

提升小波包和改进 BP 神经网络相融合的新故障诊断算法

谭晓东^{1,2}, 覃德泽^{1,2}

(1. 贺州学院 计算机科学与信息工程学院, 广西 贺州 542899; 2. 广西大学 广西理工科学实验中心, 南宁 530004)

摘要: 针对传统的小波变换和 BP 神经网络应用于故障诊断中存在自适应差、效率低等问题, 提出一种提升小波包和改进 BP 神经网络相融合的新故障诊断算法; 利用插值细分思想, 设计了提升小波包的预测算子和更新算子, 结合传统小波包算法和提升模式的原理, 完成了提升小波包算法的设计, 并将该算法应用于故障信号的消噪和能量特征量的提取; 利用遗传算法优化标准 BP 神经网络的初始权值和阈值, 采用 L-M 算法优化标准 BP 神经网络的搜索方式; 以美国凯斯西储大学提供的滚动轴承实验数据, 将新算法应用于实验中, 分析结果表明: 新故障诊断算法比传统的 BP 神经网络算法具有收敛速度快、诊断精度高等实效性。

关键词: 提升小波包; 遗传算法; L-M 算法; BP 神经网络; 故障诊断

A New Fault Diagnosis Algorithm Combining Lifting Wavelet Packet with Improved BP Neural Network

Tan Xiaodong^{1,2}, Tan Deze^{1,2}

(1. Computer Science and Information Engineering Institute, Hezhou University, Hezhou 542800, China;

2. Guangxi Experiment Centre of Science and Technology, Guangxi University, Nanning 530004, China)

Abstract: According to the problem of poor adaptability and low efficiency when traditional wavelet transform and BP neural network used for fault diagnosis, a new fault diagnosis algorithm for the fusion of lifting wavelet packet and improved BP neural network is proposed. Takes advantage of interpolating subdivision thinking, the prediction operator and update operator of lifting wavelet packet were designed, combining traditional wavelet packet algorithm and the principle of lifting mode, the lifting wavelet packet algorithm's design was completed, and the algorithm was applied in extinction noise and energy feature extraction of fault signal. Use GA algorithm to optimize initial weights and thresholds of standard BP neural network algorithm, and use L-M algorithm to optimize the search of the standard BP neural network. Make use of the rolling experimental data provided by Case Western Reserve University, the new algorithm is applied to the experiment, the results show that: the new fault diagnosis algorithm has faster convergence, higher precision diagnostic effectiveness than the traditional BP neural network algorithm.

Keywords: lifting wavelet packet; GA algorithm; L-M algorithm; BP neural network; fault diagnosis

0 引言

故障诊断的准确性主要取决于诊断算法的实效性和先进性, 传统小波变换具有较好的时域和频域局部化分析能力, 但是, 小波变换以预设的单一小波函数作为分解信号的基函数, 不能根据信号的特点进行自适应分析^[1]。Sweldens 提出的提升小波变换^[2]是一种不依赖傅里叶变换的新的小波构造算法, 通过预测和更新算子的最优设计匹配特定的信号, 具有很好的自适应能力, 非常适合非线性故障信号的分析^[3]。提升小波包算法是提升小波算法的拓展, 不仅继承了提升小波算法的优点, 而且可以将信号频带的低频和低频信号同时进行分解, 解决了提升小波算法不能细分高频部分的弊端, 有利于非平稳故障信号特征量的提取。

神经网络具有很强的非线性处理和自学习等能力, 适合非线性故障的模式识别及分类。国内外已有不少科研工作者应用神经网络并结合小波变换提取故障特征完成故障设备的有效诊

断。文献[4-6]利用小波包算法提取电机振动故障信号的能量特征, 随后建立神经网络实现电机故障的诊断。文献[7-9]利用小波包算法对采集的滚动轴承信号进行消噪, 并提取各频带能量特征, 随后建立特征向量至故障模式之间映射的神经网络, 从而实现滚动轴承的故障诊断。

上述研究成果大部分是采用传统的小波包算法提取设备故障的特征量, 利用传统的神经网络实现故障的分类来达到故障诊断的目的。由于传统的小波包算法过于依赖傅里叶变换, 缺乏自适应能力, 传统的神经网络易陷入局部极小等问题, 基于此, 本文利用提升原理构造提升小波包算法来有效提取故障特征量, 然后利用遗传算法 (genetic algorithm, GA) 优化 BP 神经网络的初始权值、阈值等参数, 以便较好确定网络的搜索空间, 规避随机选取初始权值、阈值造成搜索方向太泛而影响寻优效率, 随后利用 Levenberg-Marquardt (L-M) 算法进行局部空间的精细搜索, 得到最优解或近似最优解, 最终达到高效的故障诊断目的。

1 提升小波包算法的设计

1.1 提升小波变换原理

提升小波变换与传统小波的主要区别在于小波基函数不再是由某一个函数的平移和伸缩而产生, 完全是在时域进行的变

收稿日期: 2013-12-29; 修回日期: 2014-02-26。

基金项目: 广西理工科学实验中心经费资助(LGZXKF201112)。

作者简介: 谭晓东(1974-), 男, 湖南衡阳人, 讲师, 硕士, 主要从事计算机应用方向的研究。

换,不需要傅里叶变换来实现信号在不同频带上的分离。提升算法构成的小波变换过程是主要由分裂、预测和更新 3 个步骤构成,其构造过程^[2]如下:1)分裂是将信号 $X(k)$ 分为偶数序列 $X_e(k)$ 和奇数序列 $X_o(k)$;2)预测是用相邻的偶数序列 $X_e(k)$ 和预测算子 P 估计信号的奇数序列 $X_o(k)$,并将估计误差 $d(k)$ 作为信号的细节分量即高频分量,如式(1)所示;3)更新是指用细节分量 $d(k)$ 和更新算子 U ,更新偶数序列 $X_e(k)$ 以获得信号的逼近分量 $c(k)$ 即低频部分,如式(2)所示。提升算法的重构过程为分解过程的逆运算,可直接由分解过程得到,重构过程的预测算子 P 和更新算子 U 与分解过程一样,如式(3)和(4)所示。

$$d(k) = X_o(k) - P[X_e(k)] \tag{1}$$

$$c(k) = X_e(k) + U[d(k)] \tag{2}$$

$$X_e(k) = c(k) - U[d(k)] \tag{3}$$

$$X_o(k) = d(k) + P[X_e(k)] \tag{4}$$

1.2 提升小波包算法的设计

提升小波包算法是在上述提升算法的基础上,并结合传统小波包算法构造而成,主要包括提升小波包分解算法、重构算法、预测算子及更新算子的设计,其构造思路^[10]主要如下:

1)分裂信号:将信号 $X(k)$ ($k \in Z, Z$ 为正整数集合)分裂为奇数序列 $X_o(k)$ 和偶数序列 $X_e(k)$ 。

$$X_o(k) = \{X_n(2k), k \in Z, n \in Z\} \tag{5}$$

$$X_e(k) = \{X_n(2k+1), k \in Z, n \in Z\} \tag{6}$$

式中, k 为子序列 $X_o(k)$ 和 $X_e(k)$ 的样本序号, n 为分解层数。

2)提升小波包分解算法:小波包分解是将信号的低频和高频部分同时分解,且具有很高的时频分辨率。根据小波包分解算法,并由式(1)和式(2)可得提升小波包经第 n 层分解的各个频带信号的表达式,如式(7)和式(8)所示:

$$X_{n(2^n-1)} = X_{(n-1)2^{n-1}o} - P[X_{(n-1)2^{n-1}e}] \tag{7}$$

$$X_{n2^n} = X_{(n-1)2^{n-1}e} + U[X_{n(2^n-1)}] \tag{8}$$

式中, P 为提升小波包预测算子, U 为提升小波包更新算子。

3)提升小波包重构算法。重构过程是对分解的信号进行筛选,将无用的频带信号置零,把有用的频带信号保留。根据小波包重构算法,同时依据式(3)和式(4),可得如式(9)~式(14)所示的提升小波包的重构算法:

$$X_{(n-1)2^{n-1}e} = X_{n2^n} - U[X_{n(2^n-1)}] \tag{9}$$

$$X_{(n-1)2^{n-1}o} = X_{n(2^n-1)} + P[X_{(n-1)2^{n-1}e}] \tag{10}$$

$$X_{(n-1)2^{n-1}(2k)} = X_{(n-1)2^{n-1}e(k)} \tag{11}$$

$$X_{(n-1)2^{n-1}(2k+1)} = X_{(n-1)2^{n-1}o(k)} \tag{12}$$

...

$$X_{(n-1)1(2k)} = X_{(n-1)1e(k)} \tag{13}$$

$$X_{(n-1)1(2k+1)} = X_{(n-1)1o(k)} \tag{14}$$

4)基于插值细分的预测算子 P 系数和更新算子 U 系数的设计。

插值细分的本质是在初始样本的基础上采用多项式插值方法来获取新的样本值,即只要插值多项式确定,将相邻两个样本的中间位置的插值点代入多项式中,那么便可求出新的样本值^[11],因此,预测算子 P 系数可以通过插值多项式来确定,具体思路如下:

取 M 个已知的样本,假设选取的样本的采样间隔时间是相等的,用 $1, 2, \dots, M$ 表示所对应的采样时刻。假设预测算子系数不受边界影响或受边界影响可忽略不计时,细分产生

的新采样值位于选取样本的中间处,此时根据 Lagrange 插值定理可推导出预测算子系数满足式(15)。

$$P(k) = \prod_{\substack{j=1 \\ j \neq k}}^M \frac{\frac{(M+1)}{2} - j}{k - j} \quad (k = 1, 2, \dots, M) \tag{15}$$

根据式(15),可求得提升小波的预测算子系数。由于等长度的更新算子系数为预测算子系数的一半,因此,当更新算子系数的个数 \tilde{M} 确定,那么即可根据预测算子的系数来确定更新算子的系数^[12]。

2 基于提升小波包的能量故障特征量的提取

由于信号在正常与故障状况下,其能量值存在较大的差异,因此,如果能有效提取不同状况下信号的能量特征量,便可根据能量值来判定哪个频带可能存在故障,且提取的能量故障特征量将用于后续神经网络模型的输入特征量。特征量提取的主要步骤如下:

Step1:信号消噪预处理。对采集信号的数据进行采样点抽取,利用提升小波包进行软阈值法去噪。在一定条件下,文中将通过实验验证基于提升小波的消噪效果优于传统小波的消噪效果。

Step2:选取合适的小波包函数及分解层数并重构信号。信号 X 经过提升小波包 n 层分解后,将得到 2^n 个频带上的子空间信号,那么信号 X 可用这些子空间信号的正交和构成,即

$$X = \sum_{i=0}^{2^n-1} X_{n,i} = X_{n,0} + X_{n,1} + \dots + X_{n,i} \tag{16}$$

式中, $X_{n,i}$ 为信号小波包分解到第 n 层第 i 个节点上的重构信号。

Step3:根据重构信号 $X_{n,i}$,结合 Parseval 定理,由式(16)可计算各频段的能量值为

$$E_{n,i} = \int |X_{n,i}(t)|^2 dt = \sum_{k=1}^m |x_{i,k}|^2 \tag{17}$$

$$(i = 0, 1, 2, \dots, 2^n - 1; k = 1, 2, \dots, m)$$

式中, $x_{i,k}$ 为第 i 个频带信号的离散点幅值, m 为采样点数, $E_{n,i}$ 为信号分解到第 n 层第 i 个节点的频带能量。

Step4:能量归一化。由式(17)可得信号 X 的总能量为

$$E = \sum_{i=0}^{2^n-1} E_{n,i} \tag{18}$$

信号分解至第 n 层时,各频段能量占总能量的百分比(即能量归一)为

$$E(i) = \frac{E_{n,i}}{E} \times 100\% \tag{19}$$

3 基于 GA 和 L-M 组合优化 BP 神经网络的算法设计

标准 BP 神经网络算法的初始权值、阈值随机给定,并采用下降梯度法计算目标函数,从而易陷入收敛速度慢、存在局部最小值等问题。基于此,笔者提出基于 GA 和 L-M 组合算法进行优化 BP 神经网络,使优化后的网络具有更高效的诊断结果。

3.1 GA 优化 BP 神经网络参数

由于 BP 神经网络的初始权值、阈值类似于搜索路径的出发点,出发位置若选择恰当,搜索效率将事半功倍。根据 GA 全局搜索特点,本文采用该算法进行优化训练 BP 神经网络的初始权值、阈值,为后续高效的寻优奠定基础。以本文的滚动

轴承实际故障诊断为例, 优化算法的设计步骤主要如下:

Step1: 确定输入、输出样本集。以提取的各频段故障能量作为网络的输入样本集, 故障类型作为输出样本集;

Step2: 参数编码。随机产生一组权阈值, 考虑实数编码比二进制编码具有更短的编码长度, 故采用实数编码方式进行编码构成权阈值染色体码链。

Step3: 设定合适的种群数目。种群数目过小容易收敛至局部最优, 数目过大容易造成速度降低。

Step4: 确定适应度函数, 并构建父本。由于 GA 优化网络初始权值、阈值目的是为了使网络输出的误差平方和最小, 但 GA 却只能朝着适应度函数值增大的方向进化, 为此, 本文选择网络输出误差的平方和倒数为适应度函数, 如式 (20) 所示。根据式 (20) 计算适应度值, 选择若干适应度值大的个体构成父本。

$$J = \frac{1}{2} \sum_{p=1}^p \sum_{s=1}^s (\hat{y}_s(p) - y_s(p))^2 \quad (20)$$

$$Fit = J^{-1}$$

式中, p 为训练样本个数, s 为网络输出节点数, $\hat{y}_s(p)$ 为网络的期望输出值, $y_s(p)$ 网络当前输出值。

Step5: 利用交叉、变异等遗传操作来进化当前种群, 并由此产生新一代种群。

Step6: 返回 Step4, 使网络初始权值、阈值不断进化, 直至满足性能要求为止。

3.2 L-M 优化 BP 神经网络

L-M 算法实质上是牛顿法和梯度下降法的组合, 将其应用于 BP 神经网络中, 可得网络的权值和阈值的修正公式为:

$$X(k+1) = X(k) - (J^T J + \mu I)^{-1} J^T e \quad (21)$$

式中, J 为网络误差函数对权值、阈值一阶求导的雅可比矩阵; e 为网络误差向量; I 为单位矩阵; μ 为一个不小于零的自适应调整参数。

式 (21) 的 μ 值大小在网络训练过程中将决定着算法的性质, 当 μ 值较小时, 其学习过程主要依赖于牛顿算法, μ 值越小则牛顿算法的权重越大; 当 μ 值较大时, L-M 算法主要依赖于下降梯度算法, μ 值越大则下降梯度算法的权重越大。在迭代中, 只要误差增大, μ 也会增大, 直至误差不增加为止即误差满足最小要求时, μ 值很大, 使 $\mu^{-1} J^T e \approx 0$, 此时网络训练过程终止。

4 诊断实例与分析

为了验证本文提出的提升小波包和改进 BP 神经网络组合式算法在故障诊断中的实效性, 采用美国凯斯西储大学电气工程实验室采集的滚动轴承实验数据^[13]进行故障测试。在实验装置中, 轴承安装于 1.5 kW 电机的转轴上, 利用电火花进行单点损伤, 通过振动加速度传感器进行数据采集, 采样频率为 12 kHz, 采集的数据分为轴承正常、内圈故障、滚动体故障和外圈故障 4 种情况。以采集驱动端的实验数据为训练样本, 风扇端数据为测试样本, 利用提出的新诊断算法分别实现滚动轴承不同故障下的准确诊断, 具体诊断过程如下:

1) 信号消噪处理。分别对采集的 4 种不同信号抽取 1 024 个数据, 利用提升小波和传统小波算法分别对其进行消噪预处理, 两种算法均采用 3 层分解, 传统小波采用全局阈值消噪, 提升小波采用阈值为 $\eta_n = c \times \sigma_n$, 其中 η_n 为第 n 层的阈值, σ_n 为第 n 层的均方差, c 为 2.5~3.5 的取值。图 1 为轴承内圈故障消噪后的效

果, 不难发现, 提升小波包算法的消噪效果更好。

2) 能量故障特征量的提取。以提升小波包算法为依据, 选取 db5 小波基, 实行 3 层小波包分解, 各信号提取的能量特征量 (已归一化) 情况如图 2 所示。将提取驱动端的 50 组能量特征量作为 BP 神经网络的训练样本, 风扇端的 30 组能量特征量作为网络的测试样本。

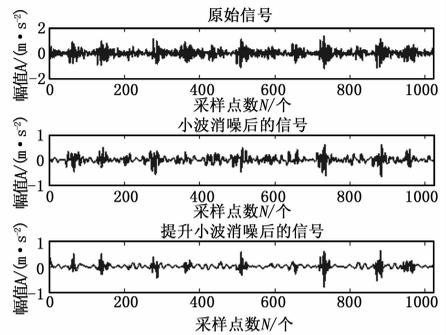


图 1 传统小波与提升小波的轴承内圈故障消噪效果

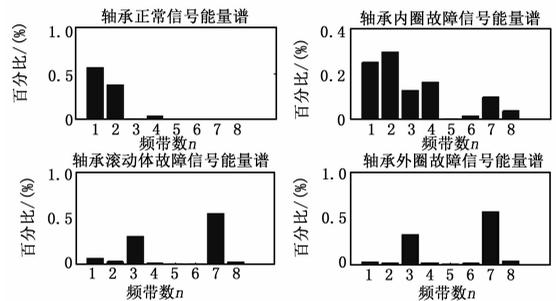


图 2 不同轴承故障类型下的能量特征

3) 构建 BP 神经网络。实验中构建的 BP 神经网络采用 3 层拓扑结构, 由于输入特征量为提取的能量特征量 $X = [\bar{E}_0, \bar{E}_1, \bar{E}_2, \bar{E}_3, \bar{E}_4, \bar{E}_5, \bar{E}_6, \bar{E}_7]$, 故输入节点数为 8 个; 输出为故障模式, 研究的故障模式有 4 种: 无故障 (1, 0, 0, 0)、轴承内圈故障 (0, 1, 0, 0)、滚动体故障 (0, 0, 1, 0)、轴承外圈故障 (0, 0, 0, 1), 因此输出节点数为 4 个。隐含层节点根据经验公式 $b \geq 2a + 1$ (b 为隐含层节点数, a 为输入层节点数), 并经过多次实验验证, $b = 17$ 时较合适。另外, 隐含层和输出层的传递函数分别设定为 tansig 和 purelin, 训练次数定为 1 000, 最小均方误差指标定为 10^{-5} 。

4) 优化 BP 神经网络并确定故障类型。设定种群数目为 50, 最大运行代数为 100, 代沟为 0.9, 利用设计的 GA 优化 BP 神经网络的初始权值、阈值, 采用 L-M 算法搜索故障信息, 以高效的方式确定轴承的故障类型。以某一成功诊断情况为例, GA 优化网络初始权值、阈值过程中的误差平方和曲线和适应度曲线如图 3 所示。图 4 和图 5 分别为标准 BP 神经网络和优化 BP 神经网络的训练过程, 训练输出结果如表 1 所示, 输出结果与期望值误差平方和如表 2 所示。结果表明: 标准 BP 神经网络经过 126 步后使最小均方误差达到 10^{-5} , 而优化 BP 神经网络仅经过 87 步便达到最小均方误差 10^{-5} 。从网络实际输出值与期望值比较来看, 优化 BP 神经网络比标准 BP 神经网络的误差更小。另外, 在 30 组测试样本中, 标准 BP 神经网络成功诊断 26 例, 准确率为 86.7%, 而优化 BP 神经网络成功诊断 28 例, 准确率为 93.3%。由此可见, 改进 BP

神经网络比标准神经网络具有更高效的故障诊断。

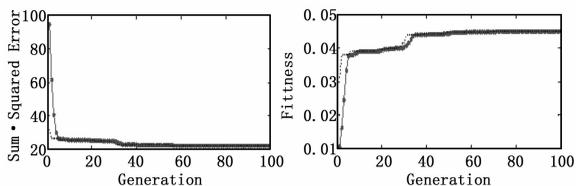


图 3 GA 优化 BP 神经网络的误差平方和及适应度曲线

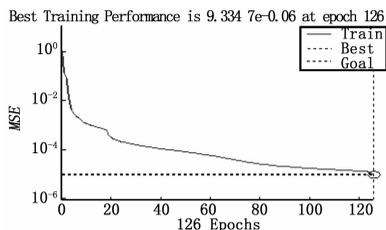


图 4 标准 BP 神经网络的训练过程

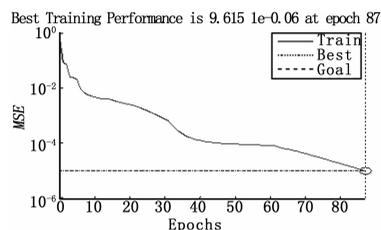


图 5 优化 BP 神经网络的训练过程

表 1 优化前后 BP 神经网络实际输出值

网络类型	各种故障类型的网络实际输出值				故障模式
	正常	内圈	滚动体	外圈	
标准 BP	1.000 7	-0.004 4	-0.000 5	0.007 0	1 0 0 0
	-0.000 8	1.005 2	0.002 2	-0.006 5	0 1 0 0
	-0.010 8	-0.066 4	0.973 7	-0.341 5	0 0 1 0
	0.010 9	0.065 6	0.024 6	1.341 1	0 0 0 1
优化 BP	0.999 3	0.010 8	-0.000 6	-0.003 8	1 0 0 0
	0.000 3	0.987 6	0.003 6	-0.002 3	0 1 0 0
	-0.001 2	-0.014 9	0.836 3	-0.162 0	0 0 1 0
	0.001 3	0.015 4	0.160 0	1.168 5	0 0 0 1

表 2 优化前后 BP 神经网络的诊断误差

网络类型	各故障类型的误差平方和			
	正常	内圈	滚动体	外圈
标准 BP	0.000 2	0.008 8	0.001 3	0.233 1
优化 BP	0.000 0	0.000 7	0.052 4	0.054 7

5 结论

1) 根据传统小波包算法、提升原理及插值细分思想,建立了提升小波包算法,并将其应用于故障信号的消噪处理和故障特征量的提取,效果表明提升小波包算法具有很好的自适应。

2) GA 和 L-M 算法组合优化了传统 BP 神经网络。利用 GA 全局搜索能力优化网络的初始权值、阈值,从而确定了网络搜索起点;利用 L-M 算法提升了网络的搜索速度,避免了陷入局部最优问题。

3) 将提升小波包和改进 BP 神经网络相融合的新故障诊断算法应用于滚动轴承故障实验中,结果表明:新算法具有既快又准的诊断效果,为实际的故障诊断提供了一种新思路。

参考文献:

[1] 秦树人, 季 忠, 尹爱军. 工程信号处理 [M]. 北京: 高等教育出版社, 2008: 6-10.

[2] Sweldens W. The lifting scheme: a construction of second generation wavelet [J]. SIAM Journal on Mathematics Analysis, 1997, 29 (2): 511-546.

[3] 陈换过, 江金寿, 李剑敏, 等. 基于提升小波包和神经网络的结构损伤检测 [J]. 振动、测试与诊断, 2013, 33 (1): 116-121.

[4] 肖顺根, 宋萌萌. 基于小波包能量神经网络的滚动轴承故障诊断方法 [J]. 机械强度, 2014, 36 (3): 340-346.

[5] 张北欧. 基于小波包变换和 Elman 神经网络电机故障诊断系统的研究 [D]. 武汉: 武汉理工大学, 2010.

[6] 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.

[7] 李运红, 张湧涛, 裴未迟. 基于小波包-Elman 神经网络的电机轴承故障诊断 [J]. 河北理工大学学报 (自然科学版), 2008, 30 (4): 81-85.

[8] 蒋伟江. 基于小波包和 SOM 神经网络的车轴滚动轴承故障诊断 [J]. 机械设计与研究, 2012, 28 (6): 70-73.

[9] 何宽芳, 黎 祺, 李学军, 等. 小波能谱熵和优化神经网络的滚动轴承诊断方法 [J]. 机械科学与技术, 2013, 32 (11): 1670-1674.

[10] 徐巧英. 加窗提升小波包在故障测距中的应用研究 [D]. 上海: 上海交通大学, 2011.

[11] 路 亮, 龙 源, 谢全民. 爆破振动信号的提升小波包分解及能量分布特征 [J]. 爆炸与冲击, 2013, 33 (2): 140-147.

[12] 高立新, 殷海晨, 张建宇, 等. 第二代小波分析在轴承故障诊断中的应用 [J]. 北京工业大学学报, 2009, 35 (5): 577-581.

[13] Bearing data center seeded fault test data [EB/OL]. <http://www.cecs.case.edu>.

(上接第 2398 页)

[5] BeagleBoard.org, Getting Started; Getting Started with Beagle-Bone & BeagleBone Black [EB/OL]. [2013-10-11]. <http://beagleboard.org/Getting%20Started>.

[6] Bradski G, Kaehler A. Learning OpenCV: Computer Vision with the OpenCV Library [M]. American: O'Reilly Media, 2008.

[7] 黄 佳. 基于 OpenCV 的计算机视觉技术研究 [D]. 广州: 华南理工大学, 2013.

[8] 刘慧英, 王小波. 基于 OpenCV 的车辆轮廓检测 [J]. 科学技术与工程, 2010, 10 (12): 2987-2991.

[9] 韩雪岭, 李成贵. 基于机器视觉的发动机喷嘴检测系统的设计 [J]. 计算机测量与控制, 2012, 20 (6): 1455-1457.

[10] 奚晓梁, 周晓东, 张 健. 基于小区域滤波的快速星图弱目标分割算法 [J]. 北京: 系统工程与电子技术, 2012, 1 (34): 40-45.

[11] 刘瑞祯, 于仕琪. OpenCV 教程——基础篇 [M]. 北京: 北京航空航天大学出版社, 2007.

[12] Abegaz S, Awgichew K. Estimation of weight and age of sheep and goats [J]. American: Ethiopia Sheep and Goat Productivity Improvement Program, 2009.