文章编号:1009-6582(2020)02-0013-07 DOI: 10.13807/j.cnki.mtt.2020.02.002

基于支持向量机的隧道衬砌空洞机器识别方法

覃 晖[1] 唐 玉[2] 谢雄耀[3,4] 王峥峥[1]
(1 大连理工大学土木工程学院,大连 116024;2 大连理工大学水利工程学院,大连 116024;
3 同济大学岩土及地下工程教育部重点实验室,上海 200092;4 同济大学地下建筑与工程系,上海 200092)

摘 要 探地雷达是检测隧道衬砌空洞最为有效的方法之一,但检测数据的解析始终是限制其广泛应用的关键。基于支持向量机的基本理论,文章建立了一套隧道衬砌空洞探地雷达图像的机器识别方法,该方法包括图像预处理、特征提取和支持向量机识别三个步骤。首先,探地雷达图像需经过零时修正、滤波、偏移、增益等预处理以提高信噪比;其次,对图像的时域信号进行分段,在分段信号上提取方差、标准绝对偏差和四阶矩三个统计量作为图像特征;最后,利用已知数据对支持向量机模型进行训练,并用数值模拟和模型试验数据对训练好的支持向量机模型进行测试。结果表明,该方法不仅能够准确识别隧道衬砌和围岩内的空洞,还可以对空洞埋深及横向分布范围做出较准确的判断。

关键词 隧道 空洞 探地雷达 支持向量机 机器识别
中图分类号:U457+.2 **文献标识码**:A

1 引 言

在已建或在建的公路隧道中,受设计、施工或环境等因素的影响,衬砌空洞病害十分普遍,有的甚至非常严重,给隧道的施工和运营造成了较大威胁[1,2]。探地雷达(Ground Penetrating Radar,GPR)因其无损、连续、快速、操作简便等特点,被认为是最为有效的检测方法之一[3]。但在探地雷达资料的解析方面,目前主要依靠人工经验进行,这虽然能够满足一些基本的检测需要,但面对大量的检测数据,人工处理显然无能为力,这也制约了探地雷达的推广应用[4,5]。因此,有必要研究探地雷达数据的机器识别算法,这不仅能提高解析效率,还可以最大程度地消除数据处理人员的主观影响,从而增强数据解析的可信度和探地雷达的易用性。

模式识别作为人工智能的一个重要分支学科,其本质就是根据模式的特性表达和模式类的划分方法,通过利用计算机将模式判属特定的类[6]。这恰好满足对探地雷达图像进行机器识别的要求,即计算机通过分析探地雷达图像中回波信号的特性,将目标体的回波信号识别出来。支持向量机(Support Vector Machine,SVM)作为模式识别的方法之一[7],因其在信号处理方面的自身优势,近年来被越来越多地应用于探地雷达图像的识别中。Wu 等[8]通过采用探地雷达方法检测铁路路基下的空穴,并采用支持向量机对存在空穴的单道雷达信号进行识别,获得了较高的分类准确率;Pasolli 等[9]通过采用支持向量机识别探地雷达图像中埋设物体的位置、大小、形状和材质,取得了较好效果,但其特征提取方法过于复杂;Ehret[10]在识别探地雷达图像中的岩石层面位置中综合比较了神经网络方法和支持向量机方法,得出支持向量机在识别准确率、模型结构以及训练简便性等方面均优于神经网络方法的结论;Shao 等[11]通过采用探地雷达方法检测铁路路基,并采用支持向量机方法对道砟类型进行了分类,但所建立

修改稿返回日期:2019-03-01
基金项目:国家自然科学基金项目(41904095);中央高校基本科研业务费专项资金(DUT19JC23,DUT19RC(4)020);同济大学岩土及地下工程教育部重点实验室开放基金项目(KLE-TJGE-B1804).
作者简介:覃 晖(1985-),男,博士,讲师,主要从事隧道及地下工程检测相关研究工作,E-mail: hqin@dlut.edu.cn.

的分类模型的泛化性能较弱，对天线高度改变后的检测数据分类的准确率较低；周辉林等[12]通过在高速公路路基病害检测中利用支持向量机对层位信息进行识别、获得了较高的识别准确度；洪旭程等[13]通过利用支持向量机和Hough变换确定隧道衬砌钢拱架的位置和间距，取得了较好效果。

为识别探地雷达探测隧道衬砌空洞的雷达图像，本文建立了一种基于支持向量机算法的探地雷达图像机器识别方法，该方法包括图像预处理、图像特征提取和支持向量机模式识别三个步骤。首先，通过对获得的探地雷达图像进行预处理，提高数据信噪比，改善图像质量；其次，将雷达图像的单道信号进行分段，并提取分段信号的方差、标准绝对偏差和四阶矩作为信号特征；最后，将特征送入训练好的支持向量机模型，便可实现对衬砌空洞的机器识别。文章最后利用训练后的支持向量机模型分别对数值模拟和模型试验获得的雷达图像进行识别，以评价该方法的适用性。

2 基于支持向量机的识别方法

模式识别包含分析和判断两个过程，分析的过程在于确定用于划分模式类的特征及其表达方法；判断的过程则在于依据待识别对象的特征，将其判属于某一个模式类。因此，本文建立的探地雷达图像自动识别方法包括：(1)图像预处理；(2)图像特征提取；(3)支持向量机模式识别。识别流程如图1所示。

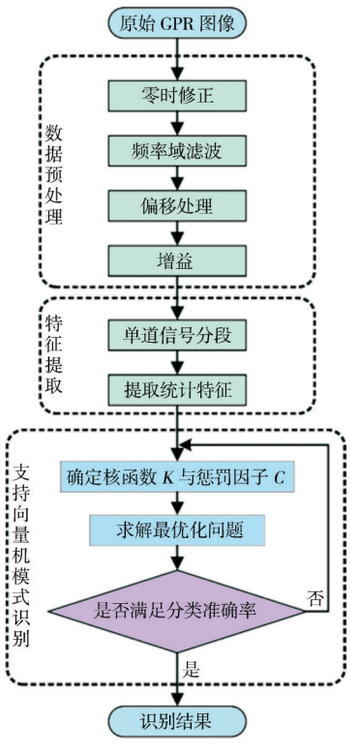


图1 雷达图像识别流程图

Fig.1 Flowchart of the GPR image recognition

2.1 图像预处理

受隧道环境和检测介质复杂性的影响，实测的探地雷达图像存在大量噪声，严重影响数据质量；同时，随着探测深度的增加，信号强度逐渐衰减，使得目标体的回波难以辨认。因此，在对图像进行分析和识别之前，需要对图像进行一定的预处理，以压制噪声，恢复振幅，提高信噪比。本文对探地雷达图像采取的预处理方法包括零时修正、频率域滤波、偏移和增益等。

零时修正：探地雷达图像上的零点，即第一个反射面，对应着衬砌表面的位置。零时修正就是将雷达图像上零点以上的部分去除，并在时间剖面上定义新的时间起点。这样处理的好处在于，一方面通过删减一部分数据减少了后续处理的数据量，另一方面雷达图像的时间轴可以从零点直接读取，无须再进行加减操作，方便识图。根据探地雷达时间剖面的特点，零点通常位于第一次强反射处，为表面反射波和直达波的叠加，集中了回波的大部分能量，在图像上表现为连续且平直的同相轴，在波形上较易分辨出来。根据这一特点便可找到时间零点，并将其之前的图像去除。

频率域滤波：在探地雷达的野外测量中，为保留尽可能多的信息，常采用全通的记录方式，将有效波和干扰波同时记录下来。为了去除数据中的干扰波，可根据有效信号和干扰信号频谱范围不同的特点，采用频率域滤波的方法来消除干扰波。

偏移：探地雷达在探测地下目标时，易偏离测点处地下介质交界面的反射点，只要其法平面通过测点，均可以被记录下来。在数据处理中需要把雷达记录中的每个反射点移到其原来的位置，这种处理方法称为偏移归位处理。经过偏移处理的雷达剖面可反映地下介质的真实位置。

增益：电磁波经发射天线发射进入地下，受波前扩散、地下介质对电磁波的吸收作用以及电磁波的散射、绕射等的影响，经地下物体反射后到达接收天线的电磁波振幅和能量将产生衰减，导致深层异常体的反射信号微弱，增大了分辨难度。因此，需要对信号进行增益处理。首先，需根据探地雷达信号的振幅衰减曲线拟合得到最优的衰减拟合曲线；然后，由记录的反射波的振幅与双程走时，来恢复反射波的真振幅。

2.2 特征提取

支持向量机的输入须为待识别样本的特征，因此在自动识别之前须对探地雷达图像进行特征提取，为支持向量机提供样本。综合考虑各类特征的提取方法，探地雷达信号时域特征的提取较为容易，且信号本身的幅度、形状以及位置等也能反映被测目标的某些性质。因此，本文通过从探地雷达的时域图像中提取统计量作为特征。常用的统计量包括均值、标准差、方差、最小值、最大值、总和、全矩、峰度、偏度、均值标准误差等。通过总结分析，本文提取信号的方差 σ^2、标准绝对偏差 MAD 和四阶矩 M_4 三个统计量作为模式识别的特征[14,15]，该特征能够使有用的反射回波和无用的反射回波在特征空间中较好的分离，这三个特征分别由式(1)~(3)给出。

$$\sigma^2 = \frac{1}{n-1}\sum_{i=1}^{n}(m_i - \bar{m})^2 \tag{1}$$

$$MAD = \frac{1}{n}\left(\sum_{i=1}^{n}|m_i - \bar{m}|\right) \tag{2}$$

$$M_4 = E(m - \bar{m})^4 \tag{3}$$

式中：m_i 为长度为 n 的信号 m 的第 i 个分量；$\bar{m}$ 为信号 m 的均值；$E(m)$ 为 m 的期望。

特征提取是在探地雷达数据的单道信号上进行的，如图2所示。首先对单道信号进行分段处理，分段长度为 n_d，分段后通常在信号末端还有余留长度 n_l。分段对长度没有限制，但分段的原则使每段信号尽量完整的包含有用回波的特征，同时长度尽可能短。另外，因在信号末端通常已不含用回波，因此余留的信号在处理与识别时不加考虑，仅在识别完成之后用于恢复原信号长度时使用。

分段完成后，计算每一段的三个特征：σ，MAD 和 M_4，并储存在向量 $s_i=[\sigma_i, MAD_i, M_{4i}]$ 中。同时，给每一个 s_i 指定一个标签 c_i 来表征该段信号所属的类，其中 c_i=1 表示该段信号为来自空洞的反射，c_i=0 表示该段信号并非空洞的反射。因此，每个分段信号可用一个向量 $T_i=[s_i, c_i]$ 来表示，称为一个样本。

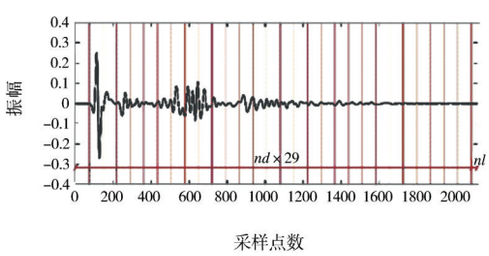


图2 单道信号分段示意

Fig.2 Schematic diagram of the single-track signal segmentation

支持向量机正是通过对这些样本进行判断来实现对探地雷达图像的识别。

2.3 支持向量机

如图3所示，以二维样本为例，在某个低维空间中存在两类样本(以方点和圆点表示)，它们在此空间中线性不可分。支持向量机的基本思想是：通过某个非线性变换 Φ 将样本转换到某个高维空间中，使得大部分样本在高维空间中线性可分。然后在高维空间中求得一个超平面，使得两类样本最大程度地分开，且分类间距最大。这个超平面就称为最优分类面。

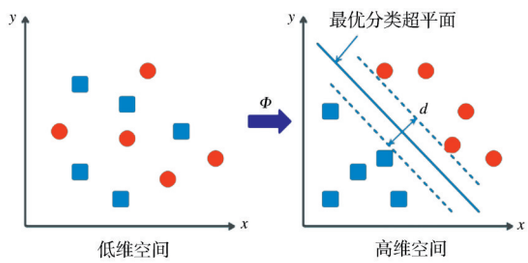


图3 支持向量机基本原理

Fig.3 The basic principle of SVM

在高维空间中求最优分类面，就是使超平面满足式(4)，即：

$$\begin{aligned} &\min \frac{1}{2}\|\omega\|^2 + C\sum_{i=1}^{N}\xi_i \\ &s.t. y_i(<\omega\cdot\Phi(x_i)>+b) \geqslant 1-\xi_i \\ &\xi_i \geqslant 0 \end{aligned} \tag{4}$$

式中：(x_i, y_i) 为训练样本；N 为样本数量；ω 和 b 分别为超平面的法向量和常数项；ξ_i 为松弛变量，表示为对超平面错误分类的容忍程度；C 为惩罚因子，表示为对分类错误的惩罚程度。

此问题是在约束条件下求最小值的问题，这是一个凸二次规划问题，该问题可通过构造 Lagrange 函数转化为对偶问题式(5)。

$$\begin{aligned} &\max_{\alpha} -\frac{1}{2}\sum_{i=1}^{N}\sum_{j=1}^{N}y_i y_j\alpha_i\alpha_j\left(\Phi(x_i)\cdot\Phi(x_j)\right)+\sum_{j=1}^{N}\alpha_j \\ &s.t. \sum_{i=1}^{N}y_i\alpha_i = 0, \\ &\quad 0 \leqslant \alpha_i \leqslant C, \quad i=1,2,\cdots,N \end{aligned} \tag{5}$$

式中：α 为 Lagrange 乘子。由于寻求特征映射 Φ 的显式表达通常非常困难，而通过构造一个核函数 $K(x_i,x_j)=\langle\Phi(x_i)\cdot\Phi(x_j)\rangle$，采用样本间的内积运算代替特征映射，可将样本隐式的表达为特征空间。

求解此对偶问题，便可得到最优分类超平面式

(6)和决策函数式(7)。

$$\sum_{i=1}^{N} y_i \alpha_i K(x_i, x_i) + b^* = 0 \tag{6}$$

$$f(x) = \mathrm{sgn}\left(\sum_{i=1}^{N} y_i \alpha_i K(x_i, x) + b^*\right) \tag{7}$$

对于待判断的样本,将其代入决策函数式(7),便可得到它的分类。

综上可知,支持向量机能够在多大程度上解决线性不可分问题,核函数的构造与选取是关键。就目前的研究而言,支持向量机中核函数的选择仍然是一个比较复杂的问题,并没有从理论上解决针对什么问题应该选用怎样的核函数,选择核函数的方法仍旧依靠经验结果[16]。从经验来看,径向基函数(RBF)是人们在解决实际问题中最常用的核函数,其原因在于它的使用常能为实际问题提供满意的结果。因此,本文选取RBF作为支持向量机的核函数,其表达式如下:

$$K(x, x') = \exp\left(-\frac{\|x - x'\|^2}{\sigma^2}\right) \tag{8}$$

式中:σ^2为RBF的系数。

3 识别方法的应用

利用支持向量机进行机器识别,首先用已知类的探地雷达数据对支持向量机进行训练,以确定支持向量机的惩罚因子C和RBF核的参数σ^2,得到决策函数,也称之为支持向量机模型。模型训练后便可对未知的探地雷达图像进行判断,识别其中的空洞。

3.1 训练数据的获取

对支持向量机模型进行训练,需要使用已知的含有空洞的探地雷达数据和不含空洞的探地雷达数据作为训练样本。获取探地雷达数据的途径包括实地探测、模型试验和计算机数值模拟等。在实地探测中,受隧道条件复杂、探测受多方面约束、衬砌空洞情况本身不明确等因素的影响,获得的数据非常复杂,干扰较多,目标体也难以分辨;模型试验可以在一定程度上弥补实地探测的缺陷,通过试验可以准确地模拟隧道结构及其背后的空洞情况,可有效控制实地探测中的不利因素,但试验可获得的数据量非常有限,模型制作成本高,且受到各种制作工艺条件的限制,获得的数据也存在一定程度的噪声;通过利用计算机数值模拟可获得任意介质参数和空洞尺寸条件下的雷达图像,能大大丰富训练样本的类型,且获得的雷达图像还具有很高的信噪比,但由数值模拟得到的是理想条件下的雷达图像,与真实数据存在一定差异,这种差异可能会导致识别结果的偏差。因此,本文采用数值模拟来获取不同类型空洞的探地雷达图像作为训练数据的同时,考虑到数据的真实性,向训练数据中加入模型试验数据共同构成训练数据集。通过对不同试验数据含量的训练数据进行测试可知,试验数据的加入对识别准确率的提高有一定的改善作用,当试验数据含量达到20%时,模型的识别准确率有较明显的改善,而当进一步提高试验数据含量时,由于更多的试验数据带来了更多的数据噪声,改善效果逐步减弱。因此,本文采用向量训练数据集中加入20%的模型试验数据。这样的训练集既保证了训练数据的真实性和丰富性,又降低了训练数据的获取成本。

用于生成训练数据的数值模型如图4所示,模型尺寸为3.0 m×2.6 m,第一层为空气(ε_r=1.0,σ=0),厚度为0.2 m;第二层为混凝土衬砌(ε_r=9.0,σ=0.01),厚度为0.6 m;第三层为围岩(ε_r=6.0,σ=0.01),厚度为1.8 m。在模型中布置空洞,空洞形状为S,埋深为H,宽度为R。为了使训练数据相对干净以保持目标体的特征,在数值模拟中不考虑衬砌内钢筋的影响。

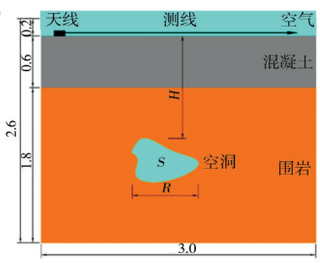


图4 隧道衬砌空洞训练模型(单位:m)

Fig.4 Training model of the tunnel lining void (Unit: m)

探地雷达图像可通过时域有限差分(Finite-Difference Time-Domain,FDTD)方法获取[17],天线中心频率为500 MHz。为获得不同空洞分布下的探地雷达图像,对空洞的三个参数取不同的值并进行组合。取S={三角形,正方形,圆形},H={0.2 m,1.0 m},R={0.1 m,0.2 m,0.3 m},正演计算后共获得18幅探地雷达图像。通过对雷达图像进行预处理和特征提取,共获得含有空洞的样本185个,不含空洞的样本42 354个。为保证正反样本的均衡性,在不含空洞的样本中随机抽取185个,与含有空洞的样本一起组成大小为370的训练样本集。

通过模型试验获取实测训练样本。根据某公路隧道的设计资料,建立如图5所示的物理模型,采用直立的混凝土墙模拟隧道衬砌,墙高2 m。二次衬砌

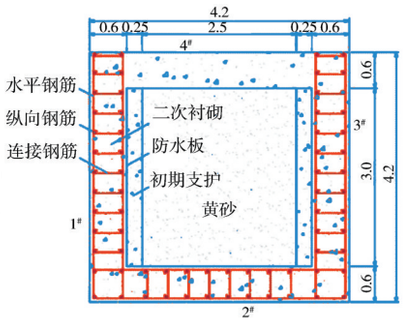


图5　隧道衬砌物理模型(单位:m)

Fig.5　Physical model of the tunnel lining (Unit: m)

采用C25商品混凝土浇筑,厚度为0.6 m,在垂直于测线方向配置直径为22 mm的钢筋,沿测线方向配置直径为12 mm的钢筋,同时配置直径为8 mm的连接钢筋,钢筋间距均为0.33 m;在二次衬砌后贴防水材料,第一层为PVC防水板,第二层为土工布;防水层后为厚0.25 m的初期支护,初期支护同样采用C25商品混凝土浇筑,不配置钢筋;初期支护后填筑黄砂以模拟围岩。

在1#墙的二次衬砌内部和墙后的黄沙中分别埋设大小为0.1 m和0.16 m的立方体空洞,使用加拿大PULSE EKKO探地雷达系统沿1#墙外侧进行探测,天线中心频率为500 MHz。从探测数据中选取37个含有空洞的样本和37个不含空洞的样本,以此作为实测训练数据加入训练样本中。最终形成的训练样本集含有样本444个,其中数值模拟样本370个,实测样本74个。

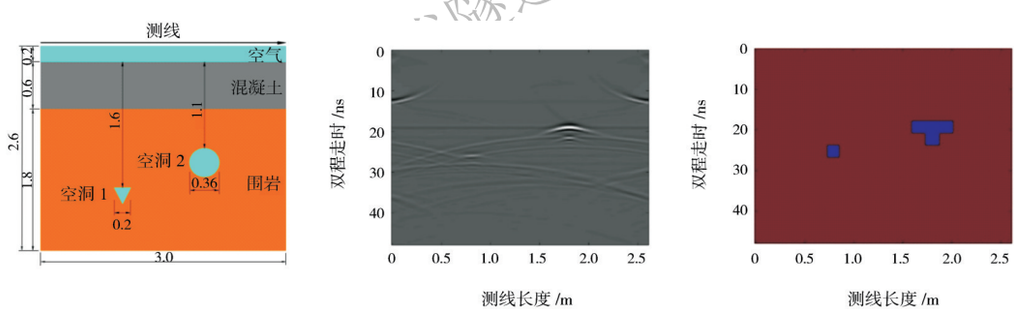
3.2　模型训练

用此样本集对支持向量机进行训练,可得到C和σ^2的最优值分别为C_{op}=8.968 3和σ^2_{op}=22.627 4,训练好的支持向量机模型在这两个参数下对训练样本的分类准确率可达93.562 2%。

3.3　识别结果

分别用数值模拟和实测的探地雷达图像对上述支持向量机模型进行测试。建立用于测试的衬砌空洞数值模型如图6(a)所示,模拟围岩中存在两个空洞的情况。介质参数与训练模型取值相同,空洞1和空洞2在围岩内的埋深分别为1.6 m和1.1 m,形状分别为倒三角形和圆形,横向宽度分别为0.2 m和0.36 m。

采用FDTD方法模拟天线中心频率为500 MHz的探地雷达沿二次衬砌表面进行探测,雷达图像经预处理后如图6(b)所示。将此图像进行特征提取后送入已训练好的支持向量机模型进行机器识别,识别结果经过可视化处理后如图6(c)所示,蓝色代表识别出的空洞,红色代表非空洞。由图6(c)可知,经过训练的支持向量机模型准确地识别出了围岩内的两个空洞。



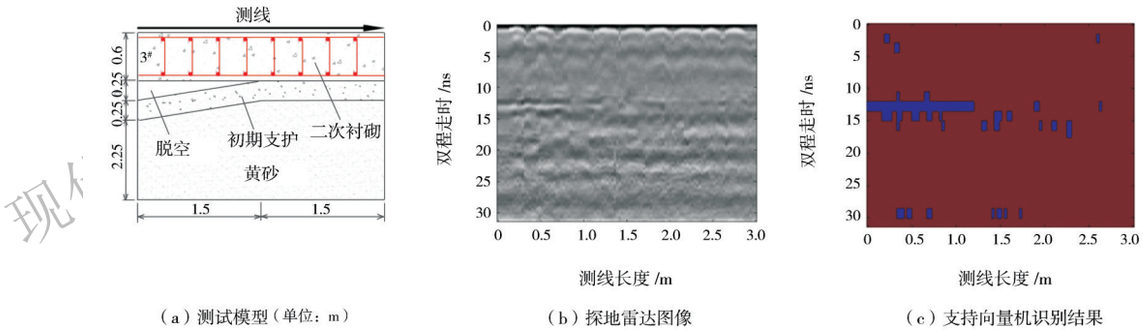
(a) 数值测试模型(单位:m)　(b) 数值模拟探地雷达图像　(c) 支持向量机识别结果

图6　数值测试模型和识别结果

Fig.6　The numerical testing model and recognition result

实测探地雷达的测试数据可利用图5建立的物理模型来获取。为与训练数据有所区分,用于测试的模型试验在3#墙完成,如图7(a)所示,空洞设置为二次衬砌与初衬脱空的情况,脱空长度为1.5 m,厚度从0.25 m逐渐变化到0(密贴)。测试设备仍采用PULSE EKKO探地雷达加载500 MHz天线,雷达图像经预处理后如图7(b)所示。将此图像进行特征提取后送入已训练好的支持向量机模型进行识别,识别结果经过可视化处理后如图7(c)所示,蓝色代表识别出的空洞,红色代表非空洞。由图7(c)可知,支持向量机识别到了二次衬砌与初期支护之间的脱空,但由于在实测数据中含有较多噪声,导致识别结果中出现了一定程度的误判,但误判区域多为小的噪声点,并不影响对脱空区域的判断。

表1给出了上述数值模拟和模型试验识别结果



（a）测试模型（单位：m）　（b）探地雷达图像　（c）支持向量机识别结果

图7　测试模型和识别结果

Fig.7　The testing model and recognition result

表1　支持向量机识别结果

Table 1　The recognition results of SVM

测试工况	空洞	是否找出空洞	真实埋深/识别埋深/m (相对误差)	真实宽度/识别宽度/m (相对误差)
数值模拟	空洞1	是	1.6/1.52 (5.0%)	0.2/0.17 (15.0%)
	空洞2	是	1.1/1.07 (2.7%)	0.36/0.42 (16.7%)
模型试验	脱空	是	12.0/11.9 (0.8%)	1.5/1.32 (12.0%)

的定量评价。由表1可知，对于由数值模拟和模型试验获得的探地雷达图像，支持向量机均识别出了在模型中设置的空洞；支持向量机对空洞埋深的识别精度较高，可达5%以内，而对空洞的横向分布宽度识别误差稍大，在17%以内。总体来说，该方法用于隧道衬砌空洞探地雷达图像的识别是可行的，经过训练的支持向量机模型能够找出位于衬砌和围岩内的空洞，并能较准确的给出空洞的位置和埋深。

4　结　论

本文针对探地雷达检测隧道衬砌空洞问题，建立了一种基于支持向量机算法的隧道衬砌空洞机器识别方法，该方法包括图像预处理、图像特征提取和支持向量机训练与识别等步骤，所得主要结论如下：

（1）数据特征的选取是支持向量机能够正确分类的前提，本文采用方差、标准绝对偏差和四阶矩三个统计量作为模式识别的特征，通过构造径向基函数作为支持向量机的核函数，使空洞和非空洞的探地雷达图像特征能够较好的区分开来。

（2）训练数据的质量直接影响支持向量机的识别效果，由于已知空洞分布的探地雷达实测数据相对稀缺且包含噪声，本文通过采用时域有限差分方法进行探地雷达数值模拟，获取了不同大小、不同位置和不同形状空洞的探地雷达图像，以此作为支持向量机的训练数据，极大地丰富了训练样本的多样性。同时，考虑到数值模拟数据与实测数据的差异，通过向训练集中加入20%的模型试验数据作为训练样本，以修正训练样本库可能导致的识别结果偏差。

（3）通过由数值模拟和模型试验获得的数据对支持向量机的识别效果进行测试可知，采用支持向量机方法用于识别探地雷达图像中的隧道衬砌空洞是可行的，该方法能够准确检测到雷达图像中含有的空洞，对空洞埋深及横向分布宽度都能做出较准确的判断，识别精度已能满足实际工程的需要。

参考文献

References

[1] WANG Jifei，HUANG Hongwei，XIE Xiongyao，et al. Void-induced Liner Deformation and Stress Redistribution[J]. Tunnelling and Underground Space Technology，2014，40：263-276.

[2] 方 勇，郭建宁，康海波，等. 富水地层公路隧道衬砌背后空洞对结构受力的影响[J]. 岩石力学与工程学报，2016，35 (8)：1648-1658.
FANG Yong，GUO Jianning，KANG Haibo，et al. Influence of Voids behind Lining on the Mechanical Behavior of Liming Structure of Highway Tunnel in Watery Strata[J]. Chinese Journal of Rock Mechanics and Engineering，2016，35 (8)：1648-1658.

[3] 杨 睿，薛亚东，杨 健. 雷达探测隧道壁后空洞的现场验证及空洞影响分析[J]. 隧道建设，2017，37 (2)：185-191.
YANG Rui，XUE Yadong，YANG Jian. In-situ Verification of Voids behind Tunnel Lining Detected by Ground Penetrating Radar and Numerical Analysis of Influence of Voids on Tunnel Structure [J]. Tunnel Construction，2017，37 (2)：185-191.

[4] 曾琛超,陈方伟,武建力,等. 基于一致性消除法的盾构隧道探地雷达正演模拟研究[J]. 现代隧道技术, 2015, 52 (4): 173-178.
ZENG Chenchao, CHEN Fangwei, WU Jianli, et al. GPR Forward Simulation for Shield Tunnel Conditions Based on the Consistent Information Removal Method[J]. Modern Tunnelling Technology, 2015, 52 (4): 173-178.
[5] 刘澜波,钱荣毅. 探地雷达:浅表地球物理科学技术中的重要工具[J]. 地球物理学报,2015, 58 (8): 2606-2617.
LIU Lanbo, QIAN Rongyi. Ground Penetrating Radar: A Critical Tool in Near-surface Geophysics[J]. Chinese Journal of Geophysics, 2015, 58 (8): 2606-2617.
[6] DUDA R O, HART P E, STORK D G. Pattern classification(2nd edition) [M]. Hoboken: John Wiley & Sons, 2001.
[7] CORTES C, VAPNIK V. Support-vector Networks[J]. Machine Leaning, 1995, 20: 273-297.
[8] WU Jianbin, TIAN Mao, ZHOU Huilin. Feature Extraction and Recognition Based on SVM[C]// 4th International Conference on Wireless Communications, Networking and Mobile Computing. Dalian:2008.
[9] PASOLLI E, MELGANI F, MASSIMO D. Automatic Analysis of GPR Images: A Pattern-recognition Approach[J]. IEEE Transaction on Geoscience and Remote Sensing, 2009, 47 (7): 2206-2217.
[10] EHRET B. Pattern Recognition of Geophysical Data[J]. Geoderma, 2010, 160 (1): 111-125.
[11] SHAO W, BOUZERDOUM A, PHUNG S L, et al. Automatic Classification of GPR Signals[C]// 13th International Conference on Ground Penetrating Radar. Lecce: 2010.
[12] 周辉林,姜玉玲,徐立红,等. 基于SVM的高速公路路基病害自动检测算法[J]. 中国公路学报, 2013, 26 (2): 42-47.
ZHOU Huilin, JIANG Yuling, XU Lihong, et al. Automatic Detection Algorithm for Expressway Subgrade Diseases Based on SVM [J]. China Journal of Highway and Transport, 2013, 26 (2): 42-47.
[13] 洪旭程,李秀荣. 隧道衬砌检测中探地雷达图像的自动识别[J]. 工程地球物理学报,2015, 12 (6): 828-832.
HONG Xucheng, LI Xiurong. Auto-recognition of Ground Penetrating Radar Image in Tunnel Lining Test Detection[J]. Chinese Journal of Engineering Geophysics, 2015, 12 (6): 828-832.
[14] SHIHAB S, AL-NUAIMY W, HUANG Y. Neural Network Target Identifier Based on Statistical Features of GPR Signals[C]// 9th International Conference on Ground Penetrating Radar.Santa Barbara, CA, USA:2002.
[15] 李志华. 高阶统计量方法在地球物理学中的应用[J]. 工程地球物理学报, 2006, 3 (5):386-391.
LI Zhihua. Application of High-order Statistics in Geophysics[J]. Chinese Journal of Engineering Geophysics, 2006, 3 (5):386-391.
[16] AYAT N E, CHERIET M, SUEN C Y. Automatic Model Selection for the Optimization of SVM Kernels[J]. Pattern Recognition, 2005 (38): 1733-1745.
[17] GIANNOPOULOS A. Modeling Ground Penetrating Radar by GprMax[J]. Construction and Building Materials, 2005, 19 (10): 755-762.

Machine Recognition Method of Tunnel Lining Voids Based on SVM Algorithm

QIN Hui[1] *TANG Yu*[2] *XIE Xiongyao*[3,4] *WANG Zhengzheng*[1]
(1 School of Civil Engineering, Dalian University of Technology, Dalian 116024; 2 School of Hydraulic Engineering, Dalian University of Technology, Dalian 116024; 3 Key Laboratory of Geotechnical and Underground Engineering, Tongji University, Shanghai 200092; 4 Department of Geotechnical Engineering, Tongji University, Shanghai 200092)

Abstract Ground penetrating radar (GPR) is one of the most effective detection methods for tunnel lining voids. However, the difficulties in data explanation are always the key to restrict its wide application. Based on support vector machine (SVM) algorithm, a set of machine recognition method of GPR image for tunnel lining voids is established. This method includes pre-processing of GPR data, feature extraction and SVM recognition. Firstly, the GPR image needs to be preprocessed by time-zero correction, filtering, migration and gain and so on to improve the signal-noise ratio (SNR). Secondly, each time-domain trace of GPR image is segmented and three statistics, namely variance, mean absolute deviation and fourth-order moment are extracted from the segmented signal as image features. Finally, the SVM model is trained by using the known data, and the data from a numerical simulation and a model experiment are used to test the trained SVM model. The results show that the proposed method can not only accurately recognize all voids in the tunnel lining and surrounding rock, but also accurately estimate the cover depths and lateral ranges of the voids.

Keywords Tunnel; Void; Ground penetrating radar (GPR); Support vector machine (SVM); Machine recognition