

基于手机传感器轨迹的路面地物检测方法

焦东来^{1,2} 王浩翔³ 吕海洋^{1,2} 徐轲^{1,2}

1 南京邮电大学江苏省智慧健康大数据分析与服务工程实验室 南京 210023

2 南京邮电大学地理与生物信息学院 南京 210023

3 南京邮电大学通信与信息工程学院 南京 210023

摘要 针对传统路面地物信息采集方法存在的采集周期长、成本高等问题,提出了一种基于手机传感器轨迹的城市路面地物检测方法。利用手机记录车辆行驶过程中各传感器数据的变化,分析经过姿态校正后的加速度数据,研究加速度变化与路况之间的联系,构建BP神经网络模型,并使用已采集数据对模型进行训练,以识别路面地物。实验结果表明,基于手机传感器轨迹的路面地物检测方法具有快速准确地检测路面地物信息的能力,且地物检测准确率大于85%,能够较为准确地检测路面地物。文中基于手机姿态传感器对手机加速度传感器姿态进行了实时矫正,利用手机垂直于路面的加速度变化检测路面地物,因此所提方法具有手机加速度传感器姿态无关性,此外,所提方法对硬件设备要求低、数据采集效率高,降低了路面地物信息采集的成本,具有广泛的应用前景。

关键词:手机传感器;车辆轨迹;路面地物检测;BP神经网络

中图分类号 P228

Road Surface Object Detection from Mobile Phone Based Sensor Trajectories

JIAO Dong-lai^{1,2}, WANG Hao-xiang³, LYU Hai-yang^{1,2} and XU Ke^{1,2}

1 Smart Health Big Data Analysis and Location Services Engineering Lab of Jiangsu Province, Nanjing University of Posts and Telecommunications, Nanjing 210023, China

2 School of Geography and Bioinformatics, Nanjing University of Posts and Telecommunications, Nanjing 210023, China

3 School of Communication and Information Engineering, Nanjing University of Posts and Telecommunications, Nanjing 210023, China

Abstract Aimed at the problem of low efficiency and high cost in the traditional road surface object collection procedure, the method of road surface object recognition from mobile phone based sensor trajectories is proposed. Mobile phones are used to record the data changes of various sensors in the process of driving, and then the acceleration data after attitude correction are analyzed to find the relationship between the acceleration trend and the road condition. Finally, the constructed BP neural network model, and use the acquired data to train the BP neural network model to recognize the road surface object and its position. Experiment results show that, the road surface object can be fast and accurately recognized by the mobile phone based sensor trajectories, and the accuracy can be higher than 85%. In this paper, attitude of mobile acceleration sensor has carried on the real time correction. Because the acceleration changing of the Mobile phones is perpendicular to the road, we use the acceleration change to detect the road feature. The method has nothing to do with a mobile phone accelerometer gesture, in addition, hardware requirements of the method are low, the efficiency of data acquisition is high, which reduce the cost of the road surface features information acquisition.

Keywords Mobile phone sensors, Vehicle trajectories, Road surface object recognition, BP neural network

1 引言

道路是城市交通的载体,然而随着经济社会的发展,车辆日益增多,路面承受的压力也越来越大,道路路面经常会出现坑洞、裂缝等,对交通安全造成威胁^[1-2]。如何快速、准确地检测道路路面地物信息,对道路路面维护和交通安全具有重要意义。

目前,道路路面地物信息的检测方法主要有以下3类。

1) 基于实地测量的传统方法。通过专业人员测量记录路面状

况,根据评估和记录获取路面状况,这类方法的工作效率较低,且数据覆盖范围有限^[3-4]。2) 基于专业设备的自动检测方法。Yang等^[5]、Hiu等^[10]使用车载LiDAR采集路面激光点云数据,计算路面几何表面变化情况以检测路面坑洞信息。Chang等^[11]基于地面激光雷达采集数据,通过聚类算法检测路面信息。Huston等^[6]使用探地雷达绘制道路表面及以下区域,来发现路面坑洞以及路面内部空洞信息。Zhang等^[7]通过采用立体视觉相机来构建路面图像,通过表面拟合设置阈值提取路面信息。Xu等^[8]使用辐射成像的方法来获取路

基金项目:国家自然科学基金(41471329)

This work was supported by the National Science Foundation of China(41471329).

通信作者:焦东来(jiaodonglai@njupt.edu.cn)

面图像的方式以检测路面信息。Liu 等^[9]使用轮廓仪收集路面平整度信息, Kang 等^[12]使用 2D LiDAR 和摄像机开发了一个坑洞检测系统, 先使用 2D LiDAR 测量设备与路面的距离, 然后利用摄像头获取路面图像信息, 结合 2D LiDAR 获取的距离信息对图像进行二值化, 最终对二值化结果进行边缘提取, 从而检测出路面的坑洞。这些方法依赖专业的测量设备和测量人员, 数据采集成本较高, 采集范围有限且更新周期较长。3) 基于移动传感器的路面地物检测方法。Christoph 等^[13]通过线结构光传感器和车载摄像头采集数据, 使用阈值法提取路面地物。Mednis 等^[14]使用声音采集设备检测路面地物情况。Eriksson 等^[15]使用加速度传感器和 GPS 设备, 使用基于机器学习的方法得到路面地物位置。Koch 等^[16]对摄像头采集的视频信号进行分析, 使用缺陷检测算法辨认出路面的地物类型。Karuppuswamy 等^[17]、Lin 等^[18]使用相机采集路面图像来检测坑洞。Jin 等^[19]使用 MPU6050 传感器以及 Arduino Uno 采集数据, 并对数据进行分析, 提取光滑路面、不平整路面、坑洞、减速带等地物的特征, 最终使用神经网络对数据分类, 从而识别出路面的地物。这些方法大大降低了路面地物检测的成本, 提高了方法效率, 但设备专业性较强, 方法适用范围有限。

随着智能手机的不断发展和应用, 基于手机传感器的数据采集方法得到了越来越多的关注。Mednis 等^[20]利用手机加速度传感器采集路面信息, 分析加速度变化极值、方差等特征, 通过阈值法检测路面地物及其位置信息。Zang 等^[25]和 Yang^[4]对传感器垂直方向运动进行建模, 利用阈值法分析垂直位移, 从而得到路面地物信息。Prashanth 等^[22]使用手机音频、GPS、姿态、摄像头等传感器采集路面数据, 对道路路面信息及交通情况进行检测。Perttunen 等^[21]利用手机加速度、GPS 传感器, 基于加速度数据傅里叶变换识别不同路面地物的频谱模式, 构建路面频谱检测系统以提取路面信息。Tai 等^[24]和 Kulkarni 等^[23]基于机器学习的方法对手机加速度传感器采集到的数据进行监督学习和非监督学习分类, 检测道路地物信息并对路面情况进行分类。Du 等^[26]使用智能手机采集路面数据, 并采用改进的高斯模型算法提取路面异常特征, 最后使用 KNN(k-Nearest Neighbour) 识别异常路面类型。这些方法需要对手机数据进行复杂的数据处理与标定, 地物检测以阈值法或聚类法为主, 地物检测能力有限。

基于此, 本文使用具有较强的非线性预测能力的 BP 神经网络(Back Propagation Neural Network), 在预处理阶段使用姿态角数据对加速度数据进行姿态的实时校正, 然后根据加速度数据构建并训练 BP 神经网络模型, 从而检测路面地物信息。

2 路面地物提取方法

采集手机位置传感器、姿态传感器、加速度传感器数据, 其中手机姿态传感器数据用于将手机加速度传感器的坐标系变

$$\begin{pmatrix} \cos(\psi) \cdot \cos(\theta) & \cos(\psi) \cdot \sin(\theta) \cdot \sin(\Phi) - \sin(\psi) \cdot \cos(\Phi) & \cos(\psi) \cdot \sin(\theta) \cdot \cos(\Phi) + \sin(\psi) \cdot \sin(\Phi) \\ \sin(\psi) \cdot \cos(\theta) & \sin(\psi) \cdot \sin(\theta) \cdot \sin(\Phi) + \cos(\psi) \cdot \cos(\Phi) & \sin(\psi) \cdot \sin(\theta) \cdot \cos(\Phi) - \cos(\psi) \cdot \sin(\Phi) \\ \sin(\theta) & \cos(\theta) \cdot \sin(\Phi) & \cos(\theta) \cdot \cos(\Phi) \end{pmatrix} \quad (1)$$

2.2 BP 神经网络模型构建与训练

BP 神经网络是一种误差反向传播算法训练的多层前馈

换为惯性坐标系, 然后将变换后的 Z 轴加速度输入到 BP 神经网络中, 将检测出的加速度值对应时刻坐标位置输出地物位置。

2.1 手机传感器空间坐标系变换

手机内集成了多个传感器, 分别具有不同的坐标参考: 1) 加速度传感器的坐标系是以手机机身为准定义的一种物体坐标系; 2) 世界坐标系是相对大地坐标系统的绝对坐标系; 3) 惯性坐标系是与物体坐标系原点重合的、坐标轴与世界坐标系坐标轴平行的坐标系(见图 1)。因此, 需要通过旋转矩阵将加速度传感器的坐标系转换为惯性坐标系, 通过三维平移变换矩阵转换为世界坐标系。




图 1 坐标系之间的几何关系

Fig. 1 Geometric relations between coordinate systems

由于手机空间姿态存在一定的随机性, 手机加速度传感器坐标系空间中三轴加速度变化与惯性坐标系不一致, 导致不能直接对采集的加速度传感器的数据进行分析, 需要通过手机姿态传感器数据对加速度数据进行坐标系变换, 使其与惯性坐标系一致, 从而分析加速度传感器数据检测路面地物, 具体步骤如下:

(1) 传感器坐标轴方向标定。由于在初始状态加速度传感器和惯性坐标系不一致, 因此需要初始化加速度传感器的坐标系, 使其在初始时刻坐标系方向一致。首先将手机沿特定方向快速移动, 根据记录的加速度传感器数据确定传感器坐标系, 并与手机惯性坐标系进行对比, 通过对数据进行取反操作, 使得两坐标系方向一致。

(2) 坐标系逆变换。在运动过程中加速度传感器坐标系的姿态会变化, 变化后经过轴向再标定的加速度传感器数据乘以空间变换矩阵的逆矩阵, 如式(1)所示, 便将加速度传感器坐标系统一到惯性坐标系, 如图 2 所示。




图 2 空间坐标系变换过程

Fig. 2 Transformation process of spatial coordinate systems

空间变换矩阵如式(1)所示:

网络。一个典型的 BP 神经网络的拓扑结构包括 3 层, 如图 3 所示, 分别是输入层、输出层、隐藏层。




图3 BP神经网络的一般结构

Fig. 3 General structure of BP neural network

(1)BP神经网络模型构建

基于BP神经网络检测路面地物信息,需要对数据进行预处理:计算每个点与上一个时刻的加速度的变化量,并设置滑动窗口对数据进行均值滤波,然后将其作为输入层。本文中BP神经网络有两个隐藏层:第一个隐藏层有7个神经元节点,采用 Sigmoid 函数作为激励函数;第二个隐藏层有70个神经元节点,并以二元阶梯函数为激励函数。输出层的神经元节点个数为1,隐藏层为二元阶梯函数,若该点被判断为地物则输出为1,反之输出为0。为使系统快速收敛,本文中使用交叉熵函数为损失函数。本文BP神经网络的构建结果如图4所示。其中, $T_1, T_2, T_3, \dots, T_{68}, T_{69}, T_{70}$ 为预处理后的实际数值。




图4 BP神经网络构建结果

Fig. 4 Construction result of BP neural network

(2)BP神经网络模型训练

BP神经网络在训练过程中通过梯度下降法不断调节各个层之间的权值和神经元的阈值,以减小网络输出与期望值之间的误差。训练步骤如下:

1)初始化BP神经网络的参数,选用单极性S型函数为激励函数 $f(x)$,如式(2)所示:

$$f(x) = \frac{1}{1 + e^{-x}} \quad (2)$$

2)输入训练集和期望值 y 。

3)获取输出结果 d ,利用反向传播算法首先设置误差函数 E ,如式(3)所示,其中 m 为训练样本个数。分别计算各参数对于误差函数的偏导数;在第 h 个隐藏层权值 w_h 的偏导数如式(5)所示,阈值 b 的偏导数如式(6)所示。为了简化说明,称隐层输出为 L_h ,并设中间变量 δ_h 如式(4)所示:

$$E = \frac{1}{m} * \frac{1}{2} \sum_{i=1}^m (y_i - d_i)^2 \quad (3)$$

$$\delta_h = (d - y) * f(\sum_{h=0}^{18} w_h * L_h + b) * [1 - f(\sum_{h=0}^{18} w_h * L_h + b)] \quad (4)$$

$$\frac{\partial E(w, b)}{\partial w_h} = \delta_h * f(\sum_{h=0}^{18} w_h * L_h + b) \quad (5)$$

$$\frac{\partial E(w, b)}{\partial b} = \delta_h \quad (6)$$

第 i 个输入层的权值 V_{ih} 的偏导数公式如式(7)所示,阈值 θ_h 的偏导数如式(8)所示:

$$\frac{\partial E(v_{ih}, \theta_h)}{\partial v_{ih}} = x_i * \delta_h^2 * w_h / (d - y) \quad (7)$$

$$\frac{\partial E(v, \theta)}{\partial \theta_h} = \delta_h \quad (8)$$

4)使用梯度下降法更新参数,如式(9)~式(11)所示:

$$w_h = w_h - 0.01 * \frac{\partial E(w, b)}{\partial w_h} \quad (9)$$

$$b = b - 0.01 * \frac{\partial E(w, b)}{\partial b} \quad (10)$$

$$v_{ih} = v_{ih} - \frac{\partial E(v, \theta)}{\partial v_{ih}} * 0.01 \quad (11)$$

$$\theta_h = \theta_h - * 0.01 * \frac{\partial E(v, \theta)}{\partial \theta_h} \quad (12)$$

5)重复步骤3)和步骤4),直到训练次数超过最大阈值或训练输出结果满足误差要求。

6)训练结束,输出各个层之间的权值和神经元节点处的阈值。

2.3 传感器轨迹-路面地物检测方法的流程

将手机任意姿态放置在行驶的车辆中进行实验,设计本文方法的流程如下:

(1)采集和清洗数据。采集手机传感器数据并设置阈值对错误数据进行清洗,如车辆静止、传感器异常等。

(2)空间坐标系变换。使用手机姿态传感器数据对加速度传感器数据进行空间姿态变换,使加速度传感器数据的坐标系转换为手机的惯性坐标系。

(3)数据预处理。对变换后的传感器数据加以大小为70的滑动窗口,对数据进行均值滤波,并更新加速度传感器数据。

(4)训练集与验证集的数据采集。实地检查实验区域并对出现地物的位置进行标注,设定标定期望值,并将处理后的数据分为训练集和验证集。

(5)BP神经网络训练。初始化BP神经网络并输入训练集,不断迭代直到满足训练终止条件,输出训练参数。

(6)模型验证与准确度评价。输入验证集到BP神经网络,计算实验结果的准确度,对其他区域进行实验和分析。

综上,本文路面地物检测的流程如图5所示。

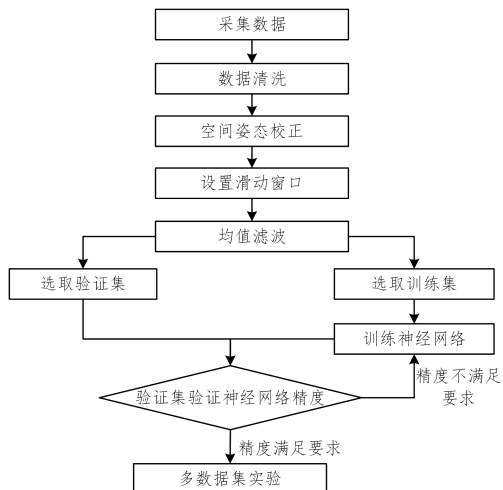


图5 路面地物检测的流程

Fig. 5 Procedure of road surface object detection

3 实验过程与结果分析

本文利用手机传感器轨迹数据训练 BP 神经网络,得到 BP 神经网络模型参数,然后对本文方法进行验证。

3.1 实验设备与区域

(1)实验设备

本文实验使用以下设备:1)搭载了传感器数据采集软件的手机,如图 6(a)所示;2)本研究所使用的车辆,如图 6(b)所示。



图 6 实验条件

Fig. 6 Experimental condition

(2)实验区域

本文校园道路为实验对象,区域中道路路面中的地物主要包括“减速带”“窨井盖”“不同大小的坑洞”等,如图 7 所示。实验区域的空间范围为 1.02km²,道路长度为 6.1km,道路空间几何形态如图 8 所示,其中图 8(a)是实验区域 1 的空间几何形态情况,图 8(b)一图 8(d)是实验区域 2 的路面情况,同样的路面地物分布如图 9 所示。




图 7 常见地物

Fig. 7 Common features




图 8 实验区域

Fig. 8 Experimental area

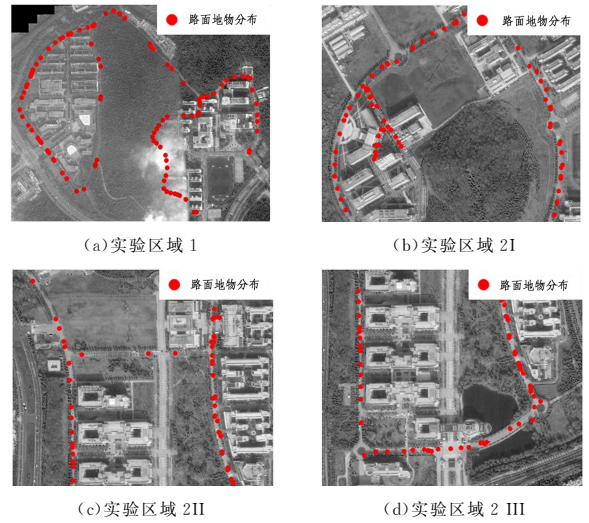


图 9 地物的空间分布

Fig. 9 Spatial distribution of features

3.2 坐标系空间变换

由于手机位置的放置具有任意性,加速度传感器 Z 轴的变化不能直接反映车辆在垂直方向的实际变化情况,对路面地物检测造成困难,如图 10 中红色曲线所示。因此,需要利用手机姿态传感器计算手机的空间姿态,利用式(1)所示的坐标系变换矩阵,将其转换为与世界坐标系平行的方向,并利用变换后的加速传感器 Z 轴的加速度变化(如图 10 中黑色曲线所示)检测路面地物信息。




图 10 Z 轴加速度校正(电子版为彩色)

Fig. 10 Z-axis acceleration correction

图 10 中,在坐标系空间变换前,加速度传感器 Z 轴方向的加速度数值波动较大,难以检测其变化规律。经过坐标系空间变换后,加速度传感器 Z 轴方向的加速度数值变化较为稳定,加速度平均值约为 9.8m/s²,与当地实际重力加速度值较为一致,数值大小在合理范围内波动,与实际路面情况较为一致。

3.3 神经网络的训练与路面地物检测

(1)神经网络模型的训练

根据实验区域路面地物的实际空间分布,对采集到的手机传感器轨迹数据进行手工标注。然后,以 Z 轴加速度采样值为中心,选取大小为 70 的滑动窗口内的加速度数值(见图 11)输入到 BP 神经网络。

驾车在如图 12 所示的道路上行驶,采集行驶数据作为神经网络训练集,训练集的路面地物分布如图 12(b)所示。




图 11 数据窗口

Fig. 11 Date windowing




图 12 实验场地
Fig. 12 Experimental area

BP神经网络的训练模型如图 13 所示, BP神经网络的输入为 1×70 的矢量, 对当前位置的垂直加速度变化情况进行综合判断, 当实际路面地物处的加速度数据输入到 BP神经网络时, 会激活神经网络的输出函数, 将该加速度时刻对应的位置传感器采样结果作为路面地物检测结果。BP神经网络训练过程中, 设置迭代残差大小为 0.001, 最大训练迭代次数为 100 000, 当达到迭代终止条件时自动停止 BP神经网络的训练, 并输出神经网络模型的参数训练结果。




图 13 BP神经网络的训练模型
Fig. 13 Training model of BP neural network

(2)路面地物检测结果与分析

为了验证神经网络的效果, 驾车在校园内行驶, 采集实验区域 2 路面轨迹数据 9 条, 实验区域 1 路面轨迹 2 条, 进行预处理等操作后将结果输入神经网络, 输出结果如图 14 所示。由图 14(b) — 图 14(d) 中可知, 实验区域 2 内共有地物 110 处。BP神经网络输出结果显示检测出地物 85 处, 9 条轨迹总误判次数为 13 次, 实际误判点 8 处。9 条轨迹结果的统计如表 1 所列。

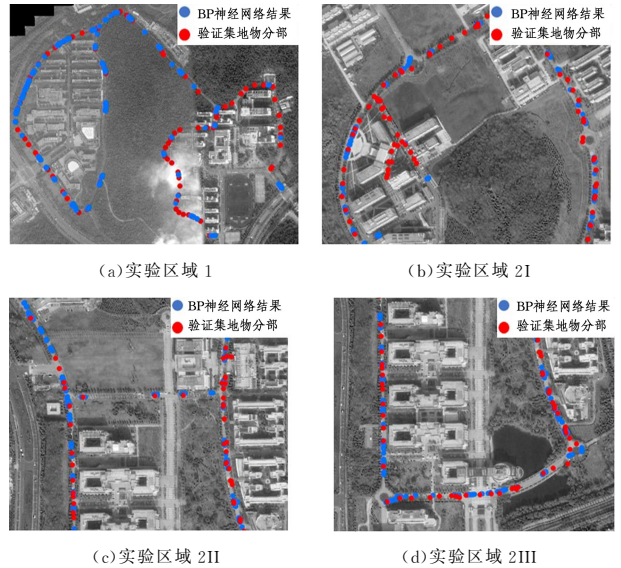


图 14 BP神经网络的结果

Fig. 14 Results of BP neural network

表 1 实验区域 2 的 BP神经网络路面地物检测结果

Table 1 Results of BP neural network in research area two

Road ID	Number of detected	Number of actual features	Number of misjudged
1	15	35	1
2	20	44	3
3	29	95	0
4	28	58	1
5	29	103	4
6	17	30	1
7	17	35	1
8	8	15	0
9	36	103	2

由图 14(a) 可知, 实验区域 1 地物研究区域内共有地物 85 处, 通过 BP神经网络输出结果显示检测出地物 50 处, 2 条轨迹总误判次数为 5 次, 实际误判点 3 处。2 条轨迹结果的统计如表 2 所列。

表 2 实验区域 1 的 BP神经网络路面地物检测结果

Table 2 Results of BP neural network in research area one

Road ID	Number of detected	Number of actual features	Number of misjudged
1	25	47	2
2	27	42	3

两区域的总体结果如表 3 所列。

表 3 BP神经网络路面地物检测结果

Table 3 Results of BP neural network

Local	Number of detected	Number of actual features	Number of misjudged
实验区域 2	85	110	8
实验区域 1	50	85	2

由表 1、表 3 可知, 经过多次行驶后实验区域 2 每条道路中的路面地物均被不同程度地检测出来, 总的来说检测出来的个数占总数的 74%, 9 条轨迹中误检测数量占总数的最大的为 road 2, 检测出来 20 个, 其中误判 3 个。误判最少的如 road 3 和 road 8 为 0 个。利用 BP神经网络对手机传感器轨迹数据进行路面地物检测, 较为准确地检测出了路面地物的实际空间分布, 按每条轨迹检测准确率均大于 85%, 从总体

来看准确率为 93%。由于每条道路行驶次数较少,因此在检测出来的个数上实验区域 2 的结果不好,检测出来的地物个数仅占总数的 58%。本文 BP 神经网络模型的时间复杂度为 $O(n_1 * n_2 + n_2 * n_3 + n_3 * n_4)$, 其中 n_1 为输入层神经元个数; n_2 为第一层隐藏层神经元个数; n_3 为第二层隐藏层神经元个数; n_4 为输出层神经元个数。在本文实验过程中, BP 神经网络完成一次训练花费的时间为 6.000 s, 完成一次数据检测花费的时间为 1.154 s, 实验结果的计算速度较快, 用时较少。

为了对本文方法的有效性进行对比, 选取较为常用的阈值法路面地物检测方法进行实验, 使用 BP 神经网络训练集数据进行实验, 以迭代的方法选取最佳阈值, 然后对实验区域中的其他验证数据集道路进行实验, 结果如图 15 所示。

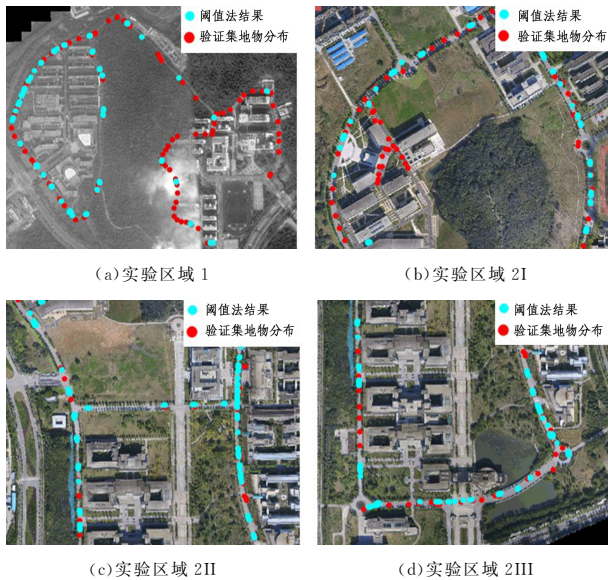


图 15 阈值法路面地物检测结果

Fig. 15 Results of threshold method

图 15 中, 利用阈值法也能够将路面地物检测出来, 显示检测出地物 78 处, 检测出来的个数占总数的 70%, 略低于 BP 神经网络的结果。9 条轨迹总误判次数为 24, 汇总起来误判点共 11 处, 9 条轨迹结果的统计如表 4 所列。

表 4 实验区域 2 的阈值法路面地物检测结果

Table 4 Results of threshold method in research area two

Road ID	Number of detected	Number of actual features	Number of misjudged
1	18	35	1
2	20	44	3
3	32	95	2
4	32	58	3
5	47	103	5
6	16	30	0
7	20	35	2
8	8	15	0
9	34	103	3

由表 4 可知, 9 条轨迹中, 误检测数量占总数的最大的为 road 2, 检测出来 20 个, 其中误判 3 个。误判最少的如 road 6 和 road 8, 为 0 个。

实验区域 1 检测出总共地物 30 个以及误判 2 个, 将实验区域结果汇总, 如表 5 所列。

表 5 阈值法路面地物检测结果

Table 5 Results of threshold method

Road ID	Number of detected	Number of actual features	Number of misjudged
实验区域 2	77	110	11
实验区域 1	30	85	2

为了进一步对路面地物检测结果的性能进行分析, 本文使用准确率 $f_{\text{precision}}$ 、召回率 f_{recall} 、 F_{score} 得分作为性能评价指标, 具体定义如式(13)一式(15)所示:

$$f_{\text{precision}} = \frac{n_{\text{real}}}{n_{\text{estimate}}} \quad (13)$$

$$f_{\text{recall}} = \frac{n_{\text{real}}}{n_{\text{practical}}} \quad (14)$$

$$F_{\text{score}} = 2 \cdot \frac{f_{\text{precision}} \cdot f_{\text{recall}}}{f_{\text{precision}} + f_{\text{recall}}} \quad (15)$$

利用上述评价指标对基于阈值的路面地物检测方法和本文方法进行性能评价, 计算结果如表 6、表 7 所列。

表 6 实验区域 2 的方法性能评价指标计算结果

Table 6 Summary of evaluation indicators in research area two

Method	$f_{\text{recall}}/\%$	$f_{\text{precision}}/\%$	F_{score}
The proposed method	74	91.3	0.816
The threshold method	70	87.5	0.78

表 7 实验区域 1 的方法性能评价指标计算结果

Table 7 Summary of evaluation indicators in research area one

Method	$f_{\text{recall}}/\%$	$f_{\text{precision}}/\%$	F_{score}
The proposed method	58.88	96.36	0.723
The threshold method	35.2	93.75	0.508

由表 6 可知, 本文方法的路面地物检测结果具有较高的准确率, 且 F_{score} 得分为 0.816, 而阈值法路面地物检测结果在准确率、召回率和 F_{score} 上均小于 BP 神经网络的方法, 因此本文方法的地物检测结果性能较优。由表 7 可知, 在进一步对比中, 阈值法的路面地物检测方法在实验区域 1 中的准确率和 F_{score} 得分也均小于 BP 神经网络的方法。

从表 6、表 7 的结果中可以看出, 由于阈值法的局限性, 即仅仅能够在实验区域取得较好的实验结果, 而对于其他区域实验结果不是很理想, 存在较多的漏检测现象, 其原因主要在于阈值法的最佳阈值具有不唯一性, 一个区域的最佳阈值可能不适用于其他区域。而本文采用的 BP 神经网络具有较强的非线性拟合能力, 能够检测出不同实验区域的地物, 得到的地物检测模型具有较好的适用性和可推广性。

结束语 道路路面地物信息获取对于城市中的道路更新与维护具有重要意义, 为了快速高效地获取路面地物信息, 本文提出一种通过手机传感器数据检测路面地物检测的方法。本文利用手机传感器数据, 使用具有非线性拟合能力的 BP 神经网络来采集数据以进行训练。通过实际路面数据采集的数据来验证神经网络的地物检测结果的准确性, 并与阈值法进行对比, 实验结果表明, 本文基于本文方法能够在不同实验区域取得较好的实验效果, 地物检测准确性超过 85%, 具有较好的稳定性和可行性, 为道路路面地物检测提供了一个快速高效的实现途径。

参考文献

- [1] GIACOMIN J, WOO Y. A study of the human ability to detect road surface type on the basis of steering wheel vibration feed-

- back[J]. Proceedings of The Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering, 2005, 219(11): 1259-1270.
- [2] SMITH K D, RAM P. Measuring and Specifying Pavement Smoothness; [techbrief][R]. United States. Federal Highway Administration, 2016.
- [3] LAN Q X. Research on Extraction of Potholes Features Based on Digital Image Recognition[D]. Chongqing: Chongqing Jiaotong University, 2015.
- [4] YANG C. Perceiving Metropolitan-Scale Pothole Profiles with Crowdsourcing[D]. Shanghai: Shanghai Jiao Tong University, 2015.
- [5] YANG L, LIU R F, LU X S, et al. An automatic extraction method for road surface pothole in vehicle-borne laser point cloud[J]. Surveying and Mapping Engineering, 2020, 1(6): 66-71.
- [6] HUI B, GUO M, WANG Z, et al. Multi-dimensional index detection of pavement potholes based on 3D laser technology[J]. Journal of Tongji University (Natural Science), 2018, 46(1): 60-66.
- [7] CHANG K T, CHANG J R, LIU J K. Detection of pavement distresses using 3D laser scanning technology[M]// Computing in Civil Engineering. 2005: 1-11.
- [8] HUSTON D, PELCZARSKI N, ESSER B, et al. Damage detection in roadways with ground penetrating radar[C]// Eighth International Conference on Ground Penetrating Radar. International Society for Optics and Photonics, 2000: 91-94.
- [9] ZHANG Z, XIAO A, CHAN C K, et al. An efficient algorithm for pothole detection using stereo vision[C]// 2014 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). IEEE, 2014: 564-568.
- [10] YU X, SALARI E. Pavement pothole detection and severity measurement using laser imaging[C]// 2011 IEEE International Conference on Electro/Information Technology. IEEE, 2011: 1-5.
- [11] LIU W, FWA T F, ZHAO Z. Wavelet analysis and interpretation of road roughness[J]. Journal of Transportation Engineering, 2005, 131(2): 120-130.
- [12] KANG B, CHOI S. Pothole Detection System using 2D LiDAR and Camera [C]// 2017 Ninth International Conference on Ubiquitous and Future Networks. IEEE, 2017: 744-746.
- [13] MERT Z, CHRISTOP H. Continuous road damage detection using regular service vehicles[C]// Proceedings of the ITS world congress. 2011: 5-8.
- [14] MEDNIS A, STRAZDINS G, LIEPINS M, et al. RoadMic: Road surface monitoring using vehicular sensor networks with microphones[C]// International Conference on Networked Digital Technologies. Berlin: Springer, 2010: 417-429.
- [15] ERIKSSON J, GIROD L, HULL B, et al. The pothole patrol: using a mobile sensor network for road surface monitoring[C]// Proceedings of the 6th International Conference on Mobile Systems, Applications, and Services. 2008: 29-39.
- [16] KOCH C, BRILAKIS I. Pothole detection in asphalt pavement images[J]. Advanced Engineering Informatics, 2011, 25(3): 507-515.
- [17] KARUPPUSWAMY J. Detection and avoidance of simulated potholes in autonomous vehicle navigation in an unstructured environment[C]// Intelligent Robots and Computer Vision XIX: Algorithms, Techniques, and Active Vision. International Society for Optics and Photonics, 2000: 70-80.
- [18] LIN J, LIU Y. Potholes detection based on SVM in the pavement distress image[C]// 2010 Ninth International Symposium on Distributed Computing and Applications to Business, Engineering and Science. IEEE, 2010: 544-547.
- [19] NG J R, WONG J S, GOH V T, et al. Identification of Road Surface Conditions using IoT Sensors and Machine Learning[M]// Computational Science and Technology. Singapore: Springer, 2019: 259-268.
- [20] MEDNIS A, STRAZDINS G, ZVIEDRIS R, et al. Real time pothole detection using android smartphones with accelerometers [C]// 2011 International Conference on Distributed Computing in Sensor Systems and Workshops (DCOSS). IEEE, 2011: 1-6.
- [21] PERTTUNEN M, MAZHELIS O, CONG F, et al. Distributed road surface condition monitoring using mobile phones[C]// International Conference on Ubiquitous Intelligence and Computing. Berlin: Springer, 2011: 64-78.
- [22] MOHAN P, PADMANABHAN V N, RAMJEE R. Nericell: rich monitoring of road and traffic conditions using mobile smartphones[C]// Proceedings of the 6th ACM Conference on Embedded Network Sensor Systems. 2008: 323-336.
- [23] KULKARNI A, MHALGI N, GURNANI S, et al. Pothole detection system using machine learning on Android[J]. International Journal of Emerging Technology and Advanced Engineering, 2014, 4(7): 360-364.
- [24] TAI Y C, CHAN C W, JANE Y J. Automatic road anomaly detection using smart mobile device[C]// Conference on Technologies and Applications of Artificial Intelligence. Hsinchu, China: 2010.
- [25] ZANG K, SHEN J, HUANG H S, et al. Assessing and mapping of road surface roughness based on GPS and accelerometer sensors on bicycle-mounted smartphones[J]. Sensors, 2018, 18(3): 914.
- [26] DU R, QIU G, GAO K, et al. Abnormal Road Surface Recognition Based on Smartphone Acceleration Sensor [J]. Sensors, 2020, 20(2), 451.



JIAO Dong-lai, born in 1977, Ph.D, associate professor. His main research interests include GIS and application of Internet of things.