

基于信息融合的汽车衡称重传感器故障诊断

林海军, 滕召胜, 迟海, 吴阳平, 易钊

(湖南大学 电气与信息工程学院, 湖南长沙 410082)

摘要: 传统汽车衡不具备故障诊断功能, 任一称重传感器发生故障都将导致称重系统失效. 为此提出了一种基于信息融合的汽车衡称重传感器故障诊断方法, 利用径向基函数神经网络(RBFNN)逼近汽车衡多路称重传感器之间的函数关系, 预测各传感器的输出, 并给出RBFNN的训练算法; 以各传感器的预测信号与实测信号为输入, 建立了融合检测模型, 采用表决融合检测准则, 完成故障传感器寻址、故障类型识别、故障程度判决和故障传感器正常输出估计等故障诊断. 大量实验与现场检定证明, 采用这种方法的汽车衡准确实现了称重传感器故障诊断, 任一称重传感器失效后的汽车衡性能优于正常状态下4级秤的指标, 其最大称重误差 $\leq 0.7\%$, 提高了系统可靠性.

关键词: 汽车衡; 称重传感器; 故障诊断; 信息融合; 径向基神经网络

中图分类号: TP206 **文献标识码:** A

Diagnosis for load cells in truck scale based on information fusion

LIN Hai-jun, TENG Zhao-sheng, CHI Hai, WU Yang-ping, YI Zhao

(College of Electrical and Information Engineering, Hunan University, Changsha Hunan 410082, China)

Abstract: Conventional truck scale without fault diagnosis will be disabled when anyone load cell is going wrong in operation. A fault-diagnosis method for load cells is proposed based on information-fusion technique. The radial-basis-function-neural-network(RBFNN) with a training algorithm is employed to approximately model the internal relations among load cells for predicting their outputs. The prediction outputs together with the real outputs of the load cells are sent to a fusion-detection model developed by us. This model employs the criterion of voting-fusion-diagnosis to generate the fusion-diagnosis results, which include locations of faulty load cells, the types and the degrees of faults, the estimated outputs of faulty load cells in normal operating condition. Field tests show that the truck scale installed with the proposed diagnostic facilities discriminates load cells precisely. In the case of one faulty cell, its maximum weighing error is less than 0.7%, exhibiting a performance better than that of a 4th class scale under normal operating condition.

Key words: truck scale; load sensor; fault-diagnosis; information fusion; radial-basis-function-neural-network

1 引言(Introduction)

传统汽车衡利用并联电路连接方式, 在模拟接线盒中将多路称重传感器的输出信号累加, 获得一个与被测载荷质量成比例的电压信号, 并传送至称重仪表, 完成被测载荷称重. 这种方法使汽车衡丧失了故障诊断功能, 任一传感器出现故障都将导致称重系统失效^[1]. 文献[2]给出了汽车衡称重传感器亚健康的故障特征, 利用空载与加载标准砝码时各传感器的输出信息, 完成传感器的故障诊断, 但这种方法需要较多的人工干预, 自动化程度低. 根据称重传感器对称分布关系, 当某一传感器失效时, 利用其相应的对称传感器输出代替失效传感器的输出^[1], 然而若汽车衡发生偏载, 将会影响该方法的诊断效果.

信息融合方法在故障诊断中得到了广泛应用^[3,4]. 径向基函数神经网络(RBFNN)具有很强的逼近非线性函数能力和自学习功能, 收敛速度快, 鲁棒性好, 已成为多传感器信息融合的一种有效工具^[5~7]. 据此, 本文提出了一种基于RBFNN信息融合的汽车衡称重传感器故障诊断方法, 利用RBFNN逼近汽车衡多路称重传感器之间的函数关系, 预测各传感器输出; 同时建立称重传感器故障融合检测模型, 完成故障传感器寻址、故障类型识别、故障程度判决与故障传感器输出信号估计等. 大量实验和现场检定表明, 这种方法能够准确实现汽车衡称重传感器的故障诊断, 提高了汽车衡的性能, 方便了汽车衡的现场维护.

2 汽车衡称重原理(Weighing principle of truck scale)

图1为汽车衡8路称重传感器的分布示意图. 设 x_i 为第 i 路称重传感器的称重信号($i = 1, 2, \dots, 8$), 则汽车衡输出的称重结果 y 为

$$y = k_1x_1 + k_2x_2 + \dots + k_8x_8 = \sum_{i=1}^8 k_ix_i, \quad (1)$$

其中 k_i 是为称重传感器通道增益.




图1 汽车衡8路称重传感器分布图

Fig. 1 Distribution of eight load cells in truck scale

3 汽车衡称重传感器故障诊断原理(Fault diagnosis principle of load cell)

基于信息融合的汽车衡称重传感器故障诊断方法利用RBFNN, 逼近汽车衡多路称重传感器之间的函数关系, 预测各传感器的输出, 并以预测值与实测值为输入, 建立融合检测模型, 完成故障传感器寻址、故障类型识别、故障程度判决与故障传感器正常输出估计等. 其诊断原理如图2所示. 图中, 系统首先通过选择开关工作在训练模式下, 即利用离线训练网络完成预测网络(RBFNN)的离线训练, 并将网络各参数保存在预测网络中; 训练完成后, 系统利用在线检测网络, 完成传感器故障诊断. $\mathbf{x} = (x_1, x_2, \dots, x_8)^T$ 为系统输入, \tilde{x}_n 为预测网络的输出.

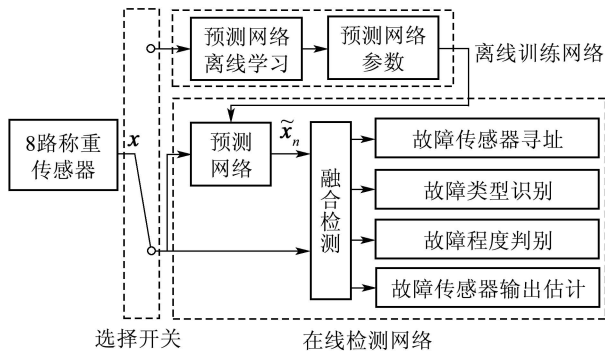


图2 基于信息融合的汽车衡称重传感器故障诊断原理

Fig. 2 Principle of fault diagnosis for load cells in truck scale based on information fusion

3.1 称重传感器故障类型(Fault type of load cells)

实践证明, 弹性体疲劳与损伤、电桥及其外围电路损坏、粘贴工艺失效、雷击、受潮、机械冲击等都

将造成称重传感器发生故障^[1,2], 其故障类型可大致分为:

1) 短路与开路故障. 电桥及其外围电路或传感器引线等发生短路或开路, 使得称重传感器的输出信号 x_i 恒为最大极限值 x_{imax} 或最小极限值 x_{imin} , 如图3(a)(b)所示, 图中 M 为载荷重量.

2) 零点故障. 称重传感器因零点改变, 空载时输出 x_i 不为0, 如图3(c)所示, 图中 M_{i0} 为正常状态下的输出.

3) 灵敏度故障. 由于弹性体疲劳或部分损坏等, 称重传感器的灵敏度 S_i 发生改变, 从而使得传感器的输出 x_i 产生误差, 如图3(d)所示, 图中 M_{i0} 为正常状态下的输出.




图3 称重传感器故障类型示意图

Fig. 3 Fault type of load cells

3.2 预测网络模型(Model of predictive network)

实验发现, 汽车衡各称重传感器的输出相互关联, 存在某种函数关系, 即

$$\begin{cases} x_1 = \varphi_1(x_2, x_3, \dots, x_8), \\ x_2 = \varphi_2(x_1, x_3, \dots, x_8), \\ \vdots \\ x_8 = \varphi_8(x_1, x_2, \dots, x_7), \end{cases} \quad (2)$$

即

$$x_n = \varphi_n(x_1, x_2, \dots, x_i, \dots, x_8), \quad n, i = 1, 2, \dots, 8; i \neq n. \quad (3)$$

式(2)(3)表明, 传感器 n 的输出是其他7路传感器输出的函数. 以其他7路传感器的称重信号为输入, 利用RBFNN逼近式(3), 从而完成传感器输出结果的预测. 其模型如图4所示.

图中, \tilde{x}_n 为传感器 n 的预测信号, 其值为

$$\tilde{x}_n = b + \sum_{j=1}^m w_j h_j = \sum_{j=0}^m w_j h_j = W^T H, \quad (4)$$

式中: 隐层神经元的个数 m 可由实验确定; W 为RBFNN的权矩阵, $W = (w_0, w_1, \dots, w_m)^T$, 其中 $w_0 =$

1; H 为径向基函数矩阵, $H = (h_0, h_1, \dots, h_m)^T$, 其中 $h_0 = b$; b 为输出层偏置值。




图4 称重传感器 n 的RBFNN预测模型

Fig. 4 Predictive model of load cell n based on RBFNN

如果采用高斯函数作为网络的基函数, 则

$$h_j = \exp\left(-\frac{\|x - c_j\|^2}{2r_j^2}\right), j = 1, 2, \dots, m. \quad (5)$$

式中: r_j 为第 j 个节点的扩展常数; x 为输入矢量,

$$x = (x_1, x_1, \dots, x_{n-1}, x_{n+1}, \dots, x_8)^T;$$

c_j 为第 j 个节点的中心矢量,

$$c_j = (c_{1,j}, c_{2,j}, \dots, c_{n-1,j}, c_{n+1,j}, \dots, c_{8,j})^T;$$

$\|\cdot\|$ 为欧几里德距离^[8]。

利用梯度训练法^[9], 可以实现RBFNN的训练, 设 x_{ti} 为网络的目标输出, 则RBFNN学习的目标函数为

$$E_e = \frac{1}{2} \sum_{i=1}^7 \eta_i e_i^2, \quad (6)$$

式中: η_i 为遗忘因子; e_i 为误差信号, 且

$$e_i = x_{ti} - \left[b + \sum_{j=1}^m w_j \exp\left(-\frac{\|x - c_j\|^2}{2r_j^2}\right) \right]. \quad (7)$$

分别求 c_j, r_j, w_j 和 b 对 e_i 的梯度, 并考虑所有训练样本、遗忘因子 η_i 和学习率 μ 的影响, c_j, r_j, w_j 和 b 的调节量分别为

$$\begin{cases} \Delta c_j = \mu \frac{w_j}{r_j^2} \sum_{i=1}^7 \eta_i e_i \|x - c_j\| \exp\left(-\frac{\|x - c_j\|^2}{2r_j^2}\right), \\ \Delta r_j = \mu \frac{w_j}{r_j^3} \sum_{i=1}^7 \eta_i e_i (\|x - c_j\|^2) \exp\left(-\frac{\|x - c_j\|^2}{2r_j^2}\right), \\ \Delta w_j = \mu \sum_{i=1}^7 \eta_i e_i \exp\left(-\frac{\|x - c_j\|^2}{2r_j^2}\right), \\ \Delta b = \mu \sum_{i=1}^7 \eta_i e_i. \end{cases} \quad (8)$$

式中 $j = 1, 2, \dots, 8$. 式(4)(5)为称重传感器 n 的基于RBFNN预测模型。

3.3 融合检测(Fusion detection)

融合检测以8路称重传感器的预测信号及实测信

号为输入, 利用表决融合检测准则, 完成故障传感器寻址、故障类型识别、故障程度判决和故障传感器正常输出估计等功能。

1) 故障传感器寻址。

设 $x_{n,k}$ 为载荷加载在汽车衡位置 k 时传感器 n 的输出信号($n = 1, 2, \dots, 8; k = 1, 2, \dots, K; K$ 为融合次数, 取奇数), $\tilde{x}_{i,k}$ 为利用预测网络获得的预测值(第1次预测值), ε_n 为传感器 n 的融合检测阈值, 若任一传感器失效, 都将满足

$$|x_{n,k} - \tilde{x}_{n,k}| > \varepsilon_n. \quad (9)$$

设传感器 i 失效, 以其他7路正常传感器的实测信号 $x_{n,k}$ ($n \neq i$)为输入, 再次利用预测网络, 得到传感器 i 的第2次预测值 $\tilde{\tilde{x}}_{i,k}$, 此时有 $\tilde{\tilde{x}}_{i,k} = \tilde{x}_{i,k}$; 以预测值 $\tilde{\tilde{x}}_{i,k}$ 与其他7路正常传感器中的任意6路实测信号 $x_{n,k}$ ($n \neq i$)为输入, 获得其余7路传感器的第2次预测值。因逼近故障传感器 i 的正常输出, 使得^[10]

$$\begin{cases} |x_{i,k} - \tilde{\tilde{x}}_{i,k}| > \varepsilon_i, \\ |x_{r,k} - \tilde{\tilde{x}}_{r,k}| \leq \varepsilon_r, r \neq i. \end{cases} \quad (10)$$

式中 $\varepsilon_i, \varepsilon_r$ 分别为传感器 i, r 的检测阈值。改变载荷加载位置, 连续检测 K 次。设当满足式(10)时, 决策值 u_1 为1, 决策值 u_0 为0; 否则 u_1 为0, u_0 为1, 则有

$$\begin{cases} M_0 = \sum_{k=1}^K u_0, \\ M_1 = \sum_{k=1}^K u_1. \end{cases} \quad (11)$$

若 $M_1 > M_0$, 则判定传感器 i 发生故障; 否则正常。即

$$L_i = \begin{cases} 1, & M_1 > M_0, \\ 0, & M_1 < M_0. \end{cases} \quad (12)$$

当 $L_i = 1$ 时, 称重传感器 i 发生故障; 同时给出故障传感器的编号 i , 完成故障传感器寻址。

2) 传感器故障类型识别。

a) 短路或开路故障识别。由图3(a)(b)可以看出, 如果称重传感器 i 发生短路或开路故障, 其输出 $x_{i,k}$ 恒为最大极限值 x_{imax} 或最小极限值 x_{imin} 。设 $F_i(00)$ 为开路故障; $F_i(01)$ 为短路故障, 则

$$F_i(00) = \begin{cases} 1, & \text{如果 } x_{i,k} \leq x_{imin} \text{ 且 } L_i = 1, \\ 0, & \text{其他。} \end{cases} \quad (13)$$

$$F_i(01) = \begin{cases} 1, & \text{如果 } x_{i,k} \geq x_{imax} \text{ 且 } L_i = 1, \\ 0, & \text{其他。} \end{cases} \quad (14)$$

b) 零点故障与灵敏度故障识别。将载荷加载在汽车衡位置 k , 改变加载位置, 使之满足

$$x_{i,1} < x_{i,2} < \cdots < x_{i,k} < \cdots < x_{i,K},$$

预测值也将满足

$$\begin{aligned} \tilde{x}_{i,1} < \tilde{x}_{i,2} < \cdots < \tilde{x}_{i,k} < \cdots < \tilde{x}_{i,K}, \\ i = 1, 2, \cdots, 8; k = 1, 2, \cdots, K, \end{aligned}$$

若称重传感器的实际值与预测值的误差 $e_{i,k}$ ($e_{i,k} = x_{i,k} - \tilde{x}_{i,k}$)均相等,即误差的一阶差分

$$\begin{aligned} \Delta e_{i,k} &= e_{i,k} - e_{i,k+1}, \\ i &= 1, 2, \cdots, 8; k = 1, 2, \cdots, K-1 \end{aligned}$$

均为0时,称重传感器发生零点故障 $F_i(10)$,如图3(c)所示.若误差均满足

$$\begin{aligned} e_{i,k} &< e_{i,k+1}, \\ i &= 1, 2, \cdots, 8; k = 1, 2, \cdots, K-1, \end{aligned}$$

即误差的一阶差分 $\Delta e_{i,k}$ 均小于0时,称重传感器发生灵敏度故障 $F_i(11)$,如图3(d)所示.即

$$F_i(10) = \begin{cases} 1, & \text{如果 } \sum_{k=1}^{K-1} \Delta e_{i,k} = 0, \Delta e_{i,k} = 0, L_i = 1, \\ 0, & \text{其他} \end{cases} \quad (15)$$

$$F_i(11) = \begin{cases} 1, & \text{如果 } \sum_{k=1}^{K-1} \text{sgn}(\Delta e_{i,k}) = 1 - K, L_i = 1, \\ 0, & \text{其他.} \end{cases} \quad (16)$$

式中 $\text{sgn}(\cdot)$ 为符号函数.

实际中称重传感器的输出信号会受噪声干扰,当发生零点故障时,将有 $|\Delta e_{i,k}| < e_\varepsilon$ (e_ε 为阈值).为了减少阈值 e_ε 对判决结果的不利影响,同时考虑到发生零位故障时,实际值与预测值的误差 $\Delta e_{i,k} = A_i > 0$ (正零位)或 $\Delta e_{i,k} = A_i < 0$ (负零位),则式(15)可以修改为

$$F_i(10) = \begin{cases} 1, & \text{如果 } \left| \sum_{k=1}^{K-1} \text{sgn}(\Delta e_{i,k}) \right| < K-1, \text{且} \\ & \left| \sum_{k=1}^{K-1} \text{sgn}(e_{i,k}) \right| = K-1, L_i = 1, \\ 0, & \text{其他.} \end{cases} \quad (17)$$

3) 故障程度判定.

系统根据各称重传感器的实测信号 x_i 、预测信号 \tilde{x}_i 以及先验知识,利用融合检测,确定各传感器的故障程度,预测故障趋势,为称重系统提供预警信号,提高系统可靠性.

称重传感器故障程度判定采用模糊判决方法,以称重传感器实测信号与预测信号的相对误差绝对

值 $dx_i(dx_i = |(x_i - \tilde{x}_i)/\tilde{x}_i|)$ 和先验故障程度判定值为输入变量,采用2维模糊结构和5级变量形式.表1为模糊决策表,先验故障程度判定值 F_0 的语言变量为正常,轻微,中,较大,完全故障; dx_i 的语言变量为很小,小,中,较大,很大,取三角形函数作为其隶属度函数^[11].

4) 故障传感器正常输出估计.

若检测到某一传感器失效,系统根据预测信号可估计获得故障传感器正常状态下的输出.设故障传感器 i 正常输出的估计值为 \hat{x}_i ,则有

$$\hat{x}_i = \frac{1}{M_1} \sum_{k=1}^K \tilde{x}_{i,k}, \text{ 如果 } |x_{i,k} - \tilde{x}_{i,k}| > \varepsilon_i, \quad (18)$$

式中 M_1 如式(11)所示.

将 \hat{x}_i 与其他正常传感器的称重信号代入式(1),即可得到故障状态下汽车衡的称重结果,从而实现无间断测量.

表1 故障程度判决模糊规则表

Table 1 Fuzzy rule for deciding faulty degree

F_0	dx_i				
	很小	小	中	较大	很大
正常	正常	轻微	中	较大	完全
轻微	轻微	轻微	中	较大	完全
中	轻微	中	中	较大	完全
较大	中	较大	较大	完全	完全
完全	完全	完全	完全	完全	完全

3.4 融合检测阈值 ε_n 的确定(Decision for threshold ε_n of fusion detection)

融合检测阈值 ε_n ($n = 1, 2, \cdots, 8$)影响检测的准确度,若 ε_n 偏大,则漏警率增大;若 ε_n 偏小,则虚警率增大.为提高检测准确度,可采用 $3\sigma_n$ 检测方法,即 $\varepsilon_n = 3\sigma_n$.这里, σ_n 为正常状态下误差 $e_{n,k}$ 的方差,即有

$$\sigma_n = \sqrt{\frac{1}{L-1} \sum_{k=1}^L (e_{n,k} - \bar{e}_{n,k})^2}, \quad (19)$$

式中: L 为误差数据的个数; $\bar{e}_{n,k}$ 为误差均值,即

$$\bar{e}_{n,k} = \frac{1}{L} \sum_{k=1}^L e_{n,k}. \quad (20)$$

4 实验与结果分析(Results and analysis)

利用基于信息融合的汽车衡称重传感器故障诊断方法对SCS-40型汽车衡进行了多次实验,均获得了良好的效果.该汽车衡的最大量程为40 t,采用8路称重传感器,每个传感器的最大容量为20 t.为了简便而不失一般性,从8路称重传感器中任取一路,本文以称重传感器2为诊断对象.通过实验获得

传感器2的最大极限值 $x_{2\max}$ (归一化)为0.9, 最小极限值 $x_{2\min}$ (归一化)为0.0035; 融合检测阈值 ε_2 (归一化)为0.016591; $L = 20$; 融合次数 $N = 5$.

4.1 预测网络的RBFNN训练(Training RBFNN in predictive network)

利用不同重量标准砝码(如0.5 t, 1 t, 6 t, 12 t, ...)加载在汽车衡的不同位置, 采集135组8路称重传感器输出信号, 经数据预处理后, 得到归一化数

$$C = \begin{bmatrix} 0.00471 & 0.00737 & 0.00524 & 0.00795 & 0.00654 & 0.01253 & 0.05840 & 0.00922 & 0.00674 & 0.00899 \\ 0.00203 & 0.00866 & 0.00172 & 0.00286 & 0.00314 & 0.08201 & -0.00706 & 0.00013 & 0.00927 & 0.00693 \\ 0.00579 & 0.00991 & 0.00131 & 0.00248 & 0.00231 & -0.05992 & 0.09566 & 0.00768 & 0.00344 & 0.00439 \\ 0.00667 & 0.00504 & 0.00219 & 0.00915 & 0.00416 & -0.01540 & 0.09007 & 0.00947 & 0.00595 & 0.00701 \\ 0.00677 & 0.00629 & 0.00106 & 0.00015 & 0.00299 & 0.12495 & 0.01040 & 0.00813 & 0.00616 & 0.00610 \\ 0.00943 & 0.00793 & 0.00141 & 0.00591 & 0.00673 & 0.00163 & 0.04395 & 0.00924 & 0.00003 & 0.00299 \\ 0.00770 & 0.00449 & 0.00457 & 0.00543 & 0.00938 & 0.05889 & 0.01315 & 0.00199 & 0.00982 & 0.00856 \end{bmatrix},$$

$$R = (0.01121 \ 0.02916 \ 0.00975 \ 0.04056 \ 0.03334 \ 0.29846 \ 0.10232 \ 0.02584 \ 0.00429 \ 0.00059),$$

$$W = (1 \ 0.05744 \ 0.07439 \ 0.08068 \ 0.06381 \ 0.02513 \ -0.38330 \ 0.13939 \ 0.09461 \ 0.08159 \ 0.09303)^T,$$

$$b = 0.29562.$$

每完成一次7路称重信号(x_1, x_3, \dots, x_8)^T采集与数据预处理后, 系统将数据 \mathbf{x} 与RBFNN各参数 C, R, W 和 b 代入式(4), 经计算、去归一化等, 即可得到称重传感器2的预测值. 图5(a)为称重传感器2的预测值与实测值比较; 图5(b)为两者的误差. 从图中可以看出, 基于RBFNN的预测网络能够较好地预测称重传感器2的输出, 其误差较小.




图5 称重传感器2的预测值与实测值比较

Fig. 5 Predictive output and actual output of load cell 2

据 \mathbf{x} , 其中110组用于训练RBF神经网络(x_1, x_3, \dots, x_8 等7路数据作为输入, x_2 作为目标输出), 25组用于网络测试. 采用式(8)对RBF神经网络进行离线训练. 当均方误差(MSE)目标为0.0000001, 学习率 μ 为0.005, 遗忘因子 η_i 均为0.85, 隐层神经元数目 m 为10时, 经多次仿真与实验发现RBFNN效果最好. 网络结束训练后, 各网络参数 C (中心矢量)、 R (扩展常数)、 W (权值矩阵)和 b (输出层偏置)如下:

4.2 称重传感器故障诊断方法仿真(Simulation for load cells with this proposed method)

预测网络训练完成后, 对处于正常工作状态、开路故障状态、短路故障状态、零点故障状态和灵敏度故障状态下的称重传感器2进行了多次仿真与测试, 其部分仿真结果如图6、7所示.

图6(a), 7(a)为传感器2的实测值、预测值与正常工作状态输出值的比较; 图6(b), 7(b)为传感器2的故障检测仿真; 图6(c), 7(c)为传感器2的故障类型识别仿真. 由图6可知, 当传感器2的输出 $x_{2,k}$ 在 h_1 与 h_2 点发生突变时(图6(a)所示), 系统将 $\tilde{x}_{2,k}, \hat{x}_{2,k}$ 与融合检测阈值 ε_2 比较, 由于均满足式(9)、式(10), 因此检测到此时传感器2发生故障(图6(b)所示). 同时, h_1 之后的8个测试点由于 $x_{2,k}$ 小于最小极限值 $x_{2\min}$, 即满足式(13), 系统判定传感器2发生开路故障 $F_2(00)$; h_2 之后的7个测试点由于 $x_{2,k}$ 大于最大极限值 $x_{2\max}$, 即满足式(14), 系统判定传感器2发生短路故障 $F_2(01)$. 由图7可知, h_3 之后的8个测试点, 由于均满足式(9)、式(10)(图7(b)所示)与式(17)(图7(c)所示), 系统判定发生零点故障 $F_2(10)$; h_4 之后的9个测试点, 由于均满足式(9)、式(10)(图7(b)所示)且 $\Delta e_{2,k}$ 均小于0(图7(c)所示), 即满足式(16), 系统判定发生灵

敏度故障 $F_2(11)$.




图6 开路与短路故障诊断

Fig. 6 Diagnosis for open-circuit fault and short-circuit fault

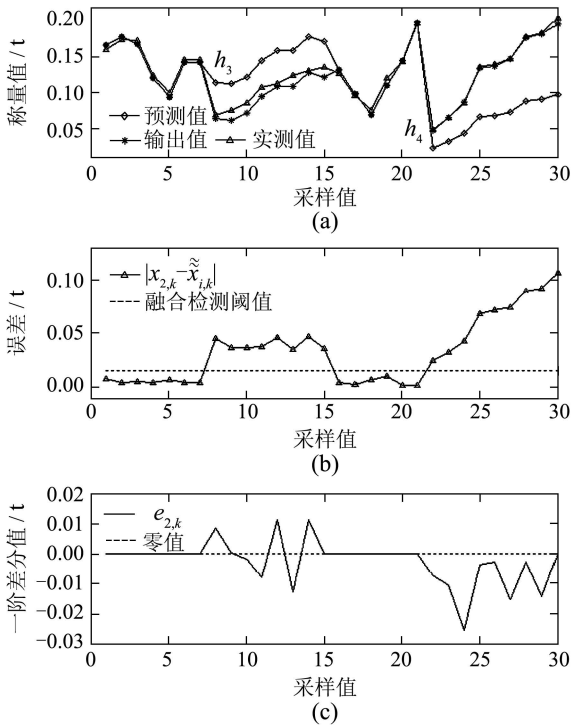


图7 零点与灵敏度故障诊断

Fig. 7 Diagnosis for zero fault and sensitivity fault

4.3 汽车衡现场检定 (Verification in field)

任一称重传感器失效后,系统将给出失效传感器正常输出的估计信号,并与其他正常传感器的

称重信号同时代入式(1),即可得到故障状态下汽车衡的称重结果.

表2为按照国家标准JJG539-97《数字指示秤检定规程》的要求^[12],对采用基于信息融合的汽车衡称重传感器故障诊断方法的SCS-40型汽车衡进行现场检定的结果.由表可知,汽车衡的性能优于国家标准规定的4级秤指标^[12],其最大称量误差 $\leq 0.7\%$,避免了采用传统方法所导致的称重系统失效.

表2 汽车衡检定结果

Table 2 Verification results of truck scale

检定项目	置零准确度 (0~5)	称量/t (5~20)	称量/t (20~40)	重复性
实测	+2 kg	+33 kg	+31 kg	+39 kg
偏差	—	0.66%	0.16%	0.10%
允差(4级)	± 5 kg	1.0%	0.5%	20 kg

5 结论(Conclusions)

传统的汽车衡由于不具备故障诊断功能,任一称重传感器发生故障都将导致称重系统失效.本文采用了一种基于信息融合的汽车衡称重传感器故障诊断方法,利用RBFNN,建立了各传感器输出预测模型和传感器故障融合检测模型,实现了故障传感器寻址、故障类型识别、故障程度判决与故障传感器正常输出估计等功能,提高了汽车衡的性能,减少了称重误差,方便了汽车衡的维护.现场检定表明,当任一称重传感器失效时,采用该方法的汽车衡性能优于国家标准规定的4级秤指标,其最大称量误差 $\leq 0.7\%$,避免了采用传统方法导致的称重系统失效;样机已经通过国家质量技术监督部门的测试检定,并开始批量生产.

参考文献(References):

- [1] BLISS D, STICKEL C, BENTZ J W. Load cell diagnostics and failure prediction weighing apparatus and process[P]. *United State Patent: 728638*, 2000.
- [2] 肖兴华. 称重传感器亚健康及早诊断方法[J]. *衡器*, 2007, 36(1): 41-42. (XIAO Xinghua. Early diagnostic method for load cells' sub-health[J]. *Weighing Apparatus*, 2007, 36(1): 41-42.)
- [3] KAI G, YAN W Z. Correcting sensor drift and intermittency faults with data fusion and automated learning[J]. *IEEE Systems Journal*, 2008, 2(2): 189-197.
- [4] WEI S Z, JIN N D. Fault diagnosis system based on information fusion and embedded internet[C] // *Proceedings of IEEE International Conference on Integration Technology*. China: IEEE Press, 2007: 203-207.

- [5] XU K J, LI Q L, MEI T, et al. Estimation of wrist force/torque using data fusion of finger force sensors[J]. *Measurement*, 2004, 36(1): 11 – 19.
- [6] FAN C L, JIN Z H, ZHANG J, et al. Application of multi-sensor data fusion based on RBF neural networks for fault diagnosis of SAMS[C] // *Proceedings of IEEE the 7th International Conference on Control, Automation, Robotics and Vision (ICARCV'02)*. Singapore: IEEE Press, 2002: 1557 – 1562.
- [7] ZHANG J, WANG B S, MA Y G, et al. Fault diagnosis of sensor network using information fusion defined on different reference sets[C] // *Proceedings of IEEE International Conference on Radar (CIE'06)*. China: IEEE Press, 2006: 1 – 5.
- [8] 陈俊风, 任子武, 伞冶. 径向基函数神经网络的一种两级学习方法[J]. *控制理论与应用*, 2008, 25(4): 655 – 660.
(CHEN Junfeng, REN Ziwu, SAN Ye. Two-level learning hierarchy for the radial basis function networks[J]. *Control Theory & Applications*, 2008, 25(4): 655 – 660.)
- [9] NICOLAO B K. Reformulated radial basis neural networks trained by gradient descent[J]. *IEEE Transactions on Neural Networks*, 1999, 10(3): 657 – 671.
- [10] 房方, 牛玉广, 孙万云, 等. 控制系统传感器故障的两次预测诊断方法[J]. *中国电机工程学报*, 2001, 21(11): 14 – 18, 23.
(FANG Fang, NIU Yuguang, SUN Wangyun, et al. Twice predictive method of control system sensor fault diagnosis[J]. *Proceedings of the CSEE*, 2001, 21(11): 14 – 18, 23.)
- [11] WANG W J, LEH L. Stability and stabilization of fuzzy large-scale systems[J]. *IEEE Transactions on Fuzzy Systems*, 2004, 12(3): 309 – 315.
- [12] 中华人民共和国国家标准. 数字指示秤检定规程JJG539-97[S]. 北京: 国家技术监督局, 1997: 3 – 11.
(Chinese national standards. *Verification Regulation of Digital Indicating Weighing Instrument*[S]. Beijing: China State Bureau of Technical Supervision, 1997: 3 – 11.)

作者简介:

林海军 (1980—), 男, 博士研究生, 研究方向为智能信息处理、智能容错技术, E-mail: linhaijun801028@126.com;

滕召胜 (1963—), 男, 教授, 博士生导师, 研究方向为智能信息处理、智能测控系统, E-mail: tengzs@126.com;

迟海 (1985—), 男, 硕士研究生, 研究方向为智能容错技术, E-mail: haichi2003@tom.com;

吴阳平 (1987—), 女, 硕士研究生, 研究方向为智能仪器, E-mail: wuyangping@126.com;

易钊 (1975—), 男, 博士研究生, 研究方向为智能测控系统, E-mail: zhaoyi2000@yahoo.com.cn.