

# 基于 DBNs 的轮毂电机机械故障在线诊断方法<sup>\*</sup>

李仲兴<sup>1</sup>, 陈震宇<sup>1</sup>, 薛红涛<sup>1</sup>, 殷苏群<sup>1</sup>, 江洪<sup>2</sup>

(1. 江苏大学汽车与交通工程学院 镇江, 212013)

(2. 江苏大学机械工程学院 镇江, 212013)

**摘要** 为实现电动汽车用轮毂电机运行状态在线监测及其安全评估,提出一种基于动态贝叶斯网络(dynamic Bayesian networks, 简称 DBNs)的轮毂电机机械故障在线诊断方法。首先,以轮毂电机运行安全为目标,着重考虑车速对轮毂电机振动信号的影响程度,在时域和频域中提炼出多个敏感度高的特征参数来表征轮毂电机的运行状态,并将其作为 DBNs 的观测节点;其次,基于速度片构建轮毂电机机械故障诊断模型,解决其运行状态在相邻时间片之间无法构建转移概率分布的问题,根据不同速度片之间的转移概率分布,建立以二速度片展开的 DBNs,实现对轮毂电机机械故障的在线诊断;最后,通过轮毂电机综合台架试验,验证了该方法对轮毂电机机械故障在线诊断的有效性。

**关键词** 轮毂电机; 机械故障; 在线诊断; 动态贝叶斯网络

**中图分类号** TH17

## 引言

传统燃油汽车带来的环境污染问题与日俱增,发展高效环保的新能源汽车已被提升到国家战略高度。采用轮毂电机驱动的电动汽车具有结构简单紧凑和传动效率高等优点,成为新能源汽车领域的研究重点<sup>[1]</sup>,与之相关的轮毂电机技术是电动汽车驱动系统的核心技术之一。由于轮毂电机安装在狭小的轮毂空间内,磁场饱和、转矩波动和负载突变等因素对其性能影响明显<sup>[2]</sup>,且多变的汽车行驶工况和复杂的路况极易诱发轮毂电机机械故障,从而引发次生故障,危及车辆运行安全。因此,有必要对轮毂电机运行状态进行在线监测和诊断,提高识别轮毂电机机械故障的准确性与时效性。

振动信号均蕴含着丰富的设备状态信息,具有抗干扰能力强和凸显轻微故障信息等优点,基于振动信号对机械设备运行状态进行监测与诊断的方法近年来发展迅速<sup>[3]</sup>。Xue 等<sup>[4]</sup>提取振动信号中最佳故障频率区域的特征信号,提出一种基于统计滤波、支持向量机、可能性理论和 D-S 证据理论的智能诊断方法,用于离心泵系统的故障诊断。Wang 等<sup>[5]</sup>

利用压缩感知理论和可调 Q 因子小波变换,提取滚动轴承振动信号中的故障特征,并在信号重构过程中实现故障诊断。文献[6]提出了一种人工碳氢网络的机器学习方法,用于从振动信号中提取故障特征,从而实现了对密封深沟球轴承的故障检测。文献[7]提出了一种基于振动信号中最优特征参数组和支持向量机的智能诊断方法,用以检测多个故障并识别故障类型。Ren 等<sup>[8]</sup>提出一种改进的最小化 Majorzation 算法,解决了原算法计算量庞大的问题。以上方法在一定程度上促进了旋转机械设备运行状态在线监测方法的发展,但由于电动汽车用轮毂电机运行环境复杂,车载电源供电波动较大,导致这些方法对轮毂电机运行状态的识别率较低,无法满足车辆运行安全的要求。

动态贝叶斯网络是一种对动态不确定事件进行建模和推理的工具,可综合多个时刻与目标类型相关的多个特征进行推理,从而克服依赖单一特征的局限<sup>[9]</sup>。笔者基于 DBNs 提出一种轮毂电机机械故障在线诊断方法。首先,分析车速对振动信号的影响程度,提出使用综合权重诊断指标法(synthetic weight detection index, 简称 SWDI)从时域和频域中提炼出多个高敏感特征参数;其次,

<sup>\*</sup> 国家自然科学基金资助项目(51775245,51575241);江苏省重点研发计划资助项目(BE2017129)  
收稿日期:2018-08-07;修回日期:2018-10-22

利用特征参数服从高斯分布的特性,结合混合高斯模型,根据不同速度片之间的转移概率分布,建立以二速度片展开的 DBNs,实现对轮毂电机机械故障的在线诊断;最后,通过轮毂电机台架试验数据进行模型参数训练与检测,结果也证明了该方法的有效性。

## 1 轮毂电机台架试验

结合轮毂电机在电动汽车中的实际运行情况,笔者设计了如图1所示的轮毂电机试验台架,主体结构包括电动轮夹具、减振器、电动轮(轮毂电机安装在轮辋内)、滚筒支撑架、单通道电液伺服试验系统、压力传感器和加速度传感器,采用 LMS 数据采集仪进行数据采集。试验时,液压激振台先上升顶住滚筒支撑架,当支撑架上的双滚筒与电动轮胎面接触并且压力达到预定值(模拟实车对电动轮的垂向载荷)后,电动轮启动。当电动轮速度达到指定值后,调用不同等级的路面载荷谱输入到电液伺服试验系统中,用来模拟电动轮在路面上的行驶情况。为了使台架试验更精准地接近实车试验,采用电动汽车中的车载供电系统对轮毂电机进行供电与控制。轮毂电机机械故障种类繁多,电机轴承故障是其典型故障之一<sup>[10]</sup>。因此,在轮毂电机轴承附近粘贴频率为 250Hz 的干扰源,引入非正常振动信号,模拟电机轴承发生机械故障时的周期性异常振动。




图1 轮毂电机试验台架

Fig.1 In-wheel motor test bench

笔者以瑞麟 M1-EV 纯电动汽车为研究原型,该车整备质量为 1 060kg,用试验台架模拟车载 1 人(质量为 60kg)时的运行状态,则单个电动轮所承受的载荷为车、人总重的 1/4,即压力传感器的预定值设为 280kg。调用 A 级路面载荷谱输入到电液伺服试验系统中,将轮毂电机转速与车速换算,分别在正常与故障情况下采集车速为 5, 10, 15, 20 和

25km/h 的垂向振动信号。试验振动信号采样频率为 12.8kHz,采样时间为 20s。

## 2 诊断用特征参数选取

轮毂电机在运行过程中产生的振动及其特征信息反映了其运行状态的变化,因此有效分析振动信号、提炼出对故障敏感度高的特征参数是进行精确诊断的关键<sup>[11]</sup>。汽车在同一段路面行驶过程中,不同的行驶车速对基于振动信号的轮毂电机机械故障诊断造成的干扰也不同,因此需要在不同车速下综合分析轮毂电机正常与故障的振动信号。笔者将采集的振动信号分为 15 段,经 100~2 000Hz 带通滤波后,计算相应的特征参数。

### 2.1 振动信号常用特征参数

时域信号是故障诊断的原始依据,基于其特征参数具有信息量大和直观易懂等特点,对不同类型的故障可以做出准确判断。频域信号是时域信号的另一种体现,能够呈现出机械设备因故障因素在频率上发生的变化,并分析其频率成分的组成和大小,可迅速判别设备初期微弱故障<sup>[12]</sup>。因此,基于时域和频域对振动信号进行分析更加全面<sup>[13]</sup>,振动信号特征参数主要从时域和频域中提取<sup>[14]</sup>。针对轮毂电机及其运行工况,在时域和频域中拟选取 8 个特征参数。

设  $\{x_i\} (i=1 \sim N)$  为所采集信号的时间序列,  $N$  为采样点数,其平均值和标准差分别为  $\bar{x} = \frac{1}{N} \sum_{i=1}^N x_i$ ,  $\sigma = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{x})^2}$ 。定义  $\{x_{pj}\} (j=1 \sim N_p)$  为  $\{x_i\}$  中极大值总数,极大值  $\{x_{pj}\}$  的平均值和标准差分别为  $\bar{x}_p = \frac{1}{N_p} \sum_{j=1}^{N_p} x_{pj}$ ,  $\sigma_p = \sqrt{\frac{1}{N_p-1} \sum_{j=1}^{N_p} (x_{pj} - \bar{x}_p)^2}$ ,  $N_v$  为  $\{x_i\}$  中极小值总数。

$$P_1 = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2} \quad (1)$$

$$P_2 = \frac{1}{N_p} \sum_{j=1}^{N_p} |x_{pj}| \quad (2)$$

$$P_3 = \left| \frac{1}{\sigma_p^4} \sum_{j=1}^{N_p} (x_{pj} - \bar{x}_p)^4 \right| \quad (3)$$

$$P_4 = \frac{N_p}{N_v} \quad (4)$$

设  $\{f_i\} (i=1 \sim I)$  为频率序列,  $I$  为采样频率的

一半,  $F(f_i)$  为第  $f_i$  的频谱值。

$$P_5 = \sqrt{\frac{\sum_{i=1}^I f_i^4 F(f_i)}{\sum_{i=1}^I f_i^2 F(f_i)}} \quad (5)$$

$$P_6 = \frac{\sum_{i=1}^I f_i^2 F(f_i)}{\sqrt{\sum_{i=1}^I F(f_i) \sum_{i=1}^I f_i^4 F(f_i)}} \quad (6)$$

$$P_7 = \sum_{i=1}^I F(f_i) \quad (7)$$

$$P_8 = \sqrt{\sum_{i=1}^I F^2(f_i)} \quad (8)$$

### 2.2 高敏感特征参数选取

特征参数的敏感度是指特征参数在区分机械设备不同运行状态时的难易程度,不同的特征参数在同一机械设备相同的状态下,敏感度不一样。同样,不同状态下同一特征参数的敏感度也不一样。高敏感度的特征参数越容易识别区分不同状态,反之,低敏感度的特征参数难以识别区分不同状态。基于此,国内外学者提出了不少选取方法,比如欧式距离法<sup>[15]</sup>(euclidean distance technique, 简称 EDT)、类间离散度与类内离散度的比值法<sup>[16]</sup>及区分度指标法<sup>[17]</sup>(distinguish index, 简称 DI)等,其中区分度指标法应用较为广泛,其定义为

$$DI = |\mu_2 - \mu_1| / \sqrt{\sigma_1^2 + \sigma_2^2} \quad (9)$$

其中:  $\mu_1, \mu_2$  分别为状态 1 和状态 2 时某一特征参数对应的平均值;  $\sigma_1, \sigma_2$  为对应的标准差。

特征参数对两种状态的区分率(discrimination rate, 简称 DR)可用式(10)表示,与敏感度的关系如表 1 所示<sup>[18]</sup>。DI 值越大,区分率越高,相应的特征参数敏感度越高。

$$DR = 1 - \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{-DI} e^{-\frac{\mu^2}{2}} d\mu \quad (10)$$

表 1 DI 值、DR 值与特征参数敏感度的关系

Tab. 1 The correspondence between DI, DR and sensitivity of parameters

DI	DR/%	敏感度
<0.85	<80	低
0.85~1.30	80~90	适中
1.30~1.65	90~95	较高
1.65~2.33	95~99	高
>2.33	>99	很高

DI 值法对两种状态下一特征参数的选取快捷有效。然而,通常情况下任何机械设备均有多

种运行工况,每种工况下的故障状态也不止两种,且单一的特征参数无法有效表征其多种运行工况下的多种故障运行状态。因此,为提高诊断的精确率,需要同时选取对多种运行状态均具有高敏感度的多个特征参数,笔者提出综合权重诊断指标法,其定义为

$$SWDI = \sum_{i=1}^{N-1} \sum_{j=i+1}^N \sum_{r=1}^R \sum_{q=1}^Q \omega_{ijrq} f(DI_{ijrq}) \quad (11)$$

其中:  $N$  为不同状态(正常状态、故障 1 状态、故障 2 状态等)的数目;  $R$  为所要选取高敏感特征参数的数量;  $Q$  为运行工况类别的数目。

从表 1 中可以看出,当 DI 值大于 2.33 时,说明该特征参数在状态区分率上已经高达 99%,满足高敏感性要求,因此将大于 2.33 的 DI 值全部近似取为 2.33,其公式为

$$f(DI) = \begin{cases} DI & (0 \leq DI \leq 2.33) \\ 2.33 & (DI > 2.33) \end{cases} \quad (12)$$

$\omega$  为权重系数,定义为

$$\omega = 3 - \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{-f(DI)} e^{-\frac{\mu^2}{2}} d\mu - 2\alpha \quad (13)$$

其中:  $\alpha$  为特征参数敏感度阈值。

当状态区分率小于  $\alpha$  时,  $\omega < 1$ ,减小不敏感特征参数在 SWDI 值中的权重;当状态区分率大于  $\alpha$  时,  $\omega > 1$ ,增大高敏感特征参数在 SWDI 值中的权重,进而降低不敏感特征参数对选取多个高敏感特征参数造成的干扰,  $\alpha$  值越高,选取出的特征参数越敏感。由表 1 可知,当状态区分率大于 95% 时,认为该特征参数敏感度高,因此笔者取  $\alpha$  为 95%。

本次试验仅涉及正常与故障 2 种状态,因此  $N$  为 2。从 8 个特征参数中优选出 4 个高敏感特征参数作为贝叶斯网络的子节点,因此  $R$  为 4。涉及 5 种不同车速的工况,因此  $Q$  为 5。基于式(11)~(13)计算不同特征参数组的 SWDI 值,如表 2 所示。通过计算,第 11 组的 SWDI 值最大为 45.97,因此选取的高敏感特征参数为  $P_1, P_2, P_5$  和  $P_7$ 。

表 2 不同特征参数组的 SWDI 值

Tab. 2 SWDI of different groups of parameters

组号	特征参数组	SWDI	DI <sub>max</sub>	DI <sub>min</sub>
1	$P_1 P_2 P_3 P_4$	39.55	7.68	0.16
2	$P_1 P_2 P_3 P_5$	43.74	7.68	0.86
⋮	⋮	⋮	⋮	⋮
11	$P_1 P_2 P_5 P_7$	45.97	7.68	0.96
12	$P_1 P_2 P_5 P_8$	44.39	7.68	0.53
⋮	⋮	⋮	⋮	⋮
70	$P_5 P_6 P_7 P_8$	41.82	7.67	0.53

表3为高敏感特征参数组的DI值与区分率。可以看出,通过SWDI值法优选出的特征参数在各车速工况下对正常与故障状态区分率均比较好,具有较好的敏感度,有利于贝叶斯网络推理。

表3 高敏感特征参数组的DI值与区分率

Tab.3 DI and DR of the high sensitive group of parameters

$v/$ (km·h <sup>-1</sup> )	$P_1$		$P_2$		$P_5$		$P_7$	
	DI	DR/%	DI	DR/%	DI	DR/%	DI	DR/%
5	1.37	91.40	0.96	83.22	2.74	99.70	1.30	90.36
10	7.68	100.00	6.32	100.00	3.83	99.99	7.01	100.00
15	4.35	100.00	4.93	100.00	6.52	100.00	3.99	100.00
20	7.76	100.00	6.75	100.00	4.81	100.00	7.67	100.00
25	2.69	99.65	2.61	99.54	2.75	99.70	2.72	99.67

### 3 基于DBNs的轮毂电机机械故障在线诊断

轮毂电机的在线故障诊断实际上是一个动态的不确定性问题,而动态贝叶斯网络可以利用初始网络和转移网络对轮毂电机运行状态进行动态概率推理,从而实现轮毂电机的在线故障诊断。由于振动信号的特征参数 $P$ 是连续值,且服从高斯分布,笔者结合高斯混合模型(Gaussian mixture model,简称GMM)建立基于高斯混合输出的动态贝叶斯网络(Gaussian mixture output dynamic Bayesian networks,简称GMOBDBNs)。

#### 3.1 基于高斯混合输出的动态贝叶斯网络

一个动态贝叶斯网络通常由有限个时间片构成,每个时间片由一个有向无环图(directed acyclic graph,简称DAG)和条件概率表(conditional probability tables,简称CPT)组成<sup>[19]</sup>。动态贝叶斯网络应用于状态识别与诊断时需要2个主要参数:2个时间片之间的转移概率分布 $P(C^t | C^{t-1})$ (转移分布),可观测变量概率分布 $P(X^t | C^t)$ (似然分布)<sup>[20]</sup>。基于高斯混合输出的动态贝叶斯网络可以看做一种观测变量概率分布能够用高斯混合进行表示的贝叶斯网络,其二时间片展开图如图2表示。

在单个时间片 $t$ 内,父节点 $C$ 表示了系统不同的 $N$ 种工作状态 $C_1, \dots, C_N$ ,节点 $M$ 表示了混合模型的混合成分个数 $K$ ,在 $C=N$ 条件下,混合权值 $m_1, m_2, \dots, m_K$ 由 $M$ 的条件概率表反映。子节点 $X$ 表示了特征 $X_1, X_2, \dots, X_W$ 为一个多元高斯节点。

在 $t-1$ 时刻,系统工作状态记为 $C_i^{t-1}$ ( $1 \leq i \leq N$ );在 $t$ 时刻,系统工作状态记为 $C_j^t$ ( $1 \leq j \leq N$ ),




图2 基于GMOBDBNs的二时间片展开

Fig.2 Unrolled GMOBDBNs in two time slice

可观测变量特征记为 $X^t$ (包含所有特征 $X_1, X_2, \dots, X_W$ ),则似然分布 $P(X^t | C^t)$ 为

$$P(X^t | C_j^t) = \sum_{k=1}^K P(X^t | M_k^t, C_j^t) P(M_k^t | C_j^t) \quad (14)$$

根据贝叶斯公式求得 $t$ 时刻系统工作状态的后验概率为

$$P(C_j^t | X^t, C_i^{t-1}) = \frac{P(X^t | C_j^t) P(C_j^t | C_i^{t-1})}{\sum_{n=1}^N P(X^t | C_n^t) P(C_n^t | C_i^{t-1})} \quad (15)$$

式(14)中混合成分条件分布 $P(M_k^t | C_j^t)$ 、高斯混合条件分布 $P(X^t | M_k^t, C_j^t)$ 以及式(15)中的转移分布 $P(C_j^t | C_i^{t-1})$ 均可以通过动态贝叶斯参数学习方法从给定的样本数据中训练学习获得<sup>[21]</sup>或专家指定获得。

#### 3.2 轮毂电机机械故障诊断模型群及在线诊断方法

传统动态贝叶斯网络是按时间片所展开,但是轮毂电机前一时间片与后一时间片的运行状态没有内在的固定联系,即无法构建两时间片之间的转移概率分布。汽车在同一段路面行驶的过程中,车速的突然提升会加剧车辆颠簸,使轮毂电机轴承所承受的动载荷和冲击变化增大,极易引起轴承的局部变形,造成轮毂电机的机械故障<sup>[22]</sup>。轮毂电机由高速运转状态向低速运转状态转变时,轮毂电机所受冲击减小,但仍有一定概率会发生故障。因此,将轮毂电机运行状态的改变过程理解为一组随速度改变的快照,每个快照描述了轮毂电机在相应时间片内特定速度下的状态,利用CAN总线将每个时间片内的汽车实际行驶速度读出,则通过确定不同速度之间的状态转移概率分布可以建立动态贝叶斯网络,进而提出基于速度片展开的轮毂电机机械故障诊断模型。图3为该模型的二速度片展开图。

在单个速度片 $v_i$ 内,轮毂电机运行状态 $S_i^t$ 为正常状态, $S_2^t$ 为故障状态。振动信号类型节点中 $C_1^i \sim C_5^i$ 和 $C_6^i \sim C_{10}^i$ 在这里分别代表速度为5,10,15,

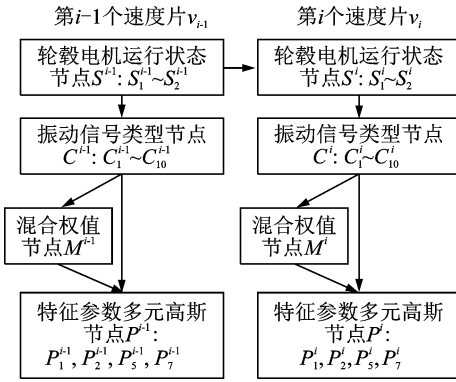


图 3 轮毂电机机械故障诊断模型的二速度片展开

Fig. 3 Unrolled mechanical fault diagnosis model of in-wheel motor in two speed slice

表 4 轮毂电机二速度片之间的运行状态转移概率

Tab. 4 The selection table of state transition probability distribution between two continuous speed slice of in-wheel motor running state

$v_{i-1} /$ ( $\text{km} \cdot \text{h}^{-1}$ )	状态	$v_i / (\text{km} \cdot \text{h}^{-1})$									
		5		10		15		20		25	
		正常	故障	正常	故障	正常	故障	正常	故障	正常	故障
5	正常	0.99	0.01	0.98	0.01	0.96	0.04	0.92	0.08	0.85	0.15
	故障	0	1	0	1	0	1	0	1	0	1
10	正常	0.99	0.01	0.99	0.01	0.97	0.03	0.95	0.05	0.92	0.08
	故障	0	1	0	1	0	1	0	1	0	1
15	正常	0.99	0.01	0.99	0.01	0.99	0.01	0.95	0.05	0.91	0.09
	故障	0	1	0	1	0	1	0	1	0	1
20	正常	0.99	0.01	0.99	0.01	0.99	0.01	0.99	0.01	0.93	0.07
	故障	0	1	0	1	0	1	0	1	0	1
25	正常	0.99	0.01	0.99	0.01	0.99	0.01	0.99	0.01	0.99	0.01
	故障	0	1	0	1	0	1	0	1	0	1

要实现轮毂电机的在线故障诊断,即随着时间的推移对轮毂电机进行状态监测,因此在二速度片轮毂电机故障诊断模型群的基础上提出时间片-速度片轮毂电机故障在线诊断方法,其在线诊断推理示意图如图 4 所示。取两个相邻的时间片为一个诊断单位,从 CAN 总线中读出各时间片的车速,根据车速从二速度片轮毂电机机械故障诊断模型群中选择相应的诊断模型(各诊断模型仅二速度片之间的状态转移概率不同,单个速度片内的贝叶斯网络相同),从而将基于时间片的概率推理问题转化为基于速度片的概率推理问题,将特征参数输入模型中进行诊断。在线诊断时,第 1 个诊断单位中的第 1 个速度片中轮毂电机运行状态由单个速度片内的贝叶斯网络进行推理,结合推理结果与选中的二速度片诊断模型对第 2 个速度片中轮毂电机运行状态进行推理;在对其他诊断单位进行推理时,前 1 个诊断单位中第 2 个速度片的诊断结果作为后 1 个诊断单位中第 1 个速度片的状态输入;依次推理,

20 和 25km/h 的正常和故障振动信号。每一待诊断的振动信号都默认为由 10 种高斯分布组成,因此混合模型中的成分个数  $K=10$ 。在特征参数多元高斯节点中将通过 SWDI 值法优选出的 4 个特征参数  $P_1^i, P_2^i, P_5^i$  和  $P_7^i$  作为模型的可观测量输入。

单个速度片  $v_i$  内各节点的条件概率表通过参数训练获得,两个速度片之间的状态转移概率采用专家指定的方法获得,设前一速度片与后一速度片之间速度差值的绝对值均为 5 的倍数,转移概率如表 4 所示。根据不同速度片之间的转移概率分布与单个速度片各节点的条件概率分布建立二速度片轮毂电机机械故障诊断模型群。

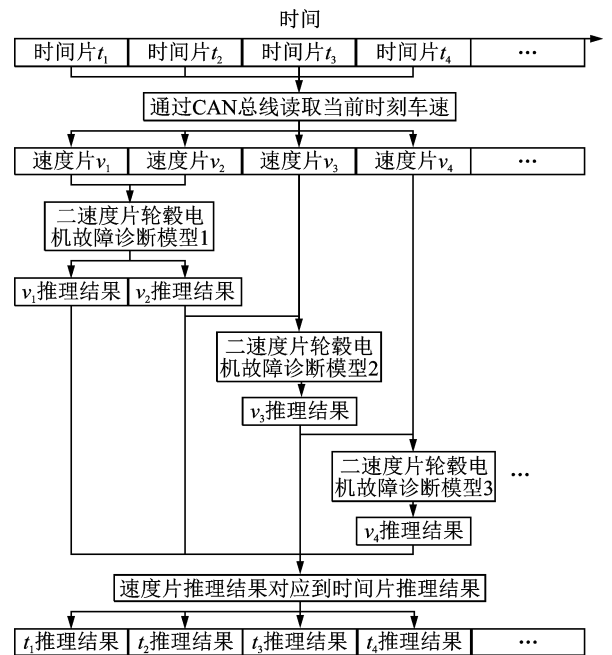


图 4 轮毂电机机械故障在线诊断推理示意图

Fig. 4 Flowchart of online mechanical fault diagnosis of in-wheel motor

输出状态诊断结果,从而实现轮毂电机机械故障的在线诊断。在本研究中,每段振动信号的采样时间为20s,分为15组,则时间片的时长为1.3s,从CAN总线中读取时间片中间时刻的速度,根据不同车速划分相应的速度片。目前主要研究车速变化率较小的情况,具体划分方案如表5所示。

表5 车速与速度片速度的对应关系

Tab. 5 The correspondence between speed and speed slice

车速/(km·h <sup>-1</sup> )	速度片速度/(km·h <sup>-1</sup> )
0~7.5	5
7.5~12.5	10
12.5~17.5	15
17.5~22.5	20
⋮	⋮

### 3.3 参数训练与诊断准确性检验

数据集包括5,10,15,20和25km/h下的正常和故障振动信号,每种振动信号包含15个样本,分别取前13个样本作为单个速度片内数据训练集,后2个样本作为测试数据库。根据表4中的状态转移概率分布将单个速度片的贝叶斯网络拓展成二速度

片动态贝叶斯轮毂电机机械故障诊断模型群。选取连续的5个时间片进行在线诊断测试,测试工况选择从5km/h到25km/h的匀加速典型工况(记为 $v_5, v_{10}, \dots, v_{25}$ ),从测试数据库中选取数据构建12个测试样本,每一样本中各时间片的轮毂电机运行状态如表6所示。利用Matlab FullBNT贝叶斯网络工具箱进行动态贝叶斯网络的建模、参数训练以及诊断测试。

表6 测试样本各时间片中轮毂电机运行状态

Tab. 6 In-wheel motor running state of different time slices of samples

样本	时间片1	时间片2	时间片3	时间片4	时间片5
	$v_5 /$ (km·h <sup>-1</sup> )	$v_{10} /$ (km·h <sup>-1</sup> )	$v_{15} /$ (km·h <sup>-1</sup> )	$v_{20} /$ (km·h <sup>-1</sup> )	$v_{25} /$ (km·h <sup>-1</sup> )
1,2	正常	正常	正常	正常	正常
3,4	正常	正常	正常	正常	故障
5,6	正常	正常	正常	故障	故障
7,8	正常	正常	故障	故障	故障
9,10	正常	故障	故障	故障	故障
11,12	故障	故障	故障	故障	故障

轮毂电机机械故障在线诊断的状态识别率如表7所示,仅样本7中时间片3与样本9中时间片1诊断有误,该方法的状态识别成功率高达96.7%,因此该方法可以有效用于轮毂电机的在线故障诊断。

表7 轮毂电机机械故障在线诊断的状态识别率

Tab. 7 Recognition rate of online mechanical fault diagnosis of in-wheel motor

样本编号	时间片1		时间片2		时间片3		时间片4		时间片5	
	$S_1$	$S_2$	$S_1$	$S_2$	$S_1$	$S_2$	$S_1$	$S_2$	$S_1$	$S_2$
1	99.99	0.01	99.99	0.01	100.00	0	99.98	0.02	98.30	1.70
2	99.99	0.01	99.95	0.05	100.00	0	100.00	0	96.94	3.06
3	99.82	0.01	99.78	0.22	100.00	0	100.00	0	21.06	78.94
4	100.00	0	100.00	0	100.00	0	99.98	0.02	28.26	71.74
5	99.99	0.01	99.99	0.01	100.00	0	0.34	99.66	0	100.00
6	99.99	0.01	99.95	0.05	100.00	0	3.31	96.69	0.01	99.99
7	99.82	0.18	99.78	0.22	85.93	14.07	0.07	99.93	0	100.00
8	100.00	0	100.00	0	12.89	87.11	0	100.00	0	100.00
9	17.64	82.36	0.04	99.96	0	100.00	0	100.00	0.01	99.99
10	78.38	21.62	0.04	99.96	0	100.00	0.01	99.99	0	100.00
11	0	100.00	0	100.00	0	100.00	0	100.00	0	100.00
12	0	100.00	0	100.00	0	100.00	0.07	99.93	0	100.00

## 4 结论

1) 综合分析不同车速下正常与故障轮毂电机轴承处的垂向振动信号,利用权重系数降低不敏感特征参数对选取多个高敏感特征参数造成的干扰,并基于此提出了SWDI综合权重诊断指标法,从时域和频域中提炼出多个高敏感特征参数,更利于动态贝叶斯网络的推理。

2) 针对轮毂电机运行状态在相邻时间片之间

无法构建转移概率分布的问题,提出“速度片”概念,结合不同速度之间的轮毂电机状态转移概率分布与特征参数 $P$ 服从高斯分布的特性,构建基于高斯混合输出的动态贝叶斯网络,从而建立轮毂电机机械故障诊断模型群。

3) 基于DBNs的轮毂电机机械故障诊断模型群提出了轮毂电机机械故障在线诊断方法,并通过轮毂电机综合台架试验数据对其进行验证,结果显示该方法的状态识别成功率高达96.7%,表明该方法在轮毂电机机械故障在线诊断上有效。

## 参 考 文 献

- [1] 明巧红,徐康聪. 轮毂电机系统及其驱动技术分析[J]. 上海汽车, 2017(3):6-10.  
MING Qiaohong, XU Kangcong. Analysis of in-wheel motor system and drive technology[J]. Shanghai Auto, 2017(3):6-10. (in Chinese)
- [2] 李勇, 徐兴, 孙晓东, 等. 轮毂电机驱动技术研究概况及发展综述[J]. 电机与控制应用, 2017, 44(6):1-7.  
LI Yong, XU Xing, SUN Xiaodong, et al. Review and future development of in-wheel motor drive technology[J]. Electric Machines & Control Application, 2017, 44(6):1-7. (in Chinese)
- [3] 葛慧敏. 车辆滚动轴承故障诊断建模及关键技术研究[D]. 镇江:江苏大学, 2017.
- [4] XUE H, LI Z, WANG H, et al. Intelligent diagnosis method for centrifugal pump system using vibration signal and support vector machine[J]. Shock and Vibration, 2014(1): 71-78.
- [5] WANG H, KE Y, SONG L, et al. A sparsity-promoted decomposition for compressed fault diagnosis of roller bearings[J]. Sensors, 2016, 16(9): 1524-1544.
- [6] XUE H, WANG M, LI Z, et al. Fault feature extraction based on artificial hydrocarbon network for sealed deep groove ball bearings of in-wheel motor [C] // Prognostics and System Health Management Conference. [S. l.]: IEEE, 2017: 1-5.
- [7] XUE H, WANG M, LI Z, et al. Sequential fault detection for sealed deep groove ball bearings of in-wheel motor in variable operating conditions[J]. Journal of Vibroengineering, 2017, 19(8): 5947-5959.
- [8] REN B, HAO Y, WANG H, et al. A sparsity-promoted method based on majorization-minimization for weak fault feature enhancement[J]. Sensors, 2018, 18(4): 1003-1022.
- [9] 唐政, 高晓光. 基于离散动态贝叶斯网络的辐射源目标识别研究[J]. 系统仿真学报, 2009, 21(1):117-120.  
TANG Zheng, GAO Xiaoguang. Research on radiant point identification based on discrete dynamic Bayesian network[J]. Journal of System Simulation, 2009, 21(1):117-120. (in Chinese)
- [10] CUI L, GONG X, ZHANG J, et al. Double-dictionary matching pursuit for fault extent evaluation of rolling bearing based on the Lempel-Ziv complexity[J]. Journal of Sound & Vibration, 2016, 385:372-388.
- [11] 熊庆. 列车滚动轴承振动信号的特征提取及诊断方法研究[D]. 成都:西南交通大学, 2015.
- [12] 赵志宏. 基于振动信号的机械故障特征提取与诊断研究[D]. 北京:北京交通大学, 2012.
- [13] CUI L, HUANG J, ZHAI H, et al. Research on the meshing stiffness and vibration response of fault gears under an angle-changing crack based on the universal equation of gear profile[J]. Mechanism & Machine Theory, 2016, 105:554-567.
- [14] 彭畅. 旋转机械轴承振动信号分析方法研究[D]. 重庆:重庆大学, 2014.
- [15] ZHAO J, LI H, LIU J, et al. Planetary gearboxes fault diagnosis based on EMD and EDT[C]//Prognostics and System Health Management Conference. [S. l.]: IEEE, 2016: 1-5.
- [16] 高爽. 齿轮故障特征参数提取及最佳特征参数选择研究[D]. 沈阳:沈阳航空航天大学, 2017.
- [17] LI K, PING X, WANG H, et al. Sequential fuzzy diagnosis method for motor roller bearing in variable operating conditions based on vibration analysis[J]. Sensors, 2013, 13(6): 8013-8041.
- [18] LI K, CHEN P, WANG S. An intelligent diagnosis method for rotating machinery using least squares mapping and a fuzzy neural network [J]. Sensors, 2012, 12(5):5919-5939.
- [19] 高晓光. 离散动态贝叶斯网络推理及其应用[M]. 北京:国防工业出版社, 2016:44-77.
- [20] 朱金林. 基于贝叶斯网络的缺失数据系统故障诊断研究[D]. 无锡:江南大学, 2013.
- [21] 朱金林, 张正道, 潘丰. 基于动态贝叶斯网络的缺失数据系统故障辨识[J]. 信息与控制, 2013, 42(4): 499-505.  
ZHU Jinlin, ZHANG Zhengdao, PAN Feng. Fault identification for missing data systems with a dynamic Bayesian network approach [J]. Information and Control, 2013, 42(4): 499-505. (in Chinese)
- [22] 朱显辉, 崔淑梅, 师楠, 等. 电动汽车电机可靠性的灰色预测模型[J]. 电机与控制学报, 2012, 16(8):42-46.  
ZHU Xianhui, CUI Shumei, SHI Nan, et al. Grey prediction model of motor reliability of electric vehicle [J]. Electric Machines and Control, 2012, 16(8):42-46. (in Chinese)



**第一作者简介:**李仲兴,男,1963年11月生,博士、教授、博士生导师。主要研究方向为故障诊断与容错控制、电动车技术等。曾发表《永磁无刷直流电机漏电故障分析及诊断》(《华中科技大学学报(自然科学版)》2018年第46卷第2期)等论文。  
E-mail:zhxli@ujs.edu.cn

**通信作者简介:**薛红涛,男,1978年9月生,博士、副教授、硕士生导师。主要研究方向为状态监测与故障智能诊断、振动分析、信号处理及特征提取。  
E-mail:xueht@ujs.edu.cn