²

1 汽车噪声振动和安全技术国家重点实验室 重庆 400044

2 重庆大学汽车工程学院 重庆 400044

3 重庆大学计算机学院 重庆 400044

(leijianmei@caeri.com.cn)

摘要 智能汽车的快速发展促使电磁兼容(Electromagnetic Compatibility, EMC)测试技术得以完善,同时也给车辆 EMC 设计带来了新的挑战,而面向测试数据的故障排查有利于车辆 EMC 的设计。随着电子系统复杂性的提升,车载系统设计人员面临着越来越多的电磁兼容故障可能性,因此需要更为有效的 EMC 故障诊断方法。然而,由于 EMC 测试数据集具有样本小、非线性、高维等特点,致使 EMC 故障诊断难度较大。鉴于此,结合 EMC 测试工程师多年的整改经验,文中提出了一种关于电磁兼容测试数据的特征提取算法,并利用从测试数据中提取出的有价值的特征数据,搭建了支持向量机二分类模型,实现了 EMC 故障分类,并展示了相应的应用效果。为了验证所提方法的有效性,采用朴素贝叶斯分类模型进行对比,实验结果表明,所提方法能够满足智能汽车 EMC 故障诊断的需求。

关键词: 测试数据;EMC;特征提取;支持向量机;故障诊断;朴素贝叶斯

中图法分类号 TP206+.3;TP181

Reverse Diagnostic Method Based on Vehicle EMC Standard Test and Machine Learning

LEI Jian-mei^{1,2}, ZENG Ling-qiu^{1,3}, MU Jie², CHEN Li-dong¹, WANG Cong¹ and CHAI Yong²

1 State Key Laboratory of Vehicle NVH and Safety Technology, Chongqing 400044, China

2 School of Automotive Engineering, Chongqing University, Chongqing 400044, China

3 College of Computer Science, Chongqing University, Chongqing 400044, China

Abstract The rapid development of intelligent vehicles not only improves electromagnetic compatibility(EMC) testing technology, but also brings new challenges to vehicle EMC design, which is benefited from test data-oriented troubleshooting. With the increase in electronic complexity, vehicle on-board system designers should confront with more and more EMC failure possibilities and they are in need of effective EMC failure diagnosis approach. However, EMC fault diagnosis is difficult due to the distinguishing features of EMC test dataset, such as small sample, nonlinear, high dimensions, etc. In view of this situation, this paper puts forward a feature extraction algorithm for electromagnetic compatibility test data based on years of rectification experience of EMC test engineers, and uses the valuable feature data extracted from the test data to set up a support vector machine(SVM) two classification model. Corresponding application effect is displayed. In order to verify the effectiveness of the proposed method, this paper adopts the naive Bayesian classification model for comparison. The experimental results show that the proposed method can match the demand of EMC fault diagnosis for intelligent vehicles.

Keywords Test data, Electromagnetic compatibility, Feature extraction, Support vector machine, Fault diagnosis, Naive Bayes

1 引言

随着智能汽车的不断发展,车载系统越来越复杂,车辆上配备了多种电子设备以提供智能应用,如全球定位系统(Global Position System, GPS)、车对车(Car-to-Car, C2C)、远程无钥匙(Remote Keyless Entry, RKE)进入等^[1]。因此,车辆内外都充满了不同频率的电磁波,这给车辆及相应部件的

EMC 设计带来了巨大的挑战。人们希望车载设备和系统能在电磁环境中良好地发挥作用,而不会给环境中的任何物体带来不可容忍的电磁干扰。也就是说,随着工作频率点的增加,EMC 问题变得更加复杂。因此在某种程度上智能汽车可以被看作一个复杂的电子系统,其 EMC 问题极其突出。显然,汽车电子系统越复杂,故障诊断就越困难。

不可否认的是,汽车故障诊断是汽车领域的重要研究课

到稿日期:2020-07-31 返修日期:2020-09-17 本文已加入开放科学计划(OSID),请扫描上方二维码获取补充信息。

基金项目:汽车噪声振动和安全技术国家重点实验室 2019 年度开放基金(NVH SKL-201913);国家自然科学基金(61601066)

This work was supported by the Open Research Fund of State Key Laboratory of Vehicle NVH and Safety Technology(NVH SKL-201913) and National Natural Science Foundation of China(61601066).

通信作者:曾令秋(zenglq@cqu.edu.cn)

题^[2]。在过去的 50 年中,学术界和行业界提供了各种解决方案,例如专家系统、故障树和知识表示等^[3],但由于电子元件的复杂化,车辆系统存在许多故障可能性,这将给故障诊断带来巨大挑战,进而影响新产品的研发。

智能汽车 EMC 故障诊断存在的主要问题有两个方面:1)原始数据集的质量和数量;2)对应算法的合理性和可行性。

一般来说,电磁兼容测试中发生故障的原始数据量非常有限,例如,中国汽车工程研究院(China Automotive Engineering Research Institute,CAERI)提供的原始数据集仅包含 1 000 条记录。其中,大多数数据没有故障排除记录,而带有故障排除记录的数据始终呈现非线性和不稳定的特征。因此,在模型设计中应考虑上述所有因素。

故障诊断的关键是找到测试数据与故障源之间的关系。显然,机器学习方法是一个很好的解决方案。人工神经网络(Artificial Neural Network,ANN)^[4]是解决复杂非线性问题的有效方法。但是,传统的数据挖掘方法,如深度信任网络(Deep Belief Network,DBN)^[5]、数据库中的知识发现(Knowledge Discovery in Database,KDD)^[6]、神经网络^[7]等,仅适用于大样本情况,不适用于 EMC 故障诊断。

人工免疫系统(Artificial Immune System,AIS)是受生物免疫系统的启发,用于解决计算机领域问题的新兴算法,在小样本故障领域得到了广泛应用,但总体而言在机械故障诊断的应用上还处在发展阶段^[8-9]。此外,最小二乘法也广泛用于小样本的故障诊断,线性最小二乘法能很好地解决线性最小二乘问题,而非线性最小二乘问题则复杂得多。

近年来,在小样本故障诊断领域,研究者们热衷于对支持向量机(Support vector machine,SVM)方法进行研究。文献[10]提出了一种配电网故障诊断系统,该系统采用 SVM、朴素贝叶斯(Naive Bayes)、支持向量回归(Support Vector Regression,SVR)和高斯过程回归(Gaussian Process Regression,GPR)等方法诊断各种系统故障。文献[11]提出了一种监督朴素贝叶斯分类器来构建检测供电系统异常的数据驱动模型。文献[12]为传输线网络故障检测、定位和分类提供了一种新的机器学习算法,还比较了决策树、SVM 和 K-Nearest Neighbor(KNN)算法的性能。文献[13]指出,针对小样本的发动机性能参数故障数据,SVM 在进行故障诊断时具有诸多优点;与此同时,针对单一核函数难以选择最优的问题,其提出了多核学习 SVM 方法。此外,文献[14]提出将核主成分分析方法与粒子群优化算法相结合来优化 SVM 模型,大幅提高了诊断精度。文献[15]提出了概率模糊 c 均值聚类人工蜂群支持向量机(Possibilistic Fuzzy C-means Clustering Artificial Bee Colony Support Vector Machine,PFCM-ABC-SVM)方法,其可以在动态条件下过滤高斯噪声数据,且在解决小型、非线性、高维等问题时效果较好。

鉴于支持向量机能够解决小样本、非线性和高维的分类问题,本文提出了一种基于支持向量机的电磁兼容故障诊断方法。首先,根据测试记录建立电磁兼容异常数据映射模型;然后,建立异常现象与车辆故障源之间的对应关系;最后,建立车辆 EMC 反诊断系统。

本文第 2 节提出了一个数据特征提取算法;第 3 节讨论了基于 SVM 的小样本故障分类;第 4 节在所提算法的基础

上构建了 SVM 分类模型,将其与朴素贝叶斯进行了对比实验,并对实验结果进行了分析;最后总结全文。

2 特征提取

2.1 原始数据基础

2.1.1 数据源

本文使用的原始数据由中国重庆 CAERI 公司 EMC 测试部门提供,主要是基于 GB14023 和 GB/T18387 标准下的测试数据。原始数据包括 1 000 个 EMC 测试记录,其中 119 个有故障排除记录。所有测试曲线均由数据分析软件 EMC32 生成,如图 1 所示。




图 1 测试曲线
Fig. 1 Test curve

图 1 中,箭头 1 所指曲线为标准极限,箭头 2 所指曲线为试验曲线。如果测试值超过测试标准的规定限值,被测设备就不能通过 EMC 测试,也就是本文所研究的 EMC 故障。一般而言,EMC 测试的最大失效概率是辐射发射超过规范的限值。

EMC 测试人员根据测试曲线生成 EMC 测试报告,这些报告仅表明试验件是否合格,并不包括故障排查结果。

此外,EMC32 软件也可以得到测试数据的 excel 表格形式,如图 2 所示。

Result Table

图 2 原始测试数据
Fig. 2 Raw test data

表格中包含测试项目的相关信息,如测试频率、测试幅值、天线高度、天线的极化方式等。测试输出有平均值、峰值和准峰值 3 种类型,有的测试项目包含 3 种测试值类型,而有些测试项目只包含其中 1 种或者 2 种。

2.1.2 EMC 骚扰源

对于智能汽车而言,存在各种各样的电磁兼容骚扰源,如 DCDC(Direct Current)、点火系统、仪表板等,各种骚扰源的影响都可以用测试曲线来表示。因此,本文认为可以基于测试曲线特征分析来实现反向故障诊断。

2.2 测试曲线特征分析

2.2.1 测试曲线特征

EMC 测试曲线主要有包络和尖峰两种类型,其中尖峰类型又可分为单点尖峰和谐波类型。此测试曲线类型的详细定义如下。

1) 包络:在某一测试频带内频谱幅值随频率缓慢变化,则此频段测试曲线类型为包络。

2) 尖峰:在某一测试频带内频谱幅值发生突变,则此频段测试类型为尖峰。其中大量连续且等间隔出现的尖峰为谐波类型,否则为单点尖峰类型。

2.2.2 特征提取

如上文所述,我们认为可以基于测试曲线特征分析来实现反向故障诊断,但是如何从这些数据中提取出有利于 EMC 故障诊断的特征,是本文研究的重点。

目前主流的特征提取技术有主成分分析法、基于遗传算法的特征提取等。其中主成分分析法^[16]在统计学中是对数据集进行降维简化的统计方法,它基于统计特征,是一种多维度的线性变换,用途较广。基于遗传算法的特征提取是对自然进化过程进行模拟,从中寻找最优解的过程。当特征空间比较复杂时,该方法不一定能得到想要的效果,且效率较低。

鉴于当前对于 EMC 的故障诊断大都基于 EMC 测试工程师的工作经验,而且测试数据中有利于故障诊断的特征已经较为明确,因此本文结合 EMC 测试工程师的相关经验,针对 EMC 测试数据的分布和特性,设计并提出了一种有利于 EMC 故障诊断的特征提取算法。

为了更好地理解 EMC 测试曲线的特征,将图 1 所示的测试曲线进行局部放大,如图 3 所示。




图 3 测试曲线局部放大图

Fig. 3 Test data curve expansion diagram

从图 3 可以看出,测试曲线基本都呈现“小山峰”的形状。因此,特征提取的关键是找出“小山峰”的峰和谷点,峰、谷点的计算公式如下:

$$\min \left(\frac{\text{Value}(P_i) - \text{Value}(V_j)}{F(P_i) - F(V_j)}, \frac{\text{Value}(P_i) - \text{Value}(V_{j+1})}{F(V_{j+1}) - F(P_i)} \right) > Th1,$$

$$i=1,2,\cdots,|P|;j=1,2,\cdots,|V| \tag{1}$$

其中, P 是峰值点, V 是谷点。

算法 1 给出了本文设计的 EMC 测试数据特征提取算法的流程,相应的变量和函数说明如表 1 所列。

算法 1 EMC 测试数据特征提取算法

```
输入:(D,L)
输出:(A)

1. set A=cell(3,2)/ * 存储特征数据 * /
2. A{1,1}='harmonicwave'
3. A{2,1}='SinglepIntpike'
4. A{3,1}='envelope'
5. for Data in D do
6.   if isoverLimitline(Data)==TRUE then
7.     Fover=Data
8.   end if
9. end for
10. split_Fre(Fover)split
11. for Dataover in Fover do
12.   if isHarmonictype(Dataover)==TRUE then
13.     A{1,2}=Dataover
14. else if isSingle Peaktype(Dataover)==TRUE then
15.   A{2,2}=Dataover
16.   else
17.     A{3,2}=Dataover
18.   end if
19. end for
20. A{3,2}=merge(A{3,2})
```

表 1 变量和函数解释说明

Table 1 Explanation for variables and functions

变量/函数	说明
D	测试数据集
L	限值集
A	特征数据集
Data	测试数据点,包括频率和振幅
<i>isoverLimitLine(X)</i>	确定测试数据 X 是否超过标准规定的限值
<i>Split_Fre(X)</i>	根据是否相邻测试频率点对 X 矩阵中的数据进行分段
<i>isHarmonictype(X)</i>	确定数据 X 是否为谐波类型
<i>isSinglePeaktype(X)</i>	确定数据 X 是否为单点尖峰类型
<i>merge(X)</i>	根据给定的阈值合并矩阵 X 中间间隔较小的频带

2.2.3 算法有效性验证

本文选取 GB14023-2011 标准下的电动汽车平均值测试数据和 GB/T18387-2008 标准下的电场发射强度测试数据对本文提出的 EMC 测试数据特征提取算法的有效性进行了验证。

根据式(1)中定义的标准来测试曲线类型,本文将对应的阈值 $Th1$ 设为 8dB。

值得注意的是,本文阈值的设置是基于 CAERI 的 EMC 测试工程师的经验,因此所设置的阈值可能会因测试机构的不同而不同。本文所设置的测试阈值集如表 2 所列,利用本文算法对测试数据进行特征提取的结果如表 3 所列。

表 2 特征提取阈值集

Table 2 Feature extraction threshold set

阈值名称	值
判断数据类型的阈值 T_{H1}	8 dB
GB14023 标准下包络合并的阈值	2 MHz
GB/T18387 标准下包络合并的阈值	0.6 MHz

表 3 特征提取结果

Table 3 Feature extraction result

测试数据名称			
GB 14023-2011 R V AV		GB/T18387-2008 R E	
超标频段/MHz	数据类型	超标频段/MHz	数据类型
30~33.45	包络	15.598~17.166	包络
35.6~36.7	包络	17.998~26.018	包络
39.65~45.6	包络	27.402~30	包络
55.15~70.85	包络	0.009~0.15	谐波
77.15~80.25	包络	—	—
90.6~93.6	包络	—	—
100.75~105.95	包络	—	—
111.2~115.8	包络	—	—
165	谐波	—	—
627	谐波	—	—
924	谐波	—	—
990	谐波	—	—

实验结果表明,所提取的特征与测试报告记录中的数据相吻合,验证了所提出的 EMC 测试数据特征提取算法的有效性。

3 基于 SVM 的小样本故障分类

如前所述,国内车辆的电磁兼容测试的发展还处于起步阶段,能用于 EMC 故障诊断的数据量比较少,因此本文研究是基于小样本数据集,采用支持向量机来处理。本节首先介绍了数据预处理过程,然后详细介绍了 SVM 模型的构建过程。

3.1 数据预处理

根据 EMC 设计经验^[2],我们可以建立异常测试值和故障源之间的对应关系表。由于一种异常现象可能对应多个故障源,因此一种异常现象的样本数据数量等于可能的故障源数量。

在建立异常测试值与故障源之间的对应关系后,根据测试整改记录,可以建立异常现象与多个故障源之间的关系。如果异常现象确定是由此故障源引起的,则样本数据标记为真,记为“1”类;否则标记为假,记为“2”类。由此可以将复杂的电磁兼容故障分类问题转化为简单的二分类问题。

样本数据预处理的关键是故障样本的离散化,根据测试经验,可以将整个测试频段划分为 5 个子频段,频率范围分别为 0~150 kHz,150 kHz~1 MHz,1 MHz~30 MHz,30 MHz~200 MHz 以及 200 MHz~1 000 MHz,记为一级、二级、三级、四级、五级。然后对所有故障记录进行 5 种属性的标注,即测试标准、测试类型、超标频段、超标数据类型和相应的可能骚扰源。

如图 1(a)所示,测试曲线在测试频率为 60MHz 附近出现异常,对应的特征属性可以表示如下。

- 1)测试标准:GB14023。
- 2)测试类型:AV(平均值测试)。
- 3)超标频段:55.15~70.85 MHz,属于子频段四级。
- 4)超标数据类型:包络。

5)可能的骚扰源:DCDC。

预处理后的数据集将被划分为训练集和测试集,为了保证结果的准确性和保真性,一般选取 2/3~4/5 的样本用于训练^[17]。在本文中,训练集和测试集样本的大小是根据不同样本比例进行实验对比后选择的,实验对比结果将在第 4 节中给出。

3.2 SVM 模型

支持向量机是基于统计学习理论发展起来的一种具有较强泛化能力的机器学习方法,在解决小样本分类问题方面有很好的效果^[18]。在实际应用中,支持向量机把机器学习转化为优化问题进行求解,并利用优化理论和方法构造算法来求解凸二次规划问题。

本文中,训练样本集表示为:

$$Train=\{(\boldsymbol{x}_i,y_i),i=1,2,\cdots,m\},y_i\in\{-1,1\}$$

(2)

其中, $\boldsymbol{x}_i$ 是具有 5 个特征属性的训练元组; y_i 是类标签,这里的“−1”对应于本文的“2”类,而“1”对应于本文的“1”类; m 是训练样本的数量。

SVM 模型训练的实验流程如下。

Step1 将原始数据集转化为 LIBSVM 支持的数据格式:[label][index1]:[value1] [index2]:[value2]…。即[类别标号 1] [特征 1]:[特征值] [特征 2]:[特征值]…。然后将数据集划分为训练集和测试集,训练集是从预处理的数据样本中随机选取的。由于数据量非常有限,训练结果可能会有所不同。为了保证训练结果的可重复性,这里使用随机种子和“expected-improvement-plus”的获取函数。

Step2 选择核函数 $\boldsymbol{K}(\boldsymbol{x}_i,\boldsymbol{x}_j)$ 和惩罚参数 C ,构造凸二次规划问题。

本文选择高斯径向核函数作为 SVM 的核函数^[19],其公式如下:

$$\boldsymbol{K}(\boldsymbol{x}_i,\boldsymbol{x}_j)=\exp(-\|\boldsymbol{x}_i-\boldsymbol{x}_j\|^2/(2*\sigma^2))$$

(3)

其中, σ 是高斯核的带宽,且 $\sigma>0$ 。误差惩罚因子 C 通过调用自定义的 *fitsvm* 函数得到。凸二次规划问题的构造如下:

$$\begin{aligned} \max_{\boldsymbol{a}} & \sum_{i=1}^m \boldsymbol{a}_i - \frac{1}{2} \sum_{i=1}^m \sum_{j=1}^m \boldsymbol{a}_i \boldsymbol{a}_j y_i y_j \boldsymbol{K}(\boldsymbol{x}_i, \boldsymbol{x}_j) \\ \text{s. t. } & \sum_{i=1}^m \boldsymbol{a}_i y_i = 0, 0 \leq \boldsymbol{a}_i \leq C, i = 1, 2, \cdots, m \end{aligned}$$

(4)

其中, $\boldsymbol{a}=(\boldsymbol{a}_1;\boldsymbol{a}_2;\cdots;\boldsymbol{a}_m)$ 是拉格朗日乘数。由此可以得到最优解 $\boldsymbol{a}=(\boldsymbol{a}_1;\boldsymbol{a}_2;\cdots;\boldsymbol{a}_m)$ 。

Step3 计算超平面的法向量 $\boldsymbol{\omega}$ 与位移项 b 。

基于 $\boldsymbol{a}=(\boldsymbol{a}_1;\boldsymbol{a}_2;\cdots;\boldsymbol{a}_m)$,可以计算 $\boldsymbol{\omega}$ 和 b ,其公式如下:

$$b=y_j-\sum_{i=1}^m y_i \boldsymbol{a}_i \boldsymbol{K}(\boldsymbol{x}_i, \boldsymbol{x}_j)$$

(5)

$$\boldsymbol{\omega}=\sum_{i=1}^m \boldsymbol{a}_i \boldsymbol{x}_i$$

(6)

Step4 找到超平面,并获得分类的决策函数。

基于式(7)实现超平面的划分,然后根据式(8)得到模型的分类决策函数。

$$\boldsymbol{\omega} \boldsymbol{x} + b = 0$$

(7)

$$f(x)=\sum_{i=1}^m \boldsymbol{a}_i y_i \boldsymbol{K}(\boldsymbol{x}, \boldsymbol{x}_i) + b$$

(8)

最后,通过训练过程得到的分类决策函数预测测试数据的类别。

4 实验结果分析

为了验证所提方法的有效性,本文采用基于每个类别的先验概率和特征属性的条件概率两个参数的朴素贝叶斯算法^[20]作为对比算法进行实验,其公式如下:

$$P(C_i)=\frac{C_{i,Train}}{Train}$$

(9)

$$P(\mathbf{X}|C_i)=\prod_{k=1}^n P(\mathbf{x}_k|C_i)$$
$$=P(\mathbf{x}_1|C_i)P(\mathbf{x}_2|C_i)\cdots P(\mathbf{x}_n|C_i)$$

(10)

其中, $Train$ 表示训练样本与其类标签的集合, $\mathbf{X}$ 表示 n 维特征变量, C 表示标签类别。本文选择具有最大 $P(\mathbf{X}|C_i)P(C_i)$ 的类别 C_i 为测试样本的预测类别。

4.1 数据集的划分

如前所述,训练集和测试集的大小选择会对实验结果产生影响,因此本文考虑了 40%, 30%, 20% 3 种分配比例的测试集分别对 SVM 模型和朴素贝叶斯分类模型进行了相应实验。实验结果如图 4 所示,对应的参数如表 4 和表 5 所列。




图 4 不同测试集比例下模型错误率的比较

Fig. 4 Comparison of model error rates with different test proportions

表 4 不同测试集比例下 SVM 分类模型的参数
Table 4 Parameters of SVM classification model with different test set proportions

参数名称	测试集分割比		
	$P=0.4$	$P=0.3$	$P=0.2$
C	104.12	223.1	255.89
δ	0.01	0.11	2.12

表 5 不同测试集比例下朴素贝叶斯分类模型的参数
Table 5 Parameters of NB classification model with different test set proportions

参数名称	测试集分割比		
	$P=0.4$	$P=0.3$	$P=0.2$
Distribution	kernel	kernel	kernel
Names			
Width	3.8	0.28	0.39
Kernel	triangle	normal	normal

从图 4 可以看出,当训练样本所占比例为 80%、测试样本所占比例为 20% 时,训练出的两个模型的错误率最低,所以本文选择 80% 的样本集作为训练集来进行实验。

4.2 学习效果

本文使用错误率、P-R 曲线、ROC (Receiver Operating Characteristic) 曲线以及 AUC 值来评估本文所搭建模型的性能。对于 ROC 曲线,本文采用 ROC 曲线和坐标轴围成的图形面积(也就是 AUC 值)来对模型的学习效果进行评估。而对于 P-R 曲线则是通过盈亏平衡点(BEP),即精度率等于召回率的点所对应的值以及 F1 值来对模型性能进行评估。其

中 F1 是查准率(Precision, P)与查全率(Recall, R)的调和平均,其定义如下:


$$F1=\frac{2\times P\times R}{P+R}$$

(11)


各指标的实验结果如表 6 和图 5 所示。

表 6 性能评价参数具体值($P=0.2$)
Table 6 Specific values of performance evaluation parameters ($P=0.2$)

评价参数	SVM 模型	朴素贝叶斯模型
Error rate	0.217 4	0.260 9
AUC	0.857 1	0.825 4
BEP	0.777 8	0.555 6
Precision	0.678 6	0.750 0
Recall	0.863 6	0.666 7
F1	0.760 0	0.705 9



(a) SVM 模型



(b) 朴素贝叶斯模型

图 5 实验结果
Fig. 5 Experimental result

从表 6 可以得出,SVM 模型的错误率相比朴素贝叶斯模型较低。AUC, F1 和 BEP 的值越大,模型的学习效果就越好。显然,从表 6 和图 5 可以看出 SVM 模型的学习性能要优于朴素贝叶斯分类模型。

4.3 应用软件示例

根据 CAERI 的需求,本文基于所提出的方法设计了一个 EMC 反向诊断系统,其应用软件示例如图 6 所示。




图 6 应用软件示例
Fig. 6 Example of Application Software

图 6 给出了 GB14023-2011 标准下某电动汽车的试验数据。选择数据比较的限值、比较类型和点击分析,然后点击查看预测结果就可以看见模型的预测结果,该结果显示在图 6 中

下面的方框中。此预测结果是根据预测可能性从大到小依次排列的。可以看出,最可能在四级(30~200 MHz)频段引发包络数据类型超标现象的骚扰源为 DCDC,其次是内部走线,后面的骚扰源由于篇幅问题和脱敏的关系,在此不一一显示。

测试工程师在测试过程中遇到此异常现象时,会根据自己的经验猜测可能的原因,通过逐个排查最终确定骚扰源。经验丰富的工程师能够在较短时间内定位到 DCDC,但是一般情况下都需要经过几次排查才能找出症结所在。根据本文所提模型的预测,引起此处异常的最大可能的骚扰源是 DCDC,而此处异常的实际原因也的确是 DCDC,因此测试工程师通过本文模型的预测结果排查 DCDC 能快速地解决问题,从而减工作量,更快捷地发现导致异常的原因。

结束语 本文提出了一种基于小规模数据集的智能汽车电磁兼容故障诊断方法。首先根据经验选择可能的电磁兼容骚扰源;然后设计了一种测试特征提取方法,将测试输出特征分为包络、单峰和谐波三大类;接着构建能用于模型训练的数据样本集,以表明异常现象与故障源之间的关系;最后利用支持向量机进行故障分类和故障排除。实验结果表明,该方法是可行的,并且取得了较满意的应用效果。

在接下来的工作中,我们将致力于样本数据增强方法的研究,扩大训练样本数据的规模,进而提高诊断的准确性。

参 考 文 献

- [1] LEI J, YAN H, CHEN R, et al. Automotive mmWave Radar EMC Test Developments and Challenges[C]// Proceedings of 2019 13th European Conference on Antennas and Propagation (EuCAP). IEEE/IET Electronic Library(IEL), 2019:1-6.
- [2] ZHENG J Q. EMC Risk Assessment in Product Design[J]. Electrical & Energy Management Technology, 2017(14):35-37,73.
- [3] LIANG X L, CHEN T, YANG X D. Application of Fuzzy Fault Tree Analysis in the Fault Diagnosis for Automobile Engine System[C]// 2017 9th International Conference on Modelling, Identification and Control(ICMIC). IEEE, 2017:711-716.
- [4] LI G, LIU P, LI Y, et al. Techniques of Electromagnetic Compatibility Model Synthesis Based on On-Site Measurement Data[J]. Journal of Microwaves, 2013, 96(9):2251-2260.
- [5] HE J, YANG S, GAN C. Unsupervised Fault Diagnosis of a Gear Transmission Chain Using a Deep Belief Network[J]. Sensors, 2017, 17(7):1564.
- [6] SILVA M, SANTOS A, FIGUEIREDO E. Damage Detection for Structural Health Monitoring of Bridges as a Knowledge Discovery in Databases Process[M]// Data Mining in Structural Dynamic Analysis: A Signal Processing Perspective. Singapore: Springer Singapore, 2019:1-24.
- [7] YIN Z, HOU J. Recent advances on SVM based fault diagnosis and process monitoring in complicated industrial processes[J]. Neurocomputing, 2016, 174(JAN. 22PT. B):643-650.
- [8] GUO C Y, OUYANG G Y, LI Y F. Fault diagnosis of circuit in small sample based on artificial immune system[J]. Journal of Electronic Measurement and Instrument, 2010, 24(5):425-429.
- [9] ZHAO L H, ZHOU L H, DAI Y P, et al. The application and

development of artificial immune system in rotating machinery fault diagnosis[J]. Modern Manufacturing Engineering, 2015(7):143-149.

- [10] MAGAGULA X G, HAMAM Y, JORDAAN J A, et al. A fault classification and localization method in a power distribution network[C]// 2017 IEEE AFRICON. IEEE, 2017:1337-1343.
- [11] GALAL M A, HUSSEIN W M, KAWY E E D A, et al. Satellite battery fault detection using Naive Bayesian classifier[C]// 2019 IEEE Aerospace Conference. IEEE, 2019:1-11.
- [12] SOWAH R A, DZABENG N A, OFOLI A R, et al. Design of Power Distribution Network Fault Data Collector for Fault Detection, Location and Classification using Machine Learning[C]// 2018 IEEE 7th International Conference on Adaptive Science & Technology(ICAST). IEEE, 2018:1-8.
- [13] CAO H L, XUE C, XUE P. Application of SVM Based on Multiple Kernels Learning in Engine Fault Diagnosis[J]. Machinery Design & Manufacture, 2019, 339(5):8-11,16.
- [14] WANG B J, ZHANG X L, FU Y A X, et al. Optimization of support vector machine and its application in intelligent fault diagnosis. [J]. Journal of Vibration, Measurement & Diagnosis, 2017, 37(3):547-552.
- [15] HAN F, TIAN Y, ZOU Q, et al. Research on the Fault Diagnosis of a Polymer Electrolyte Membrane Fuel Cell System[J]. ENERGIES, 2020, 13(10):2531.
- [16] REBALA G, RAVI A, CHURIWALA S. Principal Component Analysis[M]// An Introduction to Machine Learning. Cham, Springer International Publishing, 2019:141-52.
- [17] BELL J. Machine learning: hands-on for developers and technical professionals[M]. John Wiley & Sons, 2015.
- [18] VAPNIK V, VAPNIK V, VAPNIK V N. Statistical Learning Theory[J]. Annals of the Institute of Statistical Mathematics, 2003, 55(2):371-389.
- [19] LI R, SU H, WANG Z, et al. Medium-and long-term load forecasting based on heuristic least square support vector machine[J]. Power System Technology, 2011, 35(11):195-199.
- [20] DA L. An Intrusion Detection System Based on Naive Bayes Classifier[J]. Cyberspace Security, 2017(8):32-34.



LEI Jian-mei, born in 1978, Ph.D, professor-level senior engineer. Her main research interests include vehicle-level EMC performance analysis and prediction, and automotive RF electronics and test technologies in intelligent connected vehicles and prediction, and automotive RF electronics and test technologies in intelligent connected vehicles.



ZENG Ling-qiu, born in 1975, Ph. D, professor. His main research interests include VANET, intelligent transportation, and data processing.