

沥青路面破损图象特征提取方法研究

储江伟 初秀民 王荣本 施树明

(吉林大学交通学院, 长春 130025)

摘要 为了提高利用图象信息对沥青路面破损类型和程度识别的准确性和效率, 提出了一种可减少沥青路面破损图象识别计算量的以图象分割子块模式识别结果为基础的路面破损图象特征提取方法。该方法将路面图象等分为 64×64 像素的子块图象, 并用灰度方差值描述子块图象特征。设计了基于 BP 神经网络的子块图象模式分类器, 利用子块图象模式分类结果所组成的矩阵作为路面破损图象分割结果。通过对典型路面破损类型的识别试验, 证明了该方法的有效性, 将路面破损图象子块分布特征作为路面破损图象的整体特征可以获得较好地路面破损分类识别效果。

关键词 模式识别(520·2040) 路面破损 分类器 特征提取

中国法分类号: U416 **文献标识码:** A **文章编号:** 1006-8961(2003)10-1211-07

Research on Asphalt Pavement Surface Distress Image Feature Extraction Method

CHU Jiang-wei, CHU Xiu-min, WANG Rong-ben, SHI Su-ming

(Transportation College, Jilin University, Changchun 130025)

Abstract In order to improve the accuracy and efficiency to identify the asphalt pavement surface distress by the image information, a method of asphalt pavement surface image feature representation is put forward, which may reduce calculation of pavement surface distress image classification. A pavement surface image is divided into 64×64 pixels sub-images, and the intensity variances are used to represent the sub-images feature. Meanwhile, the sub-image pattern classifier is designed based on BP artificial neural network, all of the sub-images pattern classifying results are arrayed a matrix, and the pavement surface distress image segmentation is represented by this matrix. By the experiment to identify the typical surface distress of asphalt pavement, the conclusions are as follows: (a) the average value and a minimum value of intensity variances of the image segmentation are input to BP artificial neural network, so that the models of distress sub-images can be identified accurately. (b) the counts of horizontal and vertical projection of the distress sub-images models, sum of the distress sub-images, and convinced coefficient of the distress sub-images models may be used to describe the main features of different the pavement surface distress. (c) the distributing features of the pavement surface distress image segmentation are used to represent a integration feature of the pavement distress image, so that a good result for identifying pavement surface distress may be obtained.

Keywords Pattern recognition, Pavement surface distress, Classifier, Feature extraction

0 引言

路面破损数据是路面养护管理中的重要数据之一, 目前主要采用人工检测的方法获取, 但人工检测效率低、耗时, 而且现场检测也不安全, 因此, 开展路

面破损自动检测技术研究具有重要意义。国外的许多学者对此问题进行了相关研究, 例如, Cheng 等利用模糊逻辑结合人工神经网络实时检测路面破损^[1], 获得了较好的分类效果; 此外, 根据路面图象灰度信息的先验知识, 还提出了一种路面破损图象增强的方法^[1], 效果较好, 但是其计算处理时间较

基金项目: 教育部博士点基金项目(20000018507)

收稿日期: 2002-11-28; 成图日期: 2003-06-05

长. Kelvin 等在研究中也采用了径向基网络并设计了硬件以实现路面破损识别实时处理^[2]. Kaseko 等对路面破损识别传统分类器与人工神经网络分类器进行了比较研究,指出了神经网络分类器识别路面破损具有优越性^[3]. Chou 等利用模糊技术增强路面破损图象,在最大模糊熵的基础上选取模糊化的阈值,并根据样本图象建立了一个非线性等式,去除由于亮度不一致所引起的路面图象噪声^[4].

本文利用两套摄像机、图象采集卡、计算机、距离传感器、承载车等组成的沥青路面破损自动检测系统,对宽度覆盖一个车道的路面进行检测,每个摄像机的分辨率为 768×512 像素. 鉴于常规的路面破损调查不需要过高分辨率,提出了基于路面破损子块图象特征的沥青路面图象分割方法,并在此基础上提取路面破损图象的整体特征,从而为路面破损图象识别奠定了基础.

1 路面破损子块图象模式识别

由于路面图象内容复杂,加上受光照、路面噪声等因素的干扰,依据路面破损图象的全局直方图特征进行路面破损识别存在着较大的难度,因此,本文采用对复杂图象进行分割的处理方法,即将整幅路面图象分块,提取子块图象的灰度方差作为特征值,并设计分类器识别子块图象模式.

1.1 路面破损子块图象划分

将图 1(a)所示的路面图象等分为 64×64 像素的子块图象,并计算出各个子块图象灰度标准差矩阵,如图 1(b)所示,若将其中同行标准差大于平均标准差的两数值和相邻两行距离最近的上述标准差连线,其结果与图 1(a)中的裂纹部分基本对应. 若子块图象灰度标准差值越大,则该子块路面破损越严重. 可见采用分块处理路面破损图象特征方法较为合理.

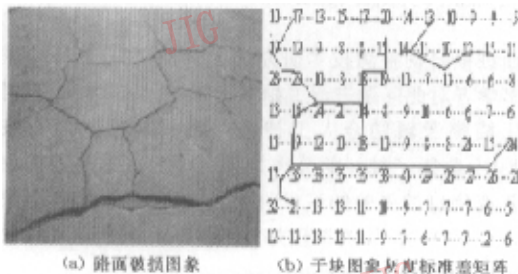


图 1 路面破损图象及其子块图象灰度标准差矩阵

1.2 路面破损子块图象特征值的选取

图象特征是指图象的原始特性或属性. 选取子块路面图象原始灰度值的直方图特征作为子块路面图象特征. 常用的直方图统计信息有:均值、方差、偏度、峰度和熵等. 其中,方差表示图象灰度的分散程度.

设像素灰度为 r ,灰度量化为 256 级, σ 为标准差,则方差为

$$\eta = \sigma^2 = \sum_{r=0}^{255} (r - \mu)^2 p(r) \quad (1)$$

式中, $p(r) = n_r / N$, n_r 是 r 级灰度的像素数, μ 为图象灰度均值, N 为图象总的像素数.

从图 1(b)可以看出,子块图象灰度标准差矩阵基本可以表征路面破损图象特征,而由式(1)可知,用子块图象方差值作为特征值会加大不同类别的子块图象灰度特征值之间的差别. 因此,可选择子块图象灰度方差作为图象特征值.

1.3 路面破损子块图象的分类

由于路面破损子块图象特征值分布极无规律,采用线性分类器难以实现路面破损子块图象正确分类,因此,选用 BP 神经网络分类器.

1.3.1 分类器输入值的确定

路面子块图象的模式可分为:(1)好路面子块图象模式(用 0 来描述);(2)破损路面子块图象模式(用 1 来描述). 对于不同幅路面图象子块图象,只根据灰度方差值 η ,并不能很好地判别子块图象模式,如图 2(a)与图 2(b)中方框内子块图象灰度方差尽管相同,但是它们却代表不同的路面子块模式. 由于同一幅路面图象中所有子块图象的灰度方差值均值 η_{avg} ,能够反映同一幅路面图象的总体信息;同一幅路面图象中所有子块图象灰度方差的最小值 η_{min} ,能够反映同一幅路面图象中破损程度最小的子块图象信息. 因此,本文选用向量 $X_j(\eta_j, \eta_{\text{avg}}, \eta_{\text{min}})$,作为一个分类器的输入值.

1.3.2 分类器训练与子块图象模式识别

选用 BP 网络分类器,采用一个隐层,输入层节点为 3 个,输出层节点为 1 个. 经过试算,隐层选用 9 个节点.

利用 264 个路面子块图象的样本对 BP 网络进行训练,目标误差设定为 0.014. 经过 100 000 次训练后学习过程收敛. BP 网络训练成功后,对图 3(a)所示的路面图象的子块图象模式进行识别实验. 在判断结果时,网络实际输出值大于 0.5 取整为 1,小于 0.5 取为 0,识别结果如图 3(b)所示. 从图 3(a)、

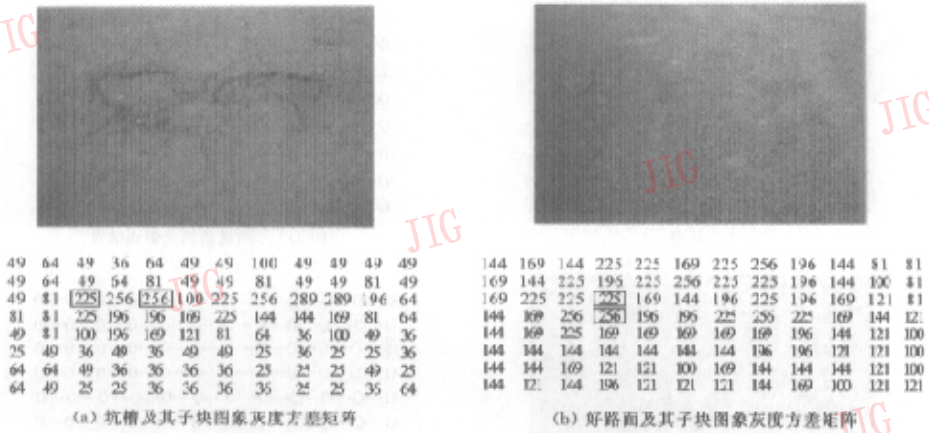


图 2 不同幅路面图像及其子块图像灰度方差矩阵




图 3 路面破损图像及其子块图像模式识别结果

图 3(b)的对比中可以看出,路面破损区域所在的位置与图 3(b)中 1 的位置基本吻合.实验表明,采用神经网络分类器可较好地识别路面破损子块模式.

2 沥青路面图像野点的剔除

在沥青路面上经常存在着沙石、杂物、油迹等噪声,影响子块图像特征值类别的识别.因此,在提取整幅沥青路面特征前,有必要剔除沥青路面图像分割结果中的野点.

2.1 子块模式值在模式值矩阵中的几何形态

由于单个路面破损子块图像特征值与含有噪声的好路面子块图像特征值可能接近,因此,在子块图像的识别中不可避免产生误判.如图 4 所示方框中,路面破损子块图像模式就是由于噪声导致的误判模式.从图 4(d)中可观察到野点(方框中的模式值)在整个子块图像模式值矩阵中,连续性极差,大多为孤立点,而图 4(b)中的破损子块图像模式值在模式值矩阵中具有几何连续性.


2.2 路面破损子块图像模式值连续性描述

像素间的连通性,在确定图像中目标的边界和区域的像素具有重要作用.因此借鉴像素连通性的定义来描述子块图像模式值连续性^[5].


设路面图像模式值矩阵中坐标为 (x, y) 的路面破损子块图像模式值为 p , 4-邻域子块图像模式值用 r 表示,记为 $N_4(p)$,如图 5(a)所示. p 与各个 4-邻域近邻子块图像模式值为一个单位距离. p 的 4 个对角近邻子块图像模式值用 s 表示,记为 $N_D(p)$,如图 5(b)所示.这些子块图像模式值点再加上 p 的 4-邻域组成 p 的 8-邻域,记为 $N_8(p)$.

连通性是建立在连接和连通的基础上.要确定两个子块图像模式值是否连接,在某种意义上要确定它们是否接触,即判断它们是否为 8-近邻子块图像模式值.


用 V 表示连接的破损子块图像模式值集合.在路面子块图像模式值矩阵中,模式值为 1 的破损子块图像模式值之间的连通性可定义为:两个子块图像模式值 p 和 r 在 V 中取值,且 r 在 $N_8(p)$ 中,则它




(a) 块裂



(c) 好路面



(b) (a) 子块图象模式识别结果



(d) (c) 子块图象模式识别结果

图 4 光线不均或油迹等噪声导致的路面子块模式误判




图 5 邻域子块图象模式

们为 8-连接. 从具有坐标的模式值 p 到具有坐标的模式值 q 的通路是由一系列具有坐标 $(x_0, y_0), (x_1, y_1), \dots, (x_n, y_n)$ 的破损路面子块图象模式值组成的. 其中 $(x_0, y_0) = (x, y), (x_n, y_n) = (s, t), (x, y_i)$ 与 (x_{i-1}, y_{i-1}) 相连接, $1 \leq i \leq n, n$ 为通路长度.

设 p 和 q 是一个路面子块图象模式值矩阵 V 中的元素, 如果存在一条完全由在 V 中的元素所组成的从 p 到 q 的通路, 则称 p 在 V 中与 q 相连通.


从图 4(b)可见, 对于路面子块图象中的野点不具有连通性或通路长度极小. 因此, 根据路面破损子块图象模式值的连通性可判断该值是否为野点. 判断野点算法如下:

设路面破损子块图象模式值 p 的 8-邻域值为 $q_i, i=1, 2, \dots, 8, n_p$ 为 p 与其他破损子块模式值的连通长度.


$$\begin{aligned} \text{if } q_i = 0 \text{ then } p = 0; \\ \text{if } n_p \leq 2 \text{ then } p = 0 \end{aligned}$$

2.3 野点剔除实验


在实验中规定: 如果 p 位于子块图象模式值边界, 则其超出边界的 8-邻域模式值为 0. 图 6 为图 4 进行剔除野点后的结果, 可以看出本文提出的剔除野点的算法是有效的.



(a) 块裂



(b) (a) 子块图象模式识别结果



(c) 好路面



(d) (c) 子块图象模式识别结果

图 6 剔除野点后路面子块特征值矩阵及其图象

3.2 路面破损子块图象总数

不同的路面破损类型其破损子块的总数(sum)也是不同的,如网状裂缝 sum 较大,而单根裂缝的 sum 较小.因此,路面破损子块图象总数在一定程度上可以反映路面破损的分类信息.各种路面破损子块总数 sum 的分布,如图 9 所示.因此,根据 sum 可将网状裂缝和其他类型的路面破损较好地区分开来.




图 9 路面破损子块图象总数分布图

3.3 路面破损子块图象模式值的自相关系数

由图 8、图 9 可见, μ_m 、sum 并不能很好地反映坑槽与块裂的分类信息,而由坑槽与块裂子块图象模式值矩阵可见,坑槽破损子块图象分布集中,而块裂破损子块图象分布相对分散,为描述该特征,引入路面破损子块图象模式值的自相关系数.路面破损子块图象分布越集中,其自相关系数越大.反之,其自相关系数小.

设 $f(m, n_i)$ 为路面破损子块图象模式值矩阵中的一点,则路面破损子块图象的自相关系数可由下式求得

$$con(\epsilon, \eta) = \frac{\sum_{i=1}^m \sum_{j=1}^n f(i, j)f(i-\epsilon, j-\eta)}{[\sum_{i=1}^m \sum_{j=1}^n f^2(i, j)]^{1/2} [\sum_{i=1}^m \sum_{j=1}^n f^2(i-\epsilon, j-\eta)]^{1/2}} \quad (4)$$

其中, $\epsilon, \eta = \pm 1$.

在计算路面破损子块图象模式值的自相关系数时,首先扩充路面破损子块模式值矩阵的边缘,在路面破损子块图象矩阵的四周增加一行或一列零向量,使子块模式矩阵扩充为 10×14 .图 10 为路面破损子块子块图象模式值相关系数分布图.坑槽和网状裂缝子块图象模式值的相关系数明显大于其他相关系数,因此,利用 $con(\epsilon, \eta, i, j)$ 可以将网状裂缝和坑槽与其他破损区分开来.




图 10 路面破损子块图象模式值相关系数分布图

3.4 路面破损识别实验

当检测车以 5km/h 的速度运行时,对路面破损进行检测.基于本文提出的路面破损图象特征提取算法能够正确识别典型的路面破损,如图 11 所示.

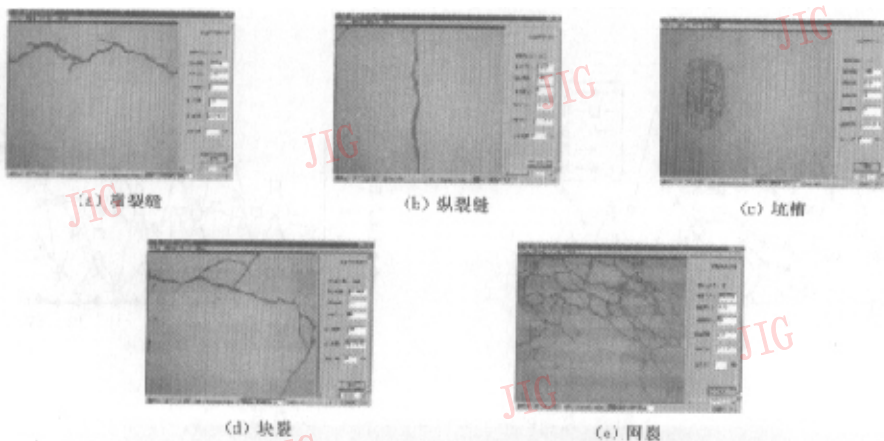


图 11 几种典型路面破损检测结果

4 结 语

通过对路面破损图像进行分割并提取路面破损图像子块特征来识别路面破损类型的自动检测方法的研究, 可得到以下结论:

(1) 将路面破损图像等分为 64×64 像素的子块图像, 以路面破损子块图像的灰度方差值 η_i 、同一幅路面图像中所有子块图像的灰度方差值均值 η_{μ} 、以及同一幅路面图像中所有子块图像灰度方差的最小值 η_{\min} 作为 BP 神经网络分类器的输入值, 可以识别路面破损子块图像模式。

(2) 利用路面破损子块图像分布特征值, 如破损子块模式值水平投影方差 η_{ov} 、破损子块模式值垂直投影方差 η_{ov} 、破损子块总数 sum 和路面破损子块图像模式值的自相关系数 $\text{con}(\epsilon, \eta, i, j)$, 可以分别作为描述各种不同路面破损类型的主要特征。

(3) 由于路面破损图像内容复杂, 采用分块处理的方法进行路面破损类型的识别, 即以所有子块模式所组成的矩阵作为路面破损图像分割结果, 可以减少后续图像处理的计算量。

(4) 应用本文提出的方法对典型沥青路面破损类型进行动态识别实验的效果较为理想, 说明本文提出的路面破损特征提取算法是有效的, 具有一定的实用性。同时, 该研究方法的思路也可以用于对水泥路面破损的识别。

(5) 由于路面破损的类型不同, 其模式特征有明显的差别。若以同样的模式特征进行破损类型的分类识别, 必然会造成某些破损类型区分上的困难和混淆, 所以, 应在上述研究的基础上, 继续进行系统性识别方法的研究, 以提高对路面破损识别的准确性和可靠性。

参 考 文 献

1 Cheng H D, Miyojim M. Novel system for automatic pavement distress detection[J]. Journal of computer in civil engineering, 1998, 12(3): 145~152.

- 2 Kelvin. Designs and implementation of automated systems for pavement surface distress survey[J]. Journal of infrastructure systems, 2000, 6(1): 24~32.
- 3 Kaseko Mohamed S, Ritchie Stephen G. Pavement image processing using neural networks[A]. In: Proceedings of the 2nd. International Conference on Applications of Advanced Technologies in Transportation Engineering [C]. Minnesota, USA, 1991, 18~21.
- 4 Chou Ch P, Liou T. Development of automated algorithms for pavement condition survey[R]. Transportation Research Record (No1536), National Research Council, Washington D. C, USA, 1996, 11: 103~109.
- 5 章毓晋. 图像工程[M]. 北京: 清华大学出版社, 2000.



储江伟 1962年生, 教授, 2000年获东北林业大学机械设计与理论专业工学博士学位, 2000年~2002年在吉林大学交通运输工程博士后流动站进行博士后研究, 主要研究方向为视觉引导 AGV、模式识别和机器视觉检测技术等。



初秀民 1969年生, 讲师, 2003年在吉林大学获载运工具运用工程专业工学博士学位, 主要研究方向为智能车辆、路面破损图像识别和相关检测技术等。



王荣本 1946年生, 教授, 博士生导师, 1994年获吉林工业大学车辆工程专业工学博士学位, 主要研究方向为智能车辆、图像识别和机器视觉导航等。



施树明 1966年生, 副教授, 1998年获吉林工业大学载运工具运用工程专业工学博士学位, 主要研究方向为智能车辆、图像识别和融合导航技术等。