

探地雷达多目标识别方法的研究

胡进峰 周正欧 孔令讲
(电子科技大学电子工程学院 成都 610054)

摘要 与现有的机器学习算法相比,在有限样本的情况下,支撑矢量机具有更强的分类推广能力。该文在提出利用非线性映射进行探地雷达目标识别的基础上,将多目标识别支撑矢量机与探地雷达目标识别相结合,得到了基于一对一(One against one)支撑矢量机的探地雷达多目标识别方法。所提方法包括基于一对一的探地雷达多目标识别方法、交叉验证的参数选取方法、多通道识别方法;并且和传统的神经网络识别方法进行对比分析。所提识别方法可以与各种目标特征选取方法相结合。对实测数据的对比处理表明所提方法优于传统探地雷达目标识别方法,所得结论对探地雷达目标识别的研究有指导意义。

关键词 探地雷达, 多目标识别, 支撑矢量机, 非线性映射, 神经网络

中图分类号: TN959.17 **文献标识码:** A **文章编号:** 1009-5896(2006)01-0026-05

Research on GPR Multi-object Recognition

Hu Jin-feng Zhou Zheng-ou Kong Ling-jiang

(College of Electronic Engineering, University of Electronic Science and Technology of China, Chengdu 610054, China)

Abstract With limited samples, SVM has stronger ability of generalization in comparison with machine learning algorithm. In this paper, the SVM is combined with the Ground Penetrating Radar(GPR) multi-object recognition, and a GPR multi-object recognition method is proposed based on the one against one SVM. The proposed method includes the GPR multi-object recognition method based on one against one SVM, the parameter selection method based on the cross-validation and the multichannel recognition method. The contrast analysis between the proposed method and the conventional neural network method is given. The proposed method can be combined with object-feature extraction methods. It is shown that the method is effective in the experimental analysis. The conclusion can direct the research on GPR object recognition.

Key words GPR, Multi-object recognition, SVM, Non-linear mapping, Neural network

1 引言

据文献[1],目前大约有1亿1千万颗地雷埋设在世界各国,每周造成超过500人伤亡,发展探地雷达探测地雷成为迫切需要。由于地雷埋藏范围广、数量大、埋藏环境复杂,如果以目前的速度,需要1100年才能清除掉目前已埋设的地雷^[1],因此研究探地雷达目标识别成为迫切需要。

探地雷达目标识别的研究包括两个方面,即目标特征选取和识别方法的研究。目标特征选取已经有较成熟的方法^[1-6];而识别方法的研究较少,目前应用较多的是神经网络识别方法^[4,7]。探地雷达目标识别中,在选取相同特征的情况下,改进识别方法能有效提高目标识别正确率,因此研究新的识别方法较重要。

文献[8]中直接采用时域的单通道信号来研究识别方法,本文也直接采用时域信号进行识别方法的研究,并提出了多通道目标识别方法。所提方法可以和其他特征选取方法结合起来,以提高复杂环境下的探地雷达目标识别的正确率。

基于神经网络优良的并行计算能力和学习推广能力,人们提出了许多基于神经网络的探地雷达目标特征识别方法^[4,7];与神经网络相比,支撑矢量机(SVM)具有更强的小样本推广能力,并且可以解决神经网络的网络结构选取和局部极小点等问题,有关报告主要集中在文字识别、人脸识别等方面^[9-11]。在提出探地雷达目标识别的非线性映射原理的基础上,详细讲述了基于一对一的支撑矢量机的探地雷达多

目标识别方法^[12], 并与交叉验证的参数选取方法、多通道目标识别方法相结合, 最后和传统的基于神经网络的探地雷达目标识别方法进行了对比分析, 说明所提方法优于传统的方法。

2 所提探地雷达目标识别的非线性映射原理

探地雷达的时域信号模型有 A-scan, B-scan, C-scan 共 3 种形式, 数学表示式如下^[1-6]:

A-scan: $f(z) = u(x_i, y_l, z_k); k = 1:N, i, l$ 为常数。

B-scan: $f(z) = u(x_i, y_l, z_k); k = 1:N$, 其中 $i = 1:P$ 且 l 为常数或 $l = 1:M$ 且 i 为常数。

C-scan: $f(z) = u(x_i, y_l, z_k); i = 1:P, l = 1:M, k = 1:N$ 。

探地雷达目标识别原理可以表示为图 1。其中 $x_i(k)$ 是探地雷达目标信号特征, 它通常是第 i 个 A-scan 的第 k 个数据点, 或者是从第 i 个 A-scan 中提取的第 k 个特征值^[1,2]。 b_i 表示探地雷达目标特征经过分类器分类后的所属类别。图中的探地雷达目标识别算法可以看作一种映射。

由于各种不可避免的杂波等影响, 各目标信号特征通常是线性不可分的, 因而探地雷达目标识别实际上就转化为非线性映射问题。由 Kolmogrov 定理可以证明, 通常的神经网络(如 BP 算法、径向基函数)可以实现任意输入/输出的非线性映射, 从而解决探地雷达目标信号特征线性不可分问题。

从图中可以看出, 支撑矢量机通过基于核函数的非线性映射也可以解决上述的非线性分类问题, 同时, 基于结构风险最小的支撑矢量机比基于经验风险最小的神经网络具有更强的推广能力^[9]。




图 1 探地雷达目标识别结构图

图 2 线性可分的情况

3 支撑矢量机原理

支撑矢量机是一种基于结构风险最小化原理的统计学习方法, 只能用于两分类的情况^[13]。对于目标特征点线性可分的情况, 如图 2, 实心点和空心点代表两类样本, H 为支撑矢量机需要寻找的最优分类线, H_1 、 H_2 分别为过各类中离分类线最近的样本且平行于分类线的直线, 它们之间的距离叫做分类间隔。最优分类线就是要求分类线不但能将两

类正确分开, 而且使分类间隔最大。分类线方程为: $\mathbf{x} \cdot \mathbf{w} + b = 0$ 。对它归一化, 使得对线性可分的样本集 $(\mathbf{x}_i, y_i)$, (其中 $i = 1, \dots, n$, $\mathbf{x} \in R^d$, $y \in \{+1, -1\}$), 满足:

$$y_i[(\mathbf{w} \cdot \mathbf{x}_i) + b] - 1 \geq 0, \quad i = 1, \dots, n \quad (1)$$

此时分类间隔等于 $2/\|\mathbf{w}\|$, 使间隔最大等价于使 $\|\mathbf{w}\|^2$ 最小。满足条件式(1)且使 $\|\mathbf{w}\|^2/2$ 最小的分类面就叫做最优超平面, H_1 、 H_2 上的训练样本点称作支持矢量。

对线性不可分的情况, 可以通过非线性变换映射到高维空间, 在高维空间求最优超平面。例如图 3 中特征点线性不可分, 可以通过非线性变换投影到图 2 中的高维空间, 使得特征点在高维空间线性可分, 于是, 图 2 中的分类线就对应原空间(图 3)中的最优超平面。满足 Mercer 条件的核函数可实现这种变换。




图 3 线性不可分的情况

4 所提方法

神经网络是基于经验风险最小原理的学习方法, 因而推广能力较差, 而且通常需要大量的训练数据, 不便于探地雷达的实际应用。而支撑矢量机属于小样本学习算法, 需要的训练数据少, 而且它是基于结构风险最小原理的学习方法, 推广能力强; 支撑矢量机通过基于核函数的非线性映射把低维的探地雷达数据样本空间映射到高维特征空间, 有利于提高探地雷达目标识别率; 支撑矢量机最终将转化成为一个二次寻优问题, 从理论上说, 得到的将是全局最优点, 解决了基于神经网络的传统的探地雷达目标识别方法中无法避免的局部极值问题^[12]。结合多通道目标识别方法将进一步提高识别率。

实际应用中, 当在一定区域内探测时, 一般情况下能探测到的目标的种类是有限的, 并可通过一定手段先了解目标的种类, 同时该区域的介质也是大致相同。这样, 可用同一部雷达采集这些种类目标的数据, 用这些数据训练好支撑矢量机。在实际探测时即可用训练好的支撑矢量机对采集到的探地雷达数据进行分类识别, 因此所提方法具有较强的实用性。

4.1 探地雷达数据的预处理及目标信号的提取

在原始的 B-scan 中采用去均值法抑制地杂波以及直流。用维纳滤波去除宽带杂波和周期杂波^[2]。

在预处理后,需要提取含有目标信息的 A-scan 进行识别方法的研究。文献[3]中用基于概率模型的方法提取目标信号,文献[4, 5]直接用人工提取目标信号来进行分类识别的研究。本文采用文献[2]所述的 Wigner-Ville 分布方法提取目标信号。参照文献[8],这里直接对提取的探地雷达目标信号进行目标识别方法的研究。

4.2 建立探地雷达数据样本空间

设探地雷达信号中共有 k 类目标信号,在经过预处理的探地雷达数据中提取各类待识别的目标的 A-scan 数据共 n 个。设探地雷达中每个 A-scan 中的采样点数是 d ,把提取的含有目标信号的 A-scan 数据组合成一个矩阵 $\mathbf{X}$,每个 A-scan 扫是 $\mathbf{X}$ 的一列,则: $\mathbf{X}=[x_1, x_2, \dots, x_n]$, 其中 x_i ($i=1, \dots, n$) 表示第 i 个 A-scan 扫数据。给每个 A-scan 扫数据贴上标签:

$y_i = m, (i=1, \dots, n; m=1, \dots, c)$, 其中 $y_i = m$ 表示第 i 个 A-scan 扫包含第 m 类目标的信号。所有的标签组成一个矩阵:

$\mathbf{Y}=[y_1, \dots, y_n]$ 。 $\mathbf{X}$ 中 n_i 个属于第 m 类目标的 A-scan 数据组成矩阵 $\mathbf{X}_m$: $\mathbf{X}_m=[x_1^m, \dots, x_{n_i}^m]$

4.3 探地雷达多目标支撑矢量机分类器的训练与分类

支撑矢量机只能用于两分类的情况^[9-13],对于基于支撑矢量机的多目标分类的情况,主要有 3 种方法,即一对一(one against one)和一对多(one against all)以及决策导向循环图(DDAG)方法^[11]。

将一对一方法^[11]与探地雷达目标识别结合起来,得到下述方法:对于 k 类探地雷达目标特征点,建立 $k(k-1)/2$ 个 SVM 分类器,每个分类器用不同的两类数据中的 A-scan 数据样本训练:

$$\left. \begin{aligned} & \min_{w^{ij}, b^{ij}, \xi^{ij}} 1/2(w^{ij})^T w^{ij} + C \sum_t \xi_t^{ij} (w^{ij})^T \\ & \text{s.t. } (w^{ij})^T \phi(x_t) + b^{ij} \geq 1 - \xi_t^{ij}, \text{ if } y_t = i, \\ & (w^{ij})^T \phi(x_t) + b^{ij} \leq -1 + \xi_t^{ij}, \text{ if } y_t = j, \xi_t^{ij} \geq 0 \end{aligned} \right\} \quad (2)$$

其中 C 是惩罚因子并取常数。经过训练后产生 $k(k-1)/2$ 个判决函数。在分类阶段,采用投票策略进行判别分类:如果判别函数 $\text{sign}((w^{ij})^T \phi(x) + b^{ij})$ 判别 x 属于第 i 类,则第 i 类的票数加 1,然后预测 x 是属于得票最多的一类。如果两类的得票数相同,则判断为序号最小的一类。

为了避免探地雷达数据中的大数值所代表的特征淹没

小数值代表的特征,同时为了避免在核运算中大的数值可能导致的数值运算困难,对探地雷达数据进行比例缩放,使其处在 $[-1, 1]$ 的范围内。对于待辨识的数据也采用同样的比例缩放^[12]。

目前在支撑矢量机中常用的核函数有 4 种:线性核函数、径向基核函数、多项式核函数、sigmoid 神经元核函数。考虑到线性核函数可以看作径向基核函数的特例,此外 sigmoid 核函数在性能上与径向基核函数相似。而多项式核函数在搜索模型参数时要复杂一些,这里选择径向基核函数^[12]:

$$K(x, y) = e^{-\gamma \|x-y\|^2} \quad (3)$$

式(2)中的参数 C 和式(3)中的参数 γ 通常凭经验选取。其中参数 C 选取太小将导致较大的训练误差,选取太大则可能导致过适配。考虑到探地雷达目标识别属于小样本训练问题,所使用的支撑矢量机规模小,因此采用网格搜索法选取参数 C, γ :

分别设置 C, γ 的搜索范围,并分别设置它们的搜索步长。然后将训练数据分成 v 个子集,对于某一确定的 C, γ 值,依次将这 v 个子集中的一个子集用作测试子集,剩下的 $v-1$ 个子集作为训练集训练上述分类器。用训练好的分类器对对应的测试子集中的 A-scan 分类。正确分类的 A-scan 总个数与参与测试的总个数的比值定义为交叉验证正确率。对于按步长变化的 C, γ ,分别计算它们的交叉验证正确率,选择交叉验证正确率最大的 C, γ 作为分类器的参数。

上述交叉检验可以避免过训练的问题,即保证测试误差最小(训练误差可能不是最小的),以保证分类器具有最佳的推广能力,同时由于探地雷达目标识别属小样本训练,因此交叉验证不会明显增大计算量。

4.4 多通道识别方法

探地雷达在实际探测中,都是在一定区域内进行探测,因而对于一个目标来说,它不会只反映在一个 A-scan 数据(单通道数据)中,而是反映在一系列相邻的多通道数据中,因此采用多通道识别方法将能提高探地雷达目标识别的正确率。

考虑到在探地雷达探测中,目标通常呈现双曲线形状,且双曲线的长度通常是目标直径的 3 倍左右^[14],因此,对于直径为 D 的目标,本文以 $3 \times D$ 范围内的多通道探测数据作为分类单位标准,当分类单位内的多个单通道数据都被分类为第 m 类目标数据时,则判定该分类单位内的目标为第 m 类目标,否则判断为不是第 m 类目标,本文中当一个分类单位内 80%以上的单通道数据被判为第 m 类目标时,则判定该

分类单位内的目标为第 m 类目标。设 $3 \times D$ 范围内有 n 个单通道数据, 则所提多通道探测方法为:

$$Y = \begin{cases} = m(\text{判断分类单位内的目标数据为第 } m \text{ 类目标数据}) \\ \quad \text{当 } (X_i, \dots, X_{i+n}) \text{ 中有 } 80\% \text{ 以上的单通道数据} \\ \quad \text{属于 } m \text{ 类目标时;} \\ \neq m(\text{判断分类单位内的目标数据不是第 } m \text{ 类目标数据}) \\ \quad \text{当 } (X_i, \dots, X_{i+n}) \text{ 中属于第 } m \text{ 类目标的单通道} \\ \quad \text{数据低于 } 80\% \text{ 时} \end{cases} \quad (4)$$

这样做的优点在于, 与单通道数据作为分类标准相比, 多通道探测方法能提高识别的正确率, 同时兼顾到了某些场合的漏判的代价很大(例如, 如果将地雷判断为非地雷目标则代价很大)。

5 实测数据处理的对比分析

所用的实验验证数据是由比利时皇家军事学院超宽带探地雷达实验室采集^[15]。探地雷达天线离地面 20cm, 分别沿横向和纵向运动完成 C-scan。每个 A-scan 采样 500 个数据点; A-scan 之间的步距、B-scan 之间的步距都是 1cm; 目标分别是 PRB 地雷、VS-50 地雷、石头, 埋在干沙和粘土下面 2cm, 5cm, 9cm 深度处。

用 4.1 节中所述方法对 PRB 地雷、VS-50 地雷、石头分别提取 485 组、1279 组和 577 组 A-scan 数据^[2], 在提取的目标信号中分别随机选取 25 组、49 组、27 组 A-scan 数据做训练数据, 其余的做测试数据。用 4.2 节所述方法建立探地雷达数据样本空间, 其中, $k = 3$, $n = 485 + 1279 + 577 = 2341$, $d = 500$ 。

在交叉验证阶段, 训练数据集一般分成 5 个左右的子集比较合适。这里考虑到训练数据较少, 所以将训练数据集按类随机分成 4 个大小近似相等的子集。交叉验证时, 对这 4 个子集采用网格搜索方法逐点搜索参数对 (C, γ) 。图 4 中, $C = 2^0, 2^1, 2^2, \dots, 2^{30}$, $\gamma = 2^{-6}, 2^{-7}, 2^{-8}, 2^{-9}, 2^{-10}$ ^[12]。对于每一个参数对 (C, γ) , 依次将这 4 个子集中的一个子集, 用作训练集训练分类器, 用另外的 3 个子集作测试集, 计算对测试集总的分类正确率, 将分类正确率相同的 (C, γ) 所对应的点用线连接。选取分类正确率最高且惩罚系数 C 最小的参数对 (C, γ) ^[12]: $C = 2^{16} = 65536.0$, $\gamma = 2^{-7} = 0.0078125$, 此时的

交叉验证正确率为 95.0495%。选好参数后, 再用全部的训练数据训练分类器, 用训练好的分类器分别对训练数据和测试数据分类, 分类结果见表 1。




图4 交叉验证结果

为了对比, 对上述数据采用传统的探地雷达神经网络目标识别方法进行目标识别^[12-4]。由于径向基神经网络对输入输出产生局部响应, 具有比 BP 网络更快的收敛速度和更强的推广能力, 而且由于本文支撑矢量机用的也是径向基函数, 因此这里用径向基神经网络。神经网络训练误差不同, 推广能力也不同。本文中神经网络具有最佳推广能力时训练误差为 0.01, 此时神经网络误差如图 5。横坐标表示迭代次数, 纵坐标表示训练误差。图中的直线表示神经网络训练的目标误差, 曲线表示训练的实际误差。经过 95 次迭代后的实际训练误差为 9.1×10^{-3} 。用训练好的神经网络对训练数据和测试数据的分类结果如表 1。

表 1 中, 两种方法对训练数据的分类正确率都是 100%。这里, 所提方法对训练数据的分类正确率不同于参数选取阶段的交叉验证正确率。所提方法对测试数据的分类正确率明显高于神经网络方法, 原因是, 神经网络通常易于陷入局部极值; 神经网络目标识别方法是基于经验风险最小的, 而所提方法是基于结构风险最小, 因此所提方法比神经网络具有更强的推广能力。表 1 中的结果表明, 采用多通道目标识别方法后, 目标识别正确率有了较明显的提高。




图5 神经网络训练误差收敛图

表 1 分类识别结果的对比

所用目标识别方法	对训练数据分类识别	对测试数据分类识别	对测试数据结合多通道探测方法
	正确识别数/总数	正确识别数/总数	正确率
本文所提方法	100%(101/101)	97.99%(2195/2240)	100%
神经网络方法	100%(101/101)	82.86%(1856/2240)	91.2%

6 结束语

提出了利用非线性映射解决探地雷达目标信号特征线性不可分思想, 讲述了基于一对一的支撑矢量机的探地雷达多目标识别方法、交叉验证选取参数的方法、多通道目标识别方法; 并传统的探地雷达神经网络目标识别方法进行对比分析, 对实测数据的分析结果表明所提方法优于传统的探地雷达目标识别方法。

在某些复杂环境下, 直接在时域上识别时正确率较低, 此时可以先提取探地雷达目标信号最具有区分力的特征^[1-6], 然后运用所述方法在这些信号特征上识别。例如, 可以先提取探地雷达目标的模糊函数特征^[1]、小波系数特征^[2]、Welch 功率谱密度特征^[3]等, 然后应用所述方法对这些探地雷达目标特征进行识别, 因此, 所提方法可以与已有的特征选取方法相结合, 有一定的实用意义。

参 考 文 献

- [1] Sun Y, Li J. Time-frequency analysis for plastic landmine detection via forward-look ground penetrating[J]. *IEE Proc. Radar Sonar Navig.* 2003, 150(4): 253 – 261.
- [2] 王群, 倪宏伟, 徐毅刚. 基于小波能量特征的探雷方法研究[J]. 数据采集与处理, 2003, 18(2): 156 – 160.
- [3] 王群, 倪宏伟, 等. 利用复合特征进行模式识别的探雷研究[J]. 应用科学学报. 2003, 21(1): 53 – 58.
- [4] 王群, 何云龙, 等. 基于神经网络的探地雷达探雷研究[J]. 电波科学学报, 2001, 16(3): 398 – 403.
- [5] Savelyev T G, Van Kempen L, Sahli H. GPR anti-personnel mine detection: improved deconvolution and time-frequency feature extraction. SPIE. 2003, 5046: 232 – 241.
- [6] Chang S S, Ruane M F. Feature extraction of ground penetrating radar for mine detection. SPIE 2003, 5089: 1201 – 1209.
- [7] Gamba P, Lossani S. Neural detection of pipe signatures in ground penetrating radar images[J]. *IEEE Trans. on Geoscience and Remote Sensing*, 2000, 38(2): 790 – 797.
- [8] Yu Ssu-Hsin, Gandhe A, Witten R. Real-time adaptable subspace method for automatic mine detection. SPIE. 2002, 4742: 986 – 995.
- [9] 焦李成, 等. 一种基于支撑矢量机的多用户检测算法[J]. 电子学报, 2002, 30(10): 1549 – 1551.
- [10] 裴继红, 等. 支撑矢量预选取的双色Voronoi图方法[J]. 电子与信息学报, 2003, 25(11): 1494 – 1498.
- [11] Hsu Chih-Wei, Lin Chih-Jen. A Comparison of Methods for Multiclass Support Vector Machines[J]. *IEEE Trans. on Neural Networks*. 2002, 13(2): 415 – 425.
- [12] Chang Chih-Chung, Lin Chih-Jen. LIBSVM : a library for support vector machines, 2001. <http://www.csie.ntu.edu.tw/~cjlin/libsvm>.
- [13] Munsh V, Collins L M. Physics model-based signal processing of ground penetrating radar for subsurface object detection and discrimination. Undergraduate report. Munshi V. and Leslie M. C. 2003.
- [14] Gunawardena A, Longstaff D. A matched filter based synthetic aperture radar(SAR) algorithm for stepped frequency ground penetrating radar[J]. *IEEE International Radar Conference*, 1995: 239 – 243.
- [15] 人道主义反雷联合研究中心网站(<http://apl-database.jrc.it>)

胡进峰: 男, 1976 年生, 博士生, 目前正从事探地雷达信号处理方面的研究。

周正欧: 男, 1940 年生, 教授, 博士生导师, 目前正从事探地雷达、数据传输等方面的研究。