

基于视觉的管道检测技术研究

葛昆山¹, 宋华², 吴华普³

1.北京航空航天大学 2.北京航空航天大学 3.北京航空航天大学

Email: 1. kunshan_ge@163.com, 2. songhua@buaa.edu.cn, 3. huapuwoo@gmail.com

摘要: 随着城市化进程的飞速发展, 城市基础设施的建设与维护变得愈发的重要。现有的管道故障检测方法存在着易受干扰、操作繁琐和通用性差等缺陷。本文设计了一种基于视觉的管道检测方法, 用来实现对管道故障的识别和分类。依据典型管道故障区域的大小和分散情况, 提取了管道缺陷的特征向量, 并对 K-means 聚类算法进行改进用于故障分类。特征向量的提取是缺陷检测的正确率的关键所在, 因此设计了图像滤波和边缘检测等操作用于改善图片质量和突出故障区域轮廓。实验表明, 该算法能够识别管道故障并正确分类。故障识别率为 80.07%, 故障分类率为 67.61%。

关键词: 管道故障; 视觉检测; 特征提取; 改进的 K-means 聚类

Research on pipeline inspection based on vision

Ge Kunshan¹, Song Hua², Wu Huapu³

1. Beihang University 2. Beihang University 3. Beihang University

Email: kunshan_ge@163.com, songhua@buaa.edu.cn, huapuwoo@gmail.com

Abstract: With the rapid development of urbanization, it is especially significant for urban construction and maintenance of infrastructure. Existing pipeline detection methods have many defects, such as vulnerable to interference, complicated operation and poor universal property. This paper designs a new underground pipeline detection method based on vision which achieves to detect the pipeline fault. According to the distribution characteristic of the typical pipeline fault area, fault feature vectors are extracted. Then the fault classification uses the improved K-mean clustering method. The fault feature extraction is the core of the visual detection algorithm, so the fast median filter algorithm and image edge detection are designed to enhance the quality of the image and highlight the profile of the fault area. Experiments show that the algorithm can assist the operator to identify and classify the pipeline fault. The fault recognition rate of the algorithm is as high as 80.07% and the fault classification rate is 67.61%.

Keywords: pipeline fault; visual detection; feature extraction; the improved K-mean clustering method

1 引言

城市地下管道作为地下空间的主载体, 是城市的重要基础设施, 是城市生存和发展的血脉, 被喻为城市的“生命线”^[1]。科学、准确、完整的地下管道现状信息以及管道健康管理与维护是地下管道安全、高效的保障^[2]。因此, 对地下管道故障及时检测与排查具有十分重要的社会意义。目前, 国内外应用于地下管道故障检测的方法工作原理各异^{[3][4][5][6]}, 主要的检测方法有电流衰减法、漏磁检测、电磁法检测、超声导波等。这些管道故障检测方法一般只适用于某一材质的管道或者特定的地质、施工条件, 局限条件明显。

基于视觉的管道检测技术^[7]是指把 CCD 摄像头安装到管道探测仪器或者机器人上, CCD 拍摄管道内表面视频/图像信息, 然后传送到地面的计算机上。通过图像预处理等处理后, 在监视器上进行实时显示, 检测人员通过显示的画面来判断管道内部的状况。1999 年, Paul W.Fieguth 等人提出了一种基于贝叶斯判据的地下管道裂缝的半自动检测方法^[8], 这种方法不适合口径较小的管道中应用, 只能检测管道的裂缝情况。2006 年, Sunil K.Sinha 等人提出了一种基于数学形态学的地下管道检测方法^[9]。该方法可以有效的划分出不同故障, 提出了根据故障区域形状特征来划分故障的想法, 但是把管道裂缝设定为一条直线进行划分, 与实际管道中的裂缝为树枝状有一定差异。2007 年, O. Duran 等人提出了一种基于神经网络的地下管道检测方法^[10], 该方法适用于地下管道的检测, 但是由于没有一个有效的提取特征的方法, 限制了该方法的发展。2011 年, Ming-Der Yang 等人提出了一种评定 CCD 拍摄到的图像质量的方法^[11], 通过该方法对采集到的管道图像进行质量评定, 抛弃质量比较低的图片, 在自动检测管道状况的算法中采用质量比较高的图片, 这就增加了自动检测算法判定管道状况的准确性。2011 年, Tung-Ching Su 等人

提出基于边缘检测的形态学分割方法，该方法能够有效的提取出故障信息，但是在划分故障时，直接设置一个阈值来划分特征信息，容易出现错误划分的情况。

本文提出一种基于视觉的管道缺陷自动检测方法，主要思想是依据不同故障在图像中呈现出的形状特征参数不同来划分的。根据典型的管道故障区域的分布特点，选取的特征参数是故障区域最小面积外接矩形的几何参数，包括矩形的长和宽。同时，我们将不同区域的分散程度考虑进去，对 K-means 聚类算法进行改进，实现管道故障的分类。为了提高管道故障检测的效果，图像滤波和边缘检测算法被设计，用于提高图片质量以及突出故障区域轮廓。

2 基于视觉的管道检测算法设计

基于视觉的管道检测算法是指通过检测系统采集管道内部状况的视频信息，然后按照一定的处理方法，提取出图像中包含的特征信息，并对特征信息进行划分，最终得出管道内部状况的判定。如图 1 所示，整个算法流程设计为三个模块，各模块功能如下：




图 1. 检测算法流程

图像预处理：检测系统采集到的原始图像，由于受到成像器件、电子元件等条件的限制以及管道中不确定因素的影响，成像质量不能达到直接进行故障特征提取的要求，因此，需要通过滤波操作，对原始图像进行一定的处理，改善图像的质量。

故障特征提取：通过边缘检测，得到图像中目标区域的边缘，然后提取出目标区域的特征参数，作为该图像的特征参数向量。

故障分类：在提取出特征参数向量的基础上，对 K-means 聚类算法进行改进，用于对故障类型进行划分。

2.1 图像预处理

图像预处理的目的是为了突出图像中故障区域的轮廓，衰减各种噪声，提高计算机对故障目标的识别度。采集到图像的主要噪声有光子噪声、散粒噪声、肥零噪声、转移噪声以及暗电流噪声，这些噪声都是离散、随机噪声^[12]，而滤波处理的主要目的是为了抑制图像中的离散噪声，把关注的目标区域提取出来。因此，本文选取的是既能消除离散随机噪声又能克服图像模糊问题的中值滤波算法。

中值滤波器选用含有奇数个像素点的滑动窗口在图像上面依次移动，每一个位置上都选取窗口覆盖区域中各个像素灰度值的中值作为该区域中心像素的灰度值输出。二维的中值滤波器可以表示为：

$$f(x, y) = \underset{(s, t) \in S_{xy}}{\text{medium}} \{g(s, t)\} \quad (1)$$

其中， $f(x, y)$ 为滤波之后的图像输出， $g(s, t)$ 为原始图像灰度值， (s, t) 为每次区域中心坐标， S_{xy} 为窗口覆盖的图像坐标区域。

对于中值滤波器来说，每次取中值的过程都是一个小范围数列进行排序的过程，需要进行数据的比较、交换等操作，比较浪费时间和空间，若采用的 $N \times N$ 滑动窗口，则每次选取中值最优算法的时间复杂度为 $O(2N^2 \log N)$ 。为了提高算法的运算速度，减小时间复杂度，本文中选用的快速中值滤波算法^[13]，以保证整个检测算法的实时处理。思路是统计窗口覆盖区域中的像素直方图，再根据直方图统计的频数选取中值，每次窗口移动后，把移出窗口外的像素灰度值频数减一，移进窗口的像素灰度值频数加一，然后根据统计的频数选取中值。具体的算法步骤如下：

- (1) 读取灰度图像的像素灰度值；
- (2) 定义一个整形的数组，来统计像素灰度值的频数，其中数组下标表示的是灰度值大小，而数组保存的

数值为该灰度值的频数；

(3) 对于移出窗口的像素灰度值，其对应的频数减一，即下标等于该灰度值的数组减一；

(4) 对于移进窗口的像素灰度值，其对应的频数加一，即下标等于该灰度值的数组加一；

(5) 从头累加数组，当和大于等于窗口内像素个数一半的时候，该数组的下标即为窗口内的中值。

随着窗口的增大，传统的滤波方法的运算时间是随着排序的时间复杂度 $O(2N^2 \log N)$ 增加的，而改进的滤波算法只需要统计进入和移出窗口的像素灰度值的频数即可，时间增加是和窗口边缘的大小 N 相关的，减小时间复杂度，以保证整个检测算法的实时处理。

2.2 故障特征提取

图像目标区域的特征提取，是整个算法的核心，关系到算法的最终结果好坏。如图 2 所示，典型的管道故障类型一般分为管道裂缝、管道漏洞、管道接口断开等故障（实际故障图片来自于英国水利工业委员会出版的管道故障分类手册）。各故障特点分明：管道漏洞接近为圆形区域，管道裂缝为树枝状区域，管道接口断开为环形区域。根据上述特点，本文提取故障区域的几何参数：即采取目标区域外接矩形的参数，然后根据参数的不同来划分故障。



(a) 管道裂缝



(b) 管道漏洞



(c) 管道接口断裂

图 2. 典型的管道故障

2.2.1 边缘检测

为了便于目标区域特征参数的提取，先进行图像的边缘检测，分割出目标区域和背景，然后提取出目标区域外接矩形的长边长度、短边长度。经典的边缘检测算法一般是考察图像中像素邻域内的灰度变化，利用边缘区域像素的灰度值变化较为剧烈的特性，根据灰度值函数的一阶或者两阶导数的变化，来寻找边缘的位置^[14]。常见的算法包括各种的微分算子，如 Sobel 算子，Prewitt 算子，Roberts 算子，Laplace 算子和 Canny 算子等，边缘检测算法效果图如图 3 所示。Robert 算子提取边缘效果最差，管道裂缝故障的边缘几乎没有提取成功；而 Sobel 算子和 Prewitt 算子的边缘提取效果相当，都能满足需求，由于 Sobel 算子运算量小，所以选择 Sobel 算子进行边缘检测。




图 3. 不同边缘检测方法效果图

2.2.2 特征提取

根据故障区域不同的特点，选取的特征参数是故障区域最小面积外接矩形的几何参数，包括矩形的长和宽。




图 4. 不同故障特征参数分布情况

在实验室环境下，采取了 199 张不同类型故障的图像（管道裂缝 89 个，管道漏洞 77 个，管道断裂 33 个），然后提取出对应外接矩形的长和宽，其分布如图 4 所示。由图 4 可以看出，管道漏洞故障特征向量分布区域在 $\vec{f}_{hole} \in A = \{30 < l < 125, 10 < s < 50\}$ ，管道裂缝故障特征向量分布区域在 $\vec{f}_{crack} \in B = \{130 < l < 350, 20 < s < 150\}$ ，管道断裂故障特征向量分布区域在 $\vec{f}_{tear} \in C = \{300 < l < 500, 300 < s < 500\}$ 。

不同故障的外接矩形的长边长度、短边长度以及长边/短边会有一些区分，因此，我们可以根据这些特征参数的不同，来划分不同类型的故障。选取的故障区域特征向量如下定义：

$$\vec{f} = \{l, s, r\} \quad (2)$$

其中， \vec{f} 为一幅图像的特征向量； l 为图像故障区域外接矩形的长边长度； s 为图像故障区域外接矩形的短边长度； $r = l/s$ 为长边长度除以短边长度。




图 5. 不同故障特征向量分布情况

2.3 故障分类

通过特征向量的分布可以看出，不同故障类型的特征向量有显著的不同，故障分类采用 K-means 聚类算法。K-means 聚类算法的基本思想为：选取类别个数 K 和随机选取 K 个初始聚类中心，然后按照最小距离的原则，将各个样本分配到 K 类中的某一类，接着通过计算调整新的类中心，进行样本的划分，最终使各样本到其所属类别中心的距离平方和最小。算法具体步骤如下：

- (1) 选取需要划分的类别个数 K 和随机选取 K 个初始聚类中心；
- (2) 按照最小聚类原则对样本进行归类；
- (3) 重新计算每个类别的聚类中心；

(4) 对所有的样本重新进行聚类，若聚类结果发生变化，则返回(2)继续进行。

K-means 聚类算法有两个比较大的缺点：一是类别个数 K 的选取，二是初始聚类中心的选取。在本文中，为了避免这两个参数对聚类结果造成较大的误差影响，仿真之前可以根据故障的类型进行 K 的选取，典型故障提取出来的特征向量来指定每个类型的初始聚类中心，这样就避免了初始值的选取对聚类结果的影响。

对于算法具体步骤进行几点说明：

(1) 最小聚类原则：即指定一个距离函数 $f(X,Y)$ ，其中 X 为聚类的中心点，Y 为选取的归类样本，选择使得函数 $f(X,Y)$ 最小的 Y，并把 Y 归并到 X 所在的类别中，一般情况，距离函数选取的是欧氏距离：

$$f(X,Y) = \sqrt{(x_1 - y_1)^2 + (x_2 - y_2)^2 + \dots + (x_n - y_n)^2} \quad (3)$$

其中， $X = \{x_1, x_2, \dots, x_n\}$ ， $Y = \{y_1, y_2, \dots, y_n\}$ 。

(2) 聚类中心的重新计算：

对于每个聚类中的样本元素 Y_1, Y_2, \dots, Y_m ，重新选取的聚类中心为：

$$X = \frac{1}{m} \left\{ \sum_{i=1}^m y_{1i}, \sum_{i=1}^m y_{2i}, \dots, \sum_{i=1}^m y_{ni} \right\} \quad (4)$$

根据上述的算法，对 199 张不同类型故障的图像（管道裂缝 89 个，管道漏洞 77 个，管道断裂 33 个）进行聚类，结果如图 6 所示。




图 6. 基于 K-means 聚类的故障分类结果

注：红色特征向量代表聚类结果是管道漏洞的特征向量，星号“*”表示该特征向量本为管道漏洞故障；蓝色特征向量代表划分为管道裂缝的特征向量，圆圈“o”表示该特征向量本为管道裂缝故障；黑色特征向量代表划分为管道断裂的特征向量，加号“+”表示该特征向量本为管道断裂故障。图 7、8 和 10 的图注与图注相同。

针对 199 张不同类型故障的图像（管道裂缝 89 个，管道漏洞 77 个，管道断裂 33 个）在 matlab 进行 1000 次仿真，每次随机选取初始化聚类中心，得到的仿真结果如表 1 所示。

表 1. K-means 聚类方法的结果

结果类型	次数	分类正确	分类错误	正确率
1	1000	173	26	86.93%
合计	1000	173000	26000	86.93%

从结果中可以看出，K-means 聚类采用欧氏距离作为距离函数，且聚类中心的重新选择采用的是均值，聚类结果把其中一部分裂缝故障当作为了漏洞故障。分析原因如下：该聚类方法的思想为最终得到不同类型的中

心，把到不同中心距离最近的样本划分到该类型中。从图 5 中可以看出，不同故障的样本分散程度并不相同，同一类型的故障样本占用的空间区域大小不一，因此对 K-means 聚类方法进行一定的改进，使之适用于本文中的应用。

在改进的 K-means 聚类方法中，距离函数 $f(X,Y)$ 不仅考虑样本点到类别中心的欧氏距离，还应该把不同区域的分散程度考虑进去，使调整后的最小聚类原则满足于本文的情况。

在改进后的聚类算法中，最小聚类原则中的距离函数改为如下形式：

$$f(X,Y) = \sqrt{(x_1 - y_1)^2 + (x_2 - y_2)^2 + \dots + (x_n - y_n)^2} / r_x \quad (5)$$

其中， $X = \{x_1, x_2, \dots, x_n\}$ ， $Y = \{y_1, y_2, \dots, y_n\}$ ， r_x 为统计出的 X 类型的分布区域大小。

根据改进的聚类方法，对 199 张不同类型故障的图像（管道裂缝 89 个，管道漏洞 77 个，管道断裂 33 个）进行聚类，结果如图 7 所示。

通过随机选取初始类别中心进行聚类，改进的聚类方法会出现结果不稳定的情况，如图 8 所示。分析上述情况可知，在改进的聚类方法中加入了故障区域的参数 r_x ，当随机给定初始聚类中心时，由于初始值是随机给定的，可能是聚类类别中的任意样本，造成了参数 r_x 和给定的初始中心不匹配，产生了比传统聚类方法更差的结果。




图 7. 基于改进聚类的故障分类结果




图 8. 随机选取的聚类结果

为了避免上述问题，那就要求给定的初始聚类中心必须在对应的聚类类别范围内。在算法研究的训练仿真阶段，利用统计的方法选定符合规定的初始聚类中心和各个类别区域的大小范围，然后将其带入到未知故障分

类的聚类算法中，得到的故障分类结果如表 2 所示。

表 2. 改进的 K-means 聚类方法的结果

结果类型	次数	分类正确	分类错误	正确率
1	25	194	5	97.49%
2	91	193	6	96.98%
3	704	192	7	96.48%
4	171	191	8	95.98%
5	1	190	9	95.48%
6	8	188	11	94.47%
合计	1000	191936	7064	96.45%

从结果中可以看到，改进的方法比传统的方法分类正确率提高接近十个百分点（从 86.93%提高到 96.45%），但是仿真得到的结果多了很多，这是因为：在改进的方法中，使用到了参数 r_x ，而参数 r_x 每次仿真都是单独提取的，存在一定的差异，导致了仿真结果的不一致性。总体来说，相对于基于 K-means 聚类的方法，改进的聚类方法具有更好的划分效果。

3 实验验证

3.1 算法验证

针对于本文提出的基于视觉的故障检测算法，进行算法仿真验证。在 PCV 管道内部人为制造各种故障，包括管道裂缝、管道漏洞、管道断裂以及正常的管道情况，共采集到 350 张管道图片，进行仿真实验。对于所有的图像数据，提取出来的特征向量分布如图 9 所示，管道故障分类的结果如图 10 所示。




图 9. 提取出的特征向量分布




图 10. 管道故障的分类结果

表 3. 改进的 K-mean 聚类方法的实验结果

仿真方法	总体图像	故障图像	正确检测故障数	故障分类正确数
视觉检测	350	281	225	190

从表 3 中可以看出，基于视觉的管道检测方法能够正确识别出 281 个故障图像中的 225 个，故障识别率为 80.07%；对于识别出的 225 个故障图片，能够对其中的 190 进行正确的故障分类，分类的正确率为 67.61%。

3.2 场地实验

针对于本文提出的基于视觉的管道检测方法，进行管道实验验证，软件界面如图 11 所示。该方法能够识别 PCV 管道内部的人为故障，故障识别率和故障分类率与算法验证结果相近。可见，该视觉检测算法能够辅助操作人员识别和分类管道故障，值得在工程中推广。对于没有识别的管道故障仍需要操作人员根据视频信息识别。




图 11. 软件界面

4 结论

针对典型的管道故障（管道裂缝、管道漏洞和管道接口断裂），本文提出了一种新的视觉检测方法，该方法依据不同故障在图像中呈现出的形状特征参数不同来划分的。通过实验验证，该方法能够正确识别管道故障并进行故障分类，并且可以应用到实际工程中辅助操作人员识别和分类管道故障。

参考文献

- [1] 李学军, 洪立波. 城市地下管线的安全形势与对策[J]. 城市勘测, 2011 (5): 166-169.
- [2] 徐匆匆, 马向英, 何江龙, 等. 城市地下管线安全发展的现状, 问题及解决办法[J]. 城市发展研究, 2013, 20(3): 108-112.
- [3] 陈利琼, 吴世娟, 卢泓方, 等. 输气管道腐蚀风险评价技术应用研究[J]. 腐蚀科学与防护技术, 2015, 27(3): 288-294.
- [4] Shi Y, Zhang C, Li R, et al. Theory and Application of Magnetic Flux Leakage Pipeline Detection[J]. Sensors, 2015, 15(12): 31036-31055.
- [5] 席御僖. 埋地管道防腐层破损点电磁法检测磁场分布特性仿真研究[D]. 西南石油大学, 2015.
- [6] Quiroga J, Villamizar R, Mujica L E, et al. Guided ultrasonic wave for monitoring stress levels in pipelines[C]//7th ECCOMAS Thematic Conference on Smart Structures and Materials (SMART 2015): proceedings book, 3-6 june 2015, Ponta Delgada, Azores. 2015.
- [7] 何存富, 周龙, 何守印等. 基于 CCD 的管内移动机器人管道缺陷检测系统[J]. 机械与电子, 2006, 10: 33-35.
- [8] Paul W. Fieguth, Sunil K. Sinha. Automated Analysis and Detection of Cracks in Underground Scanned Pipes[A]. In 1999 International Conference on Image Processing .1999, Vol.4:395-399.
- [9] Sunil K. Sinha, Paul W. Fieguth. Morphological segmentation and classification of underground pipe images[J]. Machine Vision and Applications, 2006, 17(1): 21-31.
- [10] O. Duran, K. Althoefer, L. D. Seneviratne. Automated Pipe Defect Detection and Categorization Using Camera/Laser-Based Profiler and Artificial Neural Network[J]. IEEE TRANSACTIONS. 2007, VOL. 4: 118-126.
- [11] Ming-Der Yang, Tung-Ching Su. Systematic image quality assessment for sewer inspection[J]. Expert Systems with Applications, 2011, 38: 1766-1776.
- [12] 周世龙, 龚德仁, 段登平. CCD 噪声模型在几何最优线性姿态估计中的应用[J]. 传感器与微系统, 2015, 34(3): 154-157.
- [13] 曹治华, 宋斌恒. 多种形状窗口下的快速中值滤波算法[J]. 计算机应用研究. 2006.03: 85-88.
- [14] 戴燕. 图像边缘检测与应用[D]. 西安, 西安科技大学. 2010.