

# 基于 PNN 的汽车 ABS 系统中压力调节器和轮速传感器的故障诊断

孙丽娜<sup>1</sup>, 王佳庆<sup>1</sup>, 黄永红<sup>2</sup>

(1. 苏州工业园区职业技术学院 机电工程系, 江苏 苏州 215123;

2. 江苏大学 电气信息工程学院, 江苏 镇江 212013)

**摘要:** 在汽车防抱死制动系统 (ABS) 中, 压力调节器和轮速传感器起着非常重要的作用, 为了进一步完善汽车防抱死制动系统的制动性能, 文中提出一种基于概率神经网络 (PNN) 的压力调节器和轮速传感器的故障诊断方法; 基于高附着均一路面, 起步时制动及单一的压力调节器或者轮速传感器故障的试验数据, 分别建立了基于概率神经网络的压力调节器故障诊断模型和轮速传感器故障诊断模型, 并与 BP 神经网络进行了比较; 仿真结果表明, 利用相同的训练样本集对概率神经网络和 BP 神经网络进行训练时, 基于概率神经网络的压力调节器故障诊断模型和轮速传感器故障诊断模型在训练时间和诊断精度上明显优于 BP 神经网络, 并且利用测试样本对建好的压力调节器故障模型和轮速传感器故障模型进行检测时, 无论测试样本的顺序发生什么变化, 基于概率神经网络的故障模型都能够准确的进行故障识别。

**关键词:** 防抱死制动系统; 压力调节器; 轮速传感器; 概率神经网络

## Fault Diagnosis of Pressure Regulator and Wheel Speed Sensor for Anti-lock Braking System of Automobiles Based on Probabilistic Neural Network

Sun Lina<sup>1</sup>, Wang Jiaqing<sup>1</sup>, Huang Yonghong<sup>2</sup>

(1. Mechatronics Engineering Department, Suzhou Industrial Park Institute of Vocational Technology, Suzhou 215123,

China; 2. School of Electrical and Information Engineering, Jiangsu University, Zhenjiang 212013, China)

**Abstract:** Pressure regulator and wheel speed sensor play an important role in the anti-lock braking system of automobiles. In order to further improve the braking performance of the anti-lock braking system of automobiles, a fault diagnosis method of pressure regulator and wheel speed sensor based on probabilistic neural network is proposed. Based on the test data of braking and single pressure regulator or wheel speed sensor faults when start-up on high adhesion uniform road surface, the fault diagnosis models of pressure regulator and wheel speed sensor based on probabilistic neural network are established respectively, and compared with BP neural network. The simulation results show that when the probabilistic neural network and BP neural network are trained with the same training sample set, the fault diagnosis model of pressure regulator and wheel speed sensor based on probabilistic neural network is obviously superior to BP neural network in training time and diagnostic accuracy, and when the fault models of pressure regulator and wheel speed sensor are detected by the test sample, the fault models based on probabilistic neural network can accurately identify the faults no matter what the order of test samples changes.

**Keywords:** anti-lock braking system; pressure regulator; wheel speed sensor; probabilistic neural network

### 0 引言

随着汽车科技的进步, 汽车的速度在不断地提高, 当汽车在高速下制动或在滑溜路面上制动的过程中, 由于汽车的车轮产生抱死现象, 很可能会出现车尾偏离行驶方向、汽车旋转掉头、驾驶员控制不了汽车行驶方向等危险状况, 从而造成交通事故<sup>[1]</sup>。汽车防抱死制动系统 (anti-lock braking system, ABS) 是指在汽车被要求强制减速或停车时, 为了防止车轮被抱死, 其能够自己主动地控制制动器可达到的最大滚动摩擦力的大小, 使车轮处于边滚边滑

(滑移率在 20% 左右) 的状态, 以保证车轮与地面的附着力在最大值的一种主动安全装置<sup>[2-4]</sup>。

目前针对汽车防抱死制动系统的故障诊断大多采用的是 BP 神经网络, 但是 BP 神经网络存在收敛速度慢、容易陷入局部极小值的问题, 并且在使用 BP 神经网络进行训练时, 即使同一网络模型每次训练的结果也都不相同<sup>[5]</sup>。概率神经网络 (probabilistic neural network, PNN) 是基于 Bayes 分类规则和 Parzen 窗的概率密度函数估计方法发展而来的并行算法<sup>[6-7]</sup>。由于 PNN 结构简单、训练简洁、在故障诊断方面得到了广泛的应用。

在汽车防抱死制动系统中, 压力调节器和轮速传感器起着非常重要的作用, 为了进一步地完善汽车防抱死系统的制动性能, 本文利用概率神经网络对 ABS 系统的压力调节器和轮速传感器进行故障诊断, 并与 BP 神经网络进行了

收稿日期: 2019-09-19; 修回日期: 2019-10-17。

基金项目: 江苏省自然科学基金面上项目 (BK20151345)。

作者简介: 孙丽娜 (1986-), 女, 山东聊城人, 硕士, 讲师, 主要从事复杂过程的智能检测与控制, 复杂系统的故障诊断方向的研究。

比较。结果表明概率神经网络诊断耗时短, 并且网络一旦确定, 训练结果不会改变。

### 1 防抱死制动系统的结构

典型的气动 ABS 系统结构如图 1 所示。

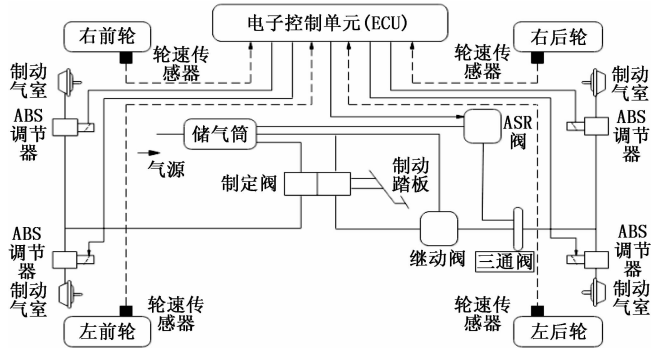


图 1 典型的气动 ABS 系统结构

由图 1 可以看出, 防抱死制动系统主要由轮速传感器、压力调节器 (ABS 调节器)、电子控制单元 (ECU) 三部分组成, 另外还包括制动气室、储气筒、制动踏板、继动阀、三通阀等。压力调节器是汽车防抱死系统中最主要的执行机构, 每个控制通道中各设置一个压力调节器, 每个调节器分别对相应的车轮进行控制。每个车轮上各安装一个转速传感器, 将有关的车轮转速的信号传送到电子控制单元 (electronic control unit, ECU)。ECU 根据各车轮转速传感器输入的信号对各个车轮的运动状态进行监测和判定, 并形成相应的控制指令。压力调节器受 ECU 的控制, 对各制动轮的制动压力进行调节。

如果防抱死制动系统的压力调节器发生了故障, 当踏下制动踏板时, 气体压力将直接进入制动气室, 车轮会突然抱死; 如果汽车防抱死系统的轮速传感器发生了故障, 那么相应车轮轮速就不能被识别而处于独立运行状态, 这时 ABS 调节阀接收不到速度信号将会非常危险。因此对压力调节器和传感器进行故障诊断非常重要。

### 2 概率神经网络

概率神经网络<sup>[8-9]</sup>的结构如图 2 所示。




图 2 概率神经网络结构

在图 2 中,  $R$  为输入向量元素的数目;  $Q$  为输入目标样本的数目;  $K$  是输入向量类别的数目;  $a_i^1$  是向量  $a^1$  的第  $i$  个元素,  $IW^{1,1}$  是权值矩阵  $IW^{1,1}$  的第  $i$  个行向量。

将 PNN 的第一层径向基神经元的输入权值矩阵  $IW^{1,1}$  设为  $Q$  个训练样本对的转置  $P'$ 。当网络获得到输入时, 由

$|dist|$  函数计算得到一个向量。然后将该向量中的元素与偏差向量  $b$  中的元素逐个相乘, 并把计算结果传送给  $radbas$  函数。经过  $radbas$  函数计算之后, 看输入向量与哪一个样本向量最接近, 则  $a^1$  中对应的元素就接近于 1。如果输入向量与一系列训练样本向量都接近的话, 那么对应的几个元素的值都接近于 1。

PNN 的第二层权值矩阵  $LW^{2,1}$  设为期望目标响应  $T$ 。权值矩阵的每一个行向量中只有一个元素的值为 1, 对应着一类输入, 其余元素的值均为 0, 然后计算矩阵乘积  $Ta^1$ 。最后, 第二层神经元采用竞争传递函数计算  $n^2$ , 对其中最大的元素输出为 1, 其余元素取为 0。从而, PNN 就完成了对输入向量的划分。

### 3 ABS 系统故障诊断模型的建立

#### 3.1 输入输出样本的收集与设计

通过分析 ABS 系统的工作原理, 并结合实际的运行经验, 确定网络的输入和输出变量。本文只针对高附着路面, 起车时制动及单一的压力调节器或传感器发生故障时进行研究。

##### 3.1.1 确定网络的输入与输出

在 ABS 系统中, 压力调节器会出现无故障  $F_1$ 、左前调节器故障  $F_2$ 、右前调节器故障  $F_3$ 、左后调节器故障  $F_4$ 、右后调节器故障  $F_5$  共 5 种故障类型。每种类型所对应的纵向车速  $P_1$ 、侧向车速  $P_2$ 、左前轮轮速  $P_3$ 、右前轮轮速  $P_4$ 、左后轮轮速  $P_5$ 、右后轮轮速  $P_6$  的变化趋势不同。因此在对压力调节器进行故障诊断时, 确定  $P_1$ 、 $P_2$ 、 $P_3$ 、 $P_4$ 、 $P_5$ 、 $P_6$  作为压力调节器故障诊断模型的输入变量,  $F_1$ 、 $F_2$ 、 $F_3$ 、 $F_4$ 、 $F_5$  作为压力调节器故障诊断模型的输出。用二进制的形式描述这 5 种故障类型分别为 (1 0 0 0 0), (0 1 0 0 0), (0 0 1 0 0), (0 0 0 1 0), (0 0 0 0 1)。

在 ABS 系统中, 轮速传感器会出现无故障  $Y_1$ 、左前轮传感器故障  $Y_2$ 、右前轮传感器故障  $Y_3$ 、左后轮传感器故障  $Y_4$ 、右后轮传感器故障  $Y_5$  共 5 种故障类型。每种类型所对应的纵向车速  $X_1$ 、侧向车速  $X_2$ 、左前轮轮速  $X_3$ 、右前轮轮速  $X_4$ 、左后轮轮速  $X_5$ 、右后轮轮速  $X_6$  的变化趋势也不同。所以在对轮速传感器进行故障诊断时, 确定  $X_1$ 、 $X_2$ 、 $X_3$ 、 $X_4$ 、 $X_5$ 、 $X_6$  为轮速传感器故障诊断模型的输入变量,  $Y_1$ 、 $Y_2$ 、 $Y_3$ 、 $Y_4$ 、 $Y_5$  为轮速传感器故障诊断模型的输出。用二进制的形式描述这 5 种故障类型分别为 (1 0 0 0 0), (0 1 0 0 0), (0 0 1 0 0), (0 0 0 1 0), (0 0 0 0 1)。

##### 3.1.2 网络输入输出样本的采集

无故障时仿真条件为: 路面附着系数为 0.4, 100% 滑转的附着系数为 0.3, 变速器 5 档, 4 个车轮制动力都为  $4e6N \cdot m$ , 初始车速 22.5 m/s。参数  $K_p$  为 290,  $K_t$  为 70。

压力调节器发生故障的仿真条件为: 把哪个车轮制动力达到最大  $12e6N \cdot m$  (其他仿真条件与无故障时相同), 就认为哪个压力调节器发生故障。在进行数据采集时, 每种故障取 10 个样本 (5 种故障), 即 0.3、0.4、0.5、0.6、1.5、1.8、3.2、3.8、4.2、4.5 s 时的速度值, 总共采集了

50 个样本。

轮速传感器发生故障的仿真条件：把哪个轮速信号断开（其他仿真条件与无故障时相同），就认为哪个轮速传感器发生故障。在进行数据采集时，每种故障取 7 个样本（5 种故障），即 2、2.5、3、3.5、4、4.5、4.7 s 时的速度值，总共采集了 35 个样本。文实验数据来自参考文献 [10]。

### 3.2 故障诊断模型的建立

#### 3.2.1 压力调节器故障诊断模型的建立

针对压力调节器的故障诊断，将 0.3、0.4、0.5、0.6、1.8、3.2、3.8、4.2、4.5 s 时所采集的数据作为训练样本。为了验证概率神经网络的故障诊断能力，本文将概率神经网络与 BP 神经网络进行比较。在 BP 神经网络训练过程中，用 newff 函数构建一个 BP 神经网络。其参数设置如下：隐含层采用对数 S 型传递函数 logsig，输出层采用线性传递函数 purelin，训练函数采用基于 Levenberg-Marquardt 的 BP 算法训练函数 trainlm，网络的最大训练次数设置为 2000，训练误差设置为 0.001。另外，BP 神经网络隐含层节点个数的选取非常重要，本文根据公式（1）确定隐含层节点的取值范围。

$$m = \sqrt{n+l} + \alpha \quad (1)$$

式中， $m$  为网络的隐含层节点的个数， $n$  为网络的输入层节点的个数， $l$  为网络的输出层节点的个数， $\alpha$  为 1~10 之间的常数。从 3.1.1 节可以看出，在对压力调节器进行故障诊断时，输入节点的个数为 6，输出节点的个数为 5，代入公式（1），计算得  $m$  的取值为 4~14。表 1 为隐含层节点在 4~14 范围内时，利用 BP 神经网络对压力调节器进行故障诊断模型的训练结果。

表 1 BP 神经网络训练结果(压力调节器故障)

隐含层节点数	平均误差	均方根误差	训练时间/s	迭代次数
4	0.380 4	0.123 1	26.364 2	1 000
5	0.096 3	0.028 5	0.686 4	15
6	0.076 6	0.026 5	0.998 4	25
7	0.118 9	0.030 3	0.639 6	16
8	0.108 3	0.029 7	1.404 0	40
9	0.082 2	0.028 0	0.561 6	10
10	0.089 6	0.023 5	0.655 2	11
11	0.076 7	0.024 3	0.811 2	12
12	0.060 5	0.023 6	0.826 8	16
13	0.093 0	0.027 5	0.826 8	13
<b>14</b>	<b>0.033 0</b>	<b>0.012 4</b>	<b>0.826 8</b>	<b>12</b>

从表 1 中可以看出，当隐含层节点数为 14 时，网络训练所得到的均方根误差最小，其值为 0.012 4，此时网络的平均绝对误差为 0.033，训练时间为 0.826 8 s，迭代次数为 12 次，此时网络训练过程的误差变化如图 3 所示。

从图 3 中可以看出，当训练次数达到 12 步时，达到了预设的训练误差 0.001，网络训练收敛。

在概率神经网络训练过程中，利用 newpnn 函数建立网




图 3 网络训练过程的误差变化 (压力调节器故障)

络，newpnn 的函数形式为： $net = newpnn(P, T, spread)$ 。其中  $P$  为网络的输入向量， $T$  为网络的输出向量，平滑因子  $spread$  的取值对网络的训练性能产生很大的影响。本文在利用概率神经网络对压力调节器的故障诊断模型进行训练时，平滑因子的取值选取从 0.1~10（间隔为 0.1），训练结果如表 2 所示。

表 2 PNN 平滑因子取值

平滑因子取值	平均绝对误差
0.1~1.6	0
1.7~4.8	0.155 6
4.9~5.2	0.222 2
5.3~6.2	0.311 1
6.3~6.6	0.400 0
6.7	0.488 9
6.8~10	0.555 6

从表 2 中可以看出，当平滑因子取值为 0~1.6 时，网络训练的平均绝对误差为 0。当平滑因子取值为 1.7~10 的过程中，随着平滑因子取值的增大，平均绝对误差也会阶段性的增加。当平滑因子取值为 0~1.6 时，所对应的网络训练时间如表 3 所示。

表 3 PNN 训练时间

平滑因子	训练时间	平滑因子	训练时间/s
0.1	0.499 2	0.9	0.109 2
<b>0.2</b>	<b>0.093 6</b>	1.0	0.156 0
0.3	0.124 8	1.1	0.124 8
0.4	0.156 0	1.2	0.171 6
0.5	0.156 0	1.3	0.140 4
0.6	0.171 6	1.4	0.124 8
0.7	0.140 4	1.5	0.156 0
0.8	0.109 2	1.6	0.156 0

从表 3 中可以看出，当平滑因子的取值为 0.2 时，训练时间最短为 0.093 6，所以平滑因子的取值选为 0.2。和 BP 神经网络相比，BP 神经网络的训练时间是 PNN 的 8.8 倍，PNN 训练后训练数据的分类效果如图 4 所示。

图 4 中的 1、2、3、4、5 分别与压力调节器的无故障、




图 4 PNN 训练后的训练数据的分类效果图  
(压力调节器故障)

左前调节器故障、右前调节器故障、左后调节器故障、右后调节器故障 5 种故障类别相对应。从图 4 中可以看出, 利用 PNN 进行故障诊断时, PNN 网络输出的故障判断类别和故障的实际类别相同, 诊断误差为 0。

### 3.2.2 轮速传感器故障诊断模型的建立

针对轮速传感器的故障诊断, 将 2.5、3、3.5、4、4.5、4.7 s 时所采集的数据作为训练样本。

在 BP 网络训练过程中, 网络的构建函数、参数设置以及隐含层节点的设置范围与压力调节器相同。表 4 为隐含层节点在 4~14 范围内时, 利用 BP 神经网络对轮速传感器进行故障诊断模型的训练结果。

表 4 BP 神经网络训练结果(轮速传感器故障)

隐含层节点数	平均误差	均方根误差	训练时间/s	迭代次数
4	0.062 5	0.024 1	2.511 6	12
5	0.093 7	0.027 0	0.639 6	10
<b>6</b>	<b>0.055 7</b>	<b>0.014 9</b>	<b>0.686 4</b>	<b>11</b>
7	0.099 8	0.029 1	0.748 8	8
8	0.059 5	0.016 2	0.592 8	7
9	0.059 2	0.015 3	0.546 0	7
10	0.075 1	0.023 8	0.702 0	9
11	0.084 7	0.026 2	0.514 8	6
12	0.059 9	0.022 1	0.826 8	11
13	0.104 8	0.027 6	0.530 4	7
14	0.108 2	0.030 0	0.686 4	10

从表 4 中可以看出, 当隐含层节点数为 6 时, 网络训练所得到的均方根误差最小, 其值为 0.014 9, 此时网络的平均绝对误差为 0.055 7, 训练时间为 0.686 4 s, 迭代次数为 11 次, 此时网络训练过程的误差变化如图 5 所示。

从图 5 中可以看出, 当训练次数达到 11 步时, 达到了预设的训练误差 0.001, 网络训练收敛。

在利用概率神经网络对轮速传感器进行故障诊断时, 平滑因子的取值同样选取从 0.1~10, 间隔为 0.1。训练结




图 5 网络训练过程的误差变化  
(轮速传感器故障)

果发现当平滑因子取值为 0.1~10 时, 网络训练的平均绝对误差都为 0, 但是当平滑因子取值为 2.4 时, 训练时间最短为 0.046 8 s, 所以选择平滑因子的取值为 2.4。和 BP 神经网络相比, BP 神经网络的训练时间是 PNN 的 14.7 倍, PNN 训练后训练数据的分类效果如图 6 所示。




图 6 PNN 训练后的训练数据分类效果  
(轮速传感器故障)

图 6 中的 1、2、3、4、5 分别与轮速传感器的无故障、左前轮传感器故障、右前轮传感器故障、左后轮传感器故障、右后轮传感器故障 5 种故障类别相对应。从图 6 中可以看出, 针对轮速传感器的故障诊断, 利用 PNN 进行故障诊断时, PNN 网络输出的判断类别和故障的实际类别相同, 诊断误差也为 0。

对比 BP 神经网络发现, 概率神经网络在压力调节器和传感器进行故障诊断时, 模型的训练时间和训练精度都优于 BP 神经网络。

## 4 结果与分析

### 4.1 压力调节器的故障类别预测

将压力调节器故障在 1.5 s 时所采集的样本数据作为测试样本, 如表 5 所示。利用建好的基于 PNN 的压力调节器故障诊断模型对测试样本进行诊断(文中主要对测试样本的实际故障类别顺序为 1-2-3-4-5 和 1-5-3-2-4 时进行故障诊断), 诊断结果如图 7 和图 8 所示。

表 5 压力调节器故障的测试样本

纵向车速/ (m/s)	横向车速/ (m/s)	左前轮轮速/ (m/s)	右前轮轮速/ (m/s)	左后轮轮速/ (m/s)	右后轮轮速/ (m/s)	实际类别	故障类型
17.781	0	16.615	16.615	16.684	16.684	1	无故障
16.683	5.303 2	0	15.667	0	15.747	2	左前调节器故障
16.683	-5.303 2	15.667	0	15.747	0	3	右前调节器故障
17.236	3.435 8	15.966	16.176	0	16.27	4	左后调节器故障
17.236	-3.435 8	16.176	15.966	16.27	0	5	右后调节器故障

表 6 传感器故障的测试样本

纵向车速/ (m/s)	横向车速/ (m/s)	左前轮轮速/ (m/s)	右前轮轮速/ (m/s)	左后轮轮速/ (m/s)	右后轮轮速/ (m/s)	实际类别	故障类型
15.184	0	14.773	14.773	14.832	14.832	1	无故障
15.184	0	0	14.773	14.832	14.832	2	左前轮传感器故障
15.814	0	14.773	0	14.832	14.832	3	右前轮传感器故障
15.184	0	14.773	14.773	0	14.832	4	左后轮传感器故障
15.814	0	14.773	14.773	14.832	0	5	右后轮传感器故障




图 7 PNN 网络的预测效果 (压力调节器故障的实际类别顺序为 1-2-3-4-5)




图 8 PNN 网络的预测效果 (压力调节器故障的实际类别顺序为 1-5-3-2-4)

结合 7 和图 8 可以看出, 所建立的基于 PNN 的压力调节器故障诊断, 无论测试顺序发生什么变化, PNN 都能准确地进行故障诊断。

#### 4.2 轮速传感器故障类别预测

将轮速传感器故障在 2 s 时采集的样本数据作为测试样本, 如表 6 所示。利用建好的基于 PNN 的轮速传感器故障

诊断模型对测试样本进行诊断 (文中主要对测试样本的实际故障类别顺序为 1-2-3-4-5 和 5-1-4-2-3 时进行诊断), 诊断结果如图 9 和图 10 所示。

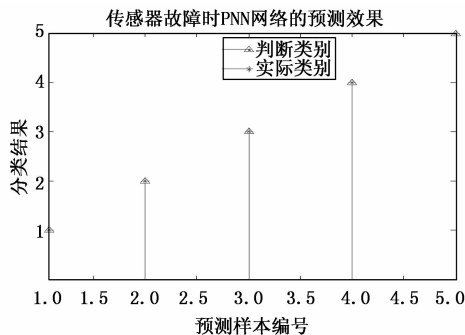


图 9 PNN 网络预测效果 (轮速传感器故障的实际类别顺序为 1-2-3-4-5)




图 10 PNN 网络预测效果 (轮速传感器故障的实际类别顺序为 5-1-4-2-3)

结合图 9 和图 10 可以看出, 无论故障诊断的测试顺序发生什么变化, 所建立的基于 PNN 的轮速传感器故障诊断模型, 都能准确地进行故障诊断。

## 5 结论

本文主要针对 ABS 系统的压力调节器和轮速传感器进行故障诊断。

1) 利用相同的训练样本对 PNN 和 BP 神经网络进行训练。基于 BP 神经网络的压力调节器和轮速传感器的故障诊断模型的训练时间分别是基于概率神经网络的 8.8 和 14.7 倍。另外, 从训练误差上来说, 基于 BP 神经网络的压力调节器和轮速传感器的故障诊断模型训练的均方根误差分别为 0.012 4 和 0.014 9, 而基于 PNN 的压力调节器和轮速传感器的故障诊断模型的训练误差都为 0。

2) 利用测试样本集对基于 PNN 的压力调节器和轮速传感器模型进行检测, 结果表明, 无论压力调节器和轮速传感器实际故障类别顺序发生什么变化, 基于 PNN 的故障诊断模型都能够准确的进行故障识别。

### 参考文献:

[1] 李 强. 汽车 ABS 系统的重要性及工作原理 [J]. 拖拉机与农用运输车, 2007, 34 (1): 10-12.

(上接第 6 页)

[50] Wang L, Ouyang W, Wang X, et al. Visual tracking with fully convolutional networks [A]. IEEE International Conference on Computer Vision. IEEE, 2016: 3119-3127.

[51] Wang N, Yeung D Y. Learning a deep compact image representation for visual tracking [A]. International Conference on Neural Information Processing Systems [C]. Curran Associates Inc. 2013: 809-817.

[52] Wang N, Li S, Gupta A, et al. Transferring rich feature hierarchies for robust visual tracking [J]. Computer Science, 2015: 1-5.

[53] Nam H, Han B. Learning multi-domain convolutional neural networks for visual tracking [A]. IEEE International Conference on Computer Vision [C]. 2015: 4293-4302.

[54] Girshick R, Donahue J, Darrell T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation [Z]. ICCV, 2013.

[55] Girshick, R. Fast R-CNN [Z]. ICCV, 2015.

[56] Ren S, He K, Girshick R, et al. Faster R-CNN: towards real-time object detection with region proposal networks [J]. IEEE Trans Pattern Anal Mach Intell., 2017, 39 (6): 1137-1149.

[57] Redmon J, Divvala S, Girshick R, et al. You only look once: unified, real-time object detection [A]. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR) [C]. IEEE, 2016.

[58] Liu W, Anguelov D, Erhan D, et al. SSD: single shot multi-Box detector [A]. European Conference on Computer Vision [C]. Springer International Publishing, 2016.

[59] Redmon J, Farhadi A. YOLO9000: better, faster, stronger

[2] 孙 毕, 李孝禄. 汽车 ABS 系统内部流动仿真与分析 [J]. 机床与液压, 2014, 42 (7): 115-118.

[3] 辛 舟, 刘志敏. 基于模糊控制下的汽车 ABS 系统研究 [J]. 机械设计与制造, 2009 (4): 142-143.

[4] 陈义庄. 液压控制装置在汽车 ABS 系统上的应用 [J]. 机床与液压, 2014 (4): 171-172.

[5] 杨凌霄, 朱亚丽. 基于概率神经网络的高压断路器故障诊断 [J]. 电力系统保护与控制, 2015, 43 (10): 62-67.

[6] 蒋玉秀, 赵晓欢, 邓元望. 基于概率神经网络的电子油门踏板故障诊断 [J]. 中南大学学报 (自然科学版), 2019, 50 (6): 1370-1377.

[7] 王桂英, 张世军, 潘思尧. 基于神经网络的变压器诊断方法研究 [J]. 计算机测量与控制, 2012, 20 (7): 1760-1762.

[8] 朱 凯, 王正林. 精通 Matlab 神经网络 [M]. 北京: 电子工业出版社, 2010.

[9] 李天玉, 吴 楠. 基于概率神经网络模型的异步电机故障诊断 [J]. 电机与控制应用, 2013, 40 (1): 35-38, 42.

[10] 李洪东. 基于 BP 神经网络在汽车 ABS 系统故障诊断 [D]. 吉林: 吉林大学, 2008.

[A]. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR) [C]. 2016: 6517-6525.

[60] Collins R T, Lipton A J, Kanade T. Introduction to the special section on video surveillance [J]. IEEE Trans on Pattern Analysis & Machine Intelligence, 2000, 22 (22): 745-746.

[61] Matsuyama T. Cooperative distributed vision—dynamic integration of visual perception, action, and communication [A]. Proceedings of Image Understanding Workshop [C]. 1998.

[62] Molyneaux D, Izadi S, Kim D, et al. Interactive environment—aware handheld projectors for pervasive computing spaces [M]. Pervasive Computing, Springer Berlin Heidelberg, 2012: 197-215.

[63] Kim J, Grauman K. Observe locally, infer globally: A space-time MRF for detecting abnormal activities with incremental updates [A]. CVPR 2009. IEEE Conference on Computer Vision and Pattern Recognition, 2009 [C]. IEEE, 2013: 2921-2928.

[64] 胡超超, 刘 军, 张 凯, 等. 基于深度学习的行人和骑行者目标检测及跟踪算法研究 [J]. 汽车技术, 2019 (7): 19-23.

[65] He B G, Chen J, Wang Wei. Behavioral characteristics of self-driving tourists: a case study in Kunming [A]. Proceedings of the 7th International Conference on Traffic and Transportation Studies 2015 [C]. Kunming, 2015: 577-586.

[66] Moon J, Prasad J V R. Minimum-time approach to obstacle avoidance by envelope protection for autonomous UAV [J]. Mechatronics, 2017, 21 (5): 861-875.

[67] Lee S, Kim Y, Kahng H, et al. Intelligent traffic control for autonomous vehicle systems based on machine learning [J]. Expert Systems With Applications, 2020: 144.