

基于二层 SVM 多分类器的桩基缺陷诊断

康维新, 彭喜元

(哈尔滨工业大学自动化测试与控制研究所, 黑龙江哈尔滨 150080)

摘 要: 为了研究桩基缺陷的快速和准确的分类方法, 依据支持向量机(SVM)理论, 采用多层分类的方法, 改进了一对一 SVM 多分类器结构, 构建了二层一对一 SVM 多分类器模型, 提出了二层多分类计算方法. 与 BP 神经网络相比, 二层 SVM 分类器的学习训练快捷, 分类处理的实时性能好, 对小样本测试环境的适应能力强, 并且具有较好的分类准确率. 该方法适合于分析训练样本数量少、分类精度要求高和分类输入输出变量较多的桩基缺陷诊断等多分类问题, 对桩基多处缺陷识别的研究也具有重要支持.

关键词: 桩基; 支持向量机; 多分类; 缺陷诊断; 神经网络

中图分类号: TU473 **文献标识码:** A **文章编号:** 0372-2112 (2008) 12A-066-05

The Defects Diagnose of Pile Foundation Based on Two-layer Multiple-Classifier of SVM

KANG Wei-xin, PENG Xi-yuan

(Automatic Test and Control Institute, Harbin Institute of Technology, Harbin, Heilongjiang 150080, China)

Abstract: For studying the rapid and accurate classification method of pile foundation defects, a multi-layer classification method is adopted to improve one-to-one support vector machine (SVM) multiple classifiers structure, build one-to-one two-layer classification model and propose two-layer multiple classification method based on SVM theory. Compared with the BP neural network, the learning and training of two-layer SVM classification is faster and the real-time of the classification processing is better. In addition, it has stronger adaptability in test environment based on small sample and better classification accuracy. The method is fit for analyzing the multi-category classification problem of defects diagnose of pile foundation such as smaller training samples, higher precise and more input and output classification variables, and provides important support to the recognition of pile foundation which had several defects.

Key words: pile foundations; support vector machine (SVM); multi-classification; defects diagnose; neural network

1 引言

桩基是承载桥梁和楼房等土木建筑的混凝土构件, 为保证工程质量, 每个桩基在建成后需要进行缺陷检测, 诊断是否存在某种缺陷以及缺陷的程度和位置, 确定桩基质量类别. 工程上常用的桩基缺陷检测方法主要是低应变应力波反射法, 即通过安装在桩顶的加速度传感器检测激振力波反射波信号, 根据反射波信号诊断桩基缺陷.

用反射波信号来诊断桩基缺陷主要有两种方式, 一是有经验的工程师对时域信号波形进行观察分析判断, 二是通过模式识别的方式进行自动分析. 前者是目前桩基诊断的主要方法, 后者尚处于研究阶段, 主要研究方向是应用小波理论和神经网络进行桩基缺陷模式识别, 其关键问题是解决缺陷识别的准确性.

在神经网络模式识别中, 由于训练样本数量的限制, 神经网络分析可以做到经验风险最小化, 但与实际风险仍有较大差异, 泛化性差, 其诊断的准确性一直不能达到工程要求. 从理论上分析, 小样本问题是困扰桩基分类应用研究的关键. 为了改善桩基缺陷识别的准确性, 本文研究在小波分析的基础上, 应用支持向量机多分类器进行桩基缺陷诊断, 来减小小样本训练带来的实际风险, 获得更好的诊断效果.

2 桩基缺陷诊断的 SVM 方法

桩基缺陷主要是扩径、缩径、断裂、夹泥、离析和沉渣过厚等形式, 如图 1 所示. 其中, 扩径是指桩身某处直径大于设计直径, 容易使桩基失衡, 或容易产生过多的沉渣; 缩径是指桩身某处直径小于设计直径, 该处的承载能力差, 使桩基的整体承载能力降低; 断裂是指桩身

某处形成断层,使桩基失衡,承载能力降低;夹泥是指桩身某处形成泥浆泡,使该处强度极低,桩基承载能力变小;离析是指水泥和骨料结合酥松,承载力差;沉渣过厚是指桩身底部郁积过厚的沉渣,有效桩长缩短,承载力降低^[1].




图1 完整桩和缺陷桩示意图

与其他领域缺陷不同的是,桩基缺陷有两个特点,一是缺陷表现为几大类,即完整桩、反射类和吸收类;二是缺陷信号与地理环境有关,表现为一定的地域特点,因此训练样本比较少.基于上述特点,桩基缺陷可以采用适合于小样本分类的 SVM 分类器;分类过程可以考虑通过粗分类和细分类两步完成,以减少分类器得数量和计算量.

缺陷的自动诊断需要进行应力波反射信号采集、小波分解、缺陷特征提取和缺陷分类等四步完成.其中,信号采集和小波分解方法与文献[2~4]相同,这里不再赘述,本文主要阐述桩基缺陷多层多分类的 SVM 模型和算法.

2.1 支持向量机分类的基本原理

支持向量机是基于统计学习理论的 VC 维理论和结构风险最小化原则的学习机器,也是继神经网络理论之后新型学习机器^[5~7].统计学习理论是由 V. Vapnic 等人在 20 世纪 60-70 年代提出的,针对小样本统计学习问题的一个理论框架,它追求的是在现有信息情况下的最优解.由于实际的训练样本有限,与神经网络等其它追求样本趋于无穷的分类器相比,在小样本条件下,支持向量机能明显缩小经验风险和实际风险存在的差异,因此,支持向量机在小样本模式分类方面具有突出的优势,并得到广泛应用^[8].

支持向量机的研究最初是针对模式识别中的两类线性可分问题,如图 2 所示,图中 \circ 和 \bullet 各代表一类.分割线(平面)1 和分割线(平面)2 都能正确地将两类样本




图2 支持向量机原理示意图

分开,即都能保证使经验风险最小(为 0),这样的线(平面)有无限多个,但分割线(平面)1 离两类样本的距离最大,称之为最优分类线(平面).最优分类线(平面)的 VC 置信度最小^[5].

设线性可分样本集为 $(x_i, y_i), i = 1, 2, \dots, n, x \in R^d, y \in \{-1, 1\}$ 为类别标号. D 维空间中线性判别函数的一般形式为 $g(x) = W \cdot x + b$, 分类面方程为

$$W \cdot x + b = 0 \quad (1)$$

将判别函数归一化,使两类所有样本都满足 $|g(x)| \geq 1$. 这样,分类间隔就等于 $2 / \|W\|$, 因此,求间隔最大变为求 $\|W\|$ 最小.

满足 $|g(x)| = 1$ 的样本点,离分类线(平面)距离最小,他们决定了最优分类线(平面),称之为支持向量(Support Vectors),图 2 中带斜线的样本即为 SV.

可见,求最优分类面的问题已转化为优化问题:

$$\min \phi(W) = \frac{1}{2} \|W\|^2 = \frac{1}{2} (W \cdot W) \quad (2)$$

$$y_i [(W \cdot x_i) + b] - 1 = 0, \quad i = 1, 2, \dots, n$$

本优化问题可以转化为

$$\min Q(a) = \frac{1}{2} \sum_{i,j=1}^n a_i a_j y_i y_j (x_i \cdot x_j) - \sum_{i=1}^n a_i \quad (3)$$

$$a_i \geq 0, \quad i = 1, 2, \dots, n \quad \sum_{i=1}^n y_i a_i = 0$$

并由此可得到最优分类函数为

$$f(x) = \text{sgn} \left\{ \sum_{i=1}^n a_i^* y_i (x_i \cdot x) + b^* \right\} \quad (4)$$

对于非支持向量满足 $a_i = 0$, 因此式(4)只需对支持向量进行. b^* 可任选一个支持向量,由式(2)的约束条件取等号求出.

SVM 基本分类器是二分类,它能通过一对一或一对余等基本形式构成多分类器,与神经网络等其它多分类器相比,SVM 多分类器的优点是对小样本分类准确性高,缺点是多分类器中需要的二分类器数量多、结构复杂、计算量大.针对 SVM 多分类器和桩基缺陷两方面的特点,本文提出并构建了二层一对一 SVM 多分类器模型,二层一对一 SVM 多分类器不仅保留了对小样本分类准确性高的优点,而且其模型和计算比基本的一对一 SVM 多分类器有明显简化.

2.2 二层一对一型 SVM 多分类器模型

SVM 多分类器结构形式很多,其中比较基本的形式有一对余、一对一及其相应的改进型.考虑到一对一分类器的优缺点和桩基缺陷的特点,本文提出一对一型 SVM 多分类器改进型结构,即二层一对一型 SVM 多分类器结构.其中,第一层一对一型分类器的任务是对桩基缺陷进行粗分类,第二层一对一型分类器的任务是对第一层分类的结果再进行细分类.基本的一对一

型分类器结构模型和改进的二层一对一型分类器结构模型如图 3 和图 4 所示。




图3 基本的一对一型SVM多分类器模型




图4 二层一对一型SVM多分类器模型

与基本的一对一型分类器比较,同样实现 k 分类,一对一型 SVM 多分类器需要 $k(k-1)/2$ 个分类器,与分类数量成平方关系.若对桩基 7 种缺陷进行分类,需要二分类器总数为 21 个.若使用二层分类器对同样 7 种桩基缺陷分类,需要分类器数量为 9 个.显然,多层一对一型 SVM 多分类器,使的二分类器的数量明显减少,计算时间也会明显缩短.

从理论上分析,桩基 7 种缺陷可分三个大类,即完整桩、反射类和吸收类,由于三个大类检测的信号差异较大,因此适合于进行粗分类,粗分类对整体分类精度影响较小.当使用基本的一对一型分类器时,由于不同大类缺陷的分类结果之间互相支持很小,有一部分二分类器作用小,或产生冗余.二层一对一型 SVM 多分类器结构优势在于消除了一对一型 SVM 多分类器中冗余的二分类器,有效减少了分类器数量,在第一层分类投票被淘汰的大类结果不再进行第二层的细分类,简化了计算过程.

2.3 一对一 SVM 多分类算法

二层一对一型 SVM 多分类器是两层的一对一型

SVM 多分类器的组合,因此每层分类器都采用下列相同的算法.

首先确定训练集

$$T = \{ (x_1, y_1), (x_2, y_2), \dots, (x_n, y_n) \}$$

其中, $x_i \in R^m, y_i \in \{1, 2, \dots, K\}, i = 1, 2, \dots, n$.

对于 K 分类问题,取所有 $y = i$ 和 $y = j$ 的训练样本构建 $M = C_k^2 = \frac{K(K-1)}{2}$ 个训练子集 T_{ij} .

对 $i = 1, 2, \dots, K, j = i + 1, \dots, K$,则由第 i 类和第 j 类数据训练数据便可训练二值分类器,分别使用 SVM 二值分类算法对这 M 个训练集进行学习,便可以构造 M 个分类器.本文的基本一对一型 SVM 多分类器需要构造出 21 个分类器,二层一对一型 SVM 多分类器需要构造出 9 个分类器.然后进行下式计算.

$$\min_{\tilde{w}, b} \frac{1}{2} (\tilde{w})^T \tilde{w} + C \sum_i \tilde{w}_i (\tilde{w})^T \quad (5)$$

$$\text{s.t.} \begin{cases} (\tilde{w})^T (x_i) + b^{\tilde{w}} \geq 1 - \tilde{w}_i, \text{ if } y_i = i \\ (\tilde{w})^T (x_i) + b^{\tilde{w}} \leq -1 + \tilde{w}_i, \text{ if } y_i = j \\ \tilde{w}_i \geq 0 \end{cases}$$

得到的决策函数集为:

$$y_{ij}(x) = \text{sgn} \left\{ \tilde{w}_i (x) + b^{\tilde{w}} \right\} \quad (6)$$

其中: $i = 1, 2, \dots, K, j = i + 1, \dots, K$

测试时判别采用投票决策法,用所有的 M 个分类器对测试样本进行分类,在第 i 类和第 j 类之间分类时,记 v_y 为投票函数,若该分类器判断 x 属于 i 类,则 i 类的票数加 1,否则 j 类的票数加 1.最后将测试样本 x 归为得票数最多的类别,并采用下列函数进行判别.

$$y_{\text{test}} = \arg \max_{y=1, \dots, k} [v_y(x)] \quad (7)$$

3 仿真实验

为了验证二层一对一型 SVM 多分类器算法的有效性和优越性,本文对二层一对一型 SVM 多分类器和 BP 神经网络分类器进行了对比仿真实验分析.

二层一对一型 SVM 多分类器实验模型采用图 4 结构,它由 2 层 3 组共 9 个二分类器构成,训练过程按两层分别进行,先进行第一层的一组粗分类训练,然后进行第二层的两组细分类训练.BP 神经网络采用 6-9-7 结构,输入和输出节点数分别与二层 SVM 多分类器相同,即:输入变量为 6 个特征向量,分别为 3 个功率谱均值 (E_1, E_2, E_3) 和 3 个方差 (S_1^2, S_2^2, S_3^2),输出变量为 7 个,分别为完整桩、扩径、缩径、断裂、夹泥、离析和沉渣.两个分类器仿真数据使用相同的桩基缺陷训练集和测试集.

首先进行二层 SVM 和 BP 神经网络的性能实验和对比.实验的训练集数据 300 个,测试集数据 200 个.测试的参数分别是:训练时耗、测试时耗、训练集准确率 (RMS) 和误差 (Dev)、测试集的准确率 (RMS) 和误差

(Dev). 性能测试的统计结果如表 1 所示.

表 1 算法性能比较

算法	时耗/s		训练集/%		测试集/%	
	训练时间	测试时间	RMS	Dev	RMS	Dev
BP 神经网络	0.2307	0.2716	76.983	1.3104	74.827	1.9035
二层 SVM	0.0562	0.0613	89.312	1.2451	88.112	1.8312

从性能测试的统计结果看,二层 SVM 训练时耗和测试时耗明显比 BP 神经网络小,说明在处理相对复杂的问题和实时性能要求较高的问题时,二层 SVM 具有较强的优势;二层 SVM 训练集和测试集的准确概率都略高于 BP 神经网络,误差相对较小,显示了二层 SVM 具有较好的分类效果.




图 5 训练时间对比曲线

其次,测试两种分类器在不同训练数据样本数量情况下的性能.训练时间测试的训练数据样本数量范围取 50~300,训练时间变化对比测试结果如图 5 所示;测试时间测试的测试数据样本数量范围取 50~200,训练样本数量取 300,测试时间变化对比测试结果如图 6 所示;准确率测试的训练数据样本数量范围取 50~300,测试样本数量取 200,准确率变化对比测试结果如图 7 所示.




图 6 测试时间对比曲线

从上述性能变化曲线的测试结果可以看出:随着训练样本数量的增加,两种分类器的训练时间都有明显增加,但二层 SVM 分类器的训练时间明显低于 BP 神经网络分类器,说明二层 SVM 分类器对不同样本数量测试条件和环境,都具有良好的适应能力,学习过程快捷;在测试时间上,二者的处理时间随着测试样本数量的增加有线性增加,但二层 SVM 分类器的处理时间明

显短于 BP 神经网络分类器,二层 SVM 分类器表现出较好的实时处理能力;在相同条件下,二者分类准确率也都具有随着训练样本数量增加而增加的趋势,但二层 SVM 略高于 BP 神经网络分类器,而且在样本数量少时优势较为突出,表现出 SVM 对小样本分类问题具有较强处理能力.




图 7 准确率对比曲线

4 结论

支持向量机是一种在解决非线性分类的小样本和高维问题方面具有较好优势的模式识别工具,本文通过改进一对一支持向量机多分类器结构,构建了用于桩基缺陷诊断的二层一对一支持向量机多分类器,并将该分类器与 BP 神经网络进行了性能测试实验和比较.测试结果表明:二层 SVM 分类器学习训练快捷,分类处理的实时性能好,对不同样本数量测试环境具有良好的适应能力,具有较强的小样本问题处理能力,分类的准确率也略高于神经网络.

桩基缺陷识别是较典型的小样本分类问题,工程上对缺陷判别的实时性也具有较高的要求,因此,多层支持向量机给由于桩基直径和地域环境的变化使缺陷特征发生变化而导致的训练样本匮乏等桩基缺陷诊断问题提供了新的解决方法,一方面可以缩短在工程现场的学习训练时间和检测时间,尽快适应测试环境,满足工程的实时性要求,另一方面可以改善小样本条件下缺陷识别的准确概率,有效减小分类的实际风险与经验风险的差异,提高分类器的泛化性.

桩基多处缺陷识别是桩基缺陷识别研究的另一个重要课题,多缺陷识别需要处理大量的向量矩阵数据,若将多层支持向量机用于该课题研究,其简单的模型结构和快捷的分类性能,将对桩基多处缺陷的分类研究提供重要支持.

参考文献:

- [1] 张宏. 灌注桩检测与处理. [M]. 北京:人民交通出版社, 2001. 1 - 12.
- [2] 康维新. 基于小波分析的桩基础完整性的检测[J]. 电子测量与仪器学报, 2002. 16(2): 23 - 25.

- Kang Wei-xin. The test of pile foundation integrity based on wavelet analysis[J]. Journal of Electronic Measurement and Instrument, 2002, 16(2) :23 - 25. (in Chinese)
- [3] kangweixin, pengxiyuan. Wavelet characteristic and experimental study of pile foundation fracture[J]. 7th International Conference on Electronic Measurement & Instruments (ICEMI). 2005, 6 :302 - 305.
- [4] 康维新, 彭喜元. 桩基小波特征的研究[J]. 电子测量与仪器学报, 2005, 19(5) :25 - 27.
Kang Wei-xin, Peng Xi-yuan. Pile foundation wavelet characteristic[J]. Journal of Electronic Measurement and Instrument, 2005. 19(5) :25 - 27. (in Chinese)
- [5] V N Vapnik. An overview of statistical learning theory[J]. IEEE Trans on Neural Networks, 1999, 10(5) :988 - 999.
- [6] Cortes C, Vapnik V. Support vector networks [J]. Machine Learning, 1995, 20 :273 - 297.
- [7] Scholkopf B, Sung K, Burges C, Girosi F, Niyogi P, Poggio T, Vapnik V. Comparing Support Vector Machines with Gaussian Kernels to Radial Basis Function Classifiers [R]. A. I. Memo-01559, MIT, 1996.
- [8] 张学工. 关于统计学习理论与支持向量机[J]. 自动化学报, 2000, (26) 1 :32 - 42.

Zhang Xue-gong. Introduction to statistical learning theory and support vector machines [J]. Acta Automatica Sinica, 2000, 26 (1) :32 - 42. (in Chinese)

作者简介:



康维新 男, 1963 年 4 月出生于黑龙江富锦, 哈尔滨工业大学自动化测试与控制系博士研究生, 主要从事自动测试与仿真、故障诊断和预测等研究工作。

E-mail : kangweixin @hrbeu. edu. cn.



彭喜元 男, 教授、博士生导师, 1961 年生于内蒙古四子王旗, 哈尔滨工业大学电气工程及自动化学院副院长, 主要研究方向为自动测试技术和智能故障诊断理论等。

E-mail : pxy @hit. edu. cn

(上接第 80 页)

- [10] Russell, Stuart, Peter Norvig. 人工智能[M]. 北京: 人民邮电出版社, 2004.
- [11] 宋泾舸, 查建中, 陆一平. 智能规划研究综述——一个面向应用的视角[J]. 智能系统学报, 2007, 2(2) :18 - 25.
Song Jian-ge, Cha Jian-zhong, Lu Yi-ping. Survey on AI planning research - an application - oriented perspective[J]. CAAI

Transactions on Intelligent Systems, 2007, 2(2) :18 - 25.

- [12] R M Jensen, M M Veloso, R E Bryant. Guided symbolic universal planning [A]. Proceedings of the 13th International Conference on Automated Planning and Scheduling[C]. Trento, Italy :IEEE, 2003. 123 - 132.