第 48 卷第 10 期　　硅　酸　盐　学　报　　Vol. 48，No. 10
2020 年 10 月　　JOURNAL OF THE CHINESE CERAMIC SOCIETY　　October，2020
http://www.gxyb.cbpt.cnki.net　　**DOI**：10.14062/j.issn.0454-5648.20200178

基于结构响应向量和支持向量机的框支承玻璃幕墙连接松弛状态智能识别

张　强，杨　健，王星尔，徐　涵，孟嫣然

(上海交通大学，海洋工程国家重点实验室，上海 200240；上海交通大学船舶海洋与建筑工程学院，上海 200240；
上海市公共建筑和基础设施数字化运维重点实验室，上海 200240)

摘　要：提出一种基于结构响应向量(SRV)和支持向量机(SVM)方法，对四边框支玻璃幕墙的连接松弛状态进行智能识别。首先，针对该类结构的动力和静力特性，建立四边框支玻璃幕墙有限元模型和在多种松弛状态下玻璃幕墙的 SRV。其次，运用 SRV 对于边界松弛位置和程度进行识别，验证由动态分量和静态分量组成的 SRV 作为松弛指标的有效性和适用性。最后，以各松弛工况下的 4 阶频率和 9 个测点转角位移形成的 SRV 组成松弛识别样本库，运用 3 种不同核函数构成的 SVM 进行训练和识别，并运用粒子群算法对于 SVM 径向基(RBF)核函数的参数进行迭代优化，形成基于 SRV–SVM 的框支玻璃幕墙的连接松弛识别方法。结果表明：采用基于 SRV–SVM 的方法对四边框支玻璃幕墙连接松弛进行定位和定量描述可获得较理想的识别效果。

关键词：框支玻璃幕墙；连接松弛识别；支持向量机；结构响应向量；粒子群算法
中图分类号：TU317　　**文献标志码**：A　　**文章编号**：0454–5648(2020)10–1682–07
网络出版时间：2020–07–27



Smart Detection of Connection Loosening of Frame Supported Glass Curtain Walls Based on Coupled Structural Response Vector and Support Vector Machine Approach

ZHANG Qiang, *YANG Jian*, *WANG Xing'er*, *XU Han*, *MENG Yanran*
(State Key Laboratory of Ocean Engineering, Shanghai Jiao Tong University, Shanghai 200240, China;
School of Naval Architecture, Ocean and Civil Engineering, Shanghai Jiao Tong University, Shanghai 200240, China;
Shanghai Key Laboratory for Digital Maintenance of Buildings and Infrastructure, Shanghai 200240, China)

Abstract: A coupled structural response vector (SRV) and support vector machine (SVM) approach was developed for the connection loosening detection of frame supported glass curtain walls. Firstly, a structural simulation model was established, which considered both static and dynamic characteristics for the connection damage due to the loosening effect of frame supported glass walls. Secondly, the structural response vector was then used for damage pattern identification and quantification, which validated the effectiveness and applicability of SRV as damage indicators. Finally, a damage identification sample database containing different SRVs with the first four frequencies of glass panels and the inclination angles at nine points was established. Three SVMs with different kernels functions were used for the sample training and damaged identification. Particle swarm optimization was also utilized to optimize the parameters of radial basis function kernel. The results show that the effectiveness of coupled SRV-SVM approach for the identification and quantification of connection loosening of frame supported glass curtain walls is satisfactory.

Keywords: frame supported glass walls; connection loosening detection; support vector machine; structural response vector; particle swarm optimization

收稿日期：2020–03–18。　修订日期：2020–04–14。
基金项目：国家重点研发计划项目(2017YFC0806100)；上海市科委“科技创新行动计划”(18DZ1205603)。
第一作者：张　强(1995—)，男，硕士研究生。
通信作者：杨　健(1974—)，男，博士，教授。

Received date: 2020–03–18.　**Revised date:** 2020–04–14.
First author: ZHANG Qiang (1995–), male, Master candidate.
E-mail: zhangqiang0223@sjtu.edu.cn
Correspondent author: YANG Jian (1974–), male, Ph.D., Professor.
E-mail: j.yang.1@sjtu.edu.cn

建筑玻璃幕墙通常由玻璃面板和支承结构所组成，已经成为现代高层建筑外围维护结构的一种主要形式。然而，早期玻璃幕墙由于使用年限或设计、结构胶、铝合金框、预埋件、连接件等材料和施工质量等问题，支承结构可能出现连接松弛甚至脱落的危险，严重影响其公共使用安全。目前仍缺乏有效实用的监测手段对建筑玻璃幕墙的连接松弛状态进行实时评估[1]，多基于有关规范对建筑玻璃幕墙进行简单目测排查，或对少量幕墙进行一些常规的力学或物理性能实验来评估其安全性[2]。

近年来，以人工神经网络为代表的机器学习算法在结构损伤识别领域得到了广泛的应用。但人工神经网络往往会出现网络结构难以确定以及网络训练易陷入局部极小化等问题[3]。与人工神经网络方法相比，支持向量机(SVM)采用结构风险最小化原理，较好地解决了过学习和欠学习的问题，对小样本问题有独特的优势，在结构损伤识别领域也有广泛的应用[4]。而支持向量机用于结构损伤识别的关键问题和难点是损伤指标参数的选取以及 SVM 核函数的取用[5]，两者对 SVM 的性能有决定性的影响，其中，损伤指标参数的选取(即损伤特征向量的构成)是否合理，决定了样本库的损伤工况主要特征能否被较为完整地反映以及其是否具备良好的可区分性。而核函数的取用对于 SVM 的识别效率和精度起着决定性的作用。为了解决这个问题，本工作首先验证了由前 4 阶自振频率和 9 个测点弯曲转角组成的结构响应向量(SRV)作为损伤指标参数对于连接松弛状态识别的有效性和适用性，将其作为 SVM 的输入量，形成基于 SRV–SVM 的框支玻璃幕墙的连接松弛状态识别方法，并对 3 种不同核函数构成的 SVM 识别精度进行评估。

1　基于SRV–SVM的连接松弛状态识别方法原理

1.1　SRV

SRV 的概念由罗旭[6]提出，即以结构在特定状态下的若干个归一化的结构响应量(包含静态响应和动态响应)为元素组成的多维空间向量。根据 SRV 的模和方向角，可以描绘出该损伤工况在相平面内对应的点。随着损伤的演化，特定的损伤模式在相平面内形成一系列的点，称之为相轨迹。将待测样本 SRV 所对应的点与各种损伤模式对应的相轨迹进行对比，通过合适的算法选取最匹配的损伤工况，从而实现结构损伤的定位和定量评估[7]。本工作选用 SVM 作为核心算法，将 SRV 作为输入量，建立框支玻璃幕墙连接松弛状态样本库，进行 SVM 的训练及识别。

1.2　SVM

SVM 是由 Vapnik[8]提出的基于统计学习理论的机器学习方法，其基本原理是通过核函数将原空间不可分的样本映射到一个高维的空间，使其在新空间内线性可分或者近似线性可分。

基于 SVM 的连接松弛状态识别方法的基本思想，是建立起输入特征向量和连接松弛状态之间一一对应的关系，再根据已经建立的关系对未知的样本进行识别[9]。相较于神经网络等常用分类算法，SVM 的目标为求解现有样本信息下的最优解而非样本数趋于无穷大时的最优解，因此更适用于小样本的损伤识别，且具有良好的泛化能力[4]。此外，因其算法复杂度与维数无关，也能很好的避免传统算法“维数灾难”的问题[10]。

2　SVM核函数和粒子群算法(PSO)参数优化原理

核函数早在 20 世纪 60 年代就被引入机器学习领域，已经得到广泛的应用，尤其对于支持向量机等方法是不可或缺的理论工具[4]。简而言之，核函数可以表示成某特征空间中 2 个向量的内积。若 φ 是从低维空间 χ (欧式空间的子集或者离散集合)到高维的 Hilbert 空间 H 的映射，则若存在函数 $K(x_i, x_j)$，对任意 x_i，$x_j \in \chi$，皆存在：

$$K(x_i, x_j)=<\varphi(x_i), \varphi(x_j)> \tag{1}$$

则该函数就被称为核函数。通过核函数的引入，完成样本从原本不可分空间到高维线性或者近似线性可分空间的映射。目前常用的 SVM 核函数主要包括 4 类：线性核函数、多项式核函数、径向基(RBF)核函数和 Sigmoid 核函数。不同的核函数对应了不同的泛化能力及识别精度和效率，而 SVM 核函数的选用以及参数的选择目前大多依据经验，缺乏具体理论的指导，因此存在很多局限性[5]。为了克服这种局限性和提升算法的效率和精度，本工作选用粒子群算法(PSO)对 SVM 核函数的参数进行优化。

粒子群算法是一种具有全局搜索能力的进化算法，运用 PSO 算法优化 SVM，主要是利用 PSO 个体之间的间接通信，对 SVM 核函数参数迭代优

化。本工作以 RBF 核函数为例，对该类核函数中的关键参数 C 和 Gamma 进行优化[11]。为了得到所需的最优解，种群中粒子 i 在时间点 t 的速率和位置为：

$$v_{id}(t+1)=qv_{id}+c_1r_1\left[p_{\text{best},id}(t)-x_{id}(t)\right]+c_2r_2\left[g_{\text{best},id}(t-x_{id}(t))\right] \tag{2}$$

$$v_{id}(t+1)=x_{id}(t)+v_{id}(t+1) \tag{3}$$

其中：q 为权重系数；c_1 和 c_2 为加速度常数；r_1 和 r_2 为 0 到 1 之间的随机数；$p_{\text{best},id}$ 是种群中第 i 个粒子在 d 维中的最优值；$g_{\text{best},id}$ 是整个种群的群体在 d 维中的最优值；x_{id} 和 v_{id} 分别是种群中第 i 个粒子在 d 维中的位移和速率。

本工作选用RBF核函数构成的SVM作为PSO算法的优化对象，设定 SVM 模型中的参数 C 和 Gamma，并初始化粒子群体的学习因子、最大迭代次数和种群规模。需要计算迭代过程中每个例子的适应度值，以获得 SVM 模型中的最佳参数，并找出最佳的适应度。

3 四边框支玻璃幕墙的有限元仿真

3.1 四边框支玻璃幕墙连接松弛理论分析模型

以四边框支玻璃幕墙作为研究对象，为了方便与现有的玻璃幕墙连接松弛条件实验对照，幕墙尺寸取 300 mm×300 mm×4 mm。在对照实验中[12]，为了模拟不同程度的连接松弛对于四边框支玻璃的动/静力特性的影响，设计了四边支承可调节压条松紧的金属框架，通过扭力扳手调节螺栓的松紧程度，可以模拟幕墙的连接松弛，每拧 1/2 圈进行一次自振频率的测量以及中心测点的位移测量。

为了减少有限元模型的计算复杂度和计算耗时，采用壳单元进行建模。根据刘小根等[12−13]的试验研究和理论分析，框支玻璃的约束特性处于四边固支与四边简支之间，结合其边界支承的特点，可以将其看作边缘在 x 和 y 方向上转动受到弹性约束的矩形板，在 z 方向的平动考虑四边简支约束。考虑到框支玻璃工作状态的受力以拉压为主，z 方向的转动(即面内扭转)不予考虑，故将其完全约束[1]，力学简图如图 1 所示。

边界条件可以表述为：

$$x=a,w=0,\frac{\partial w}{\partial x}=-\frac{D}{K_1}\left\{\frac{\partial^2 w}{\partial x^2}+\mu\frac{\partial^2 w}{\partial y^2}\right\} \tag{4}$$

$$x=0,w=0,\frac{\partial w}{\partial x}=-\frac{D}{K_2}\left\{\frac{\partial^2 w}{\partial x^2}+\mu\frac{\partial^2 w}{\partial y^2}\right\} \tag{5}$$

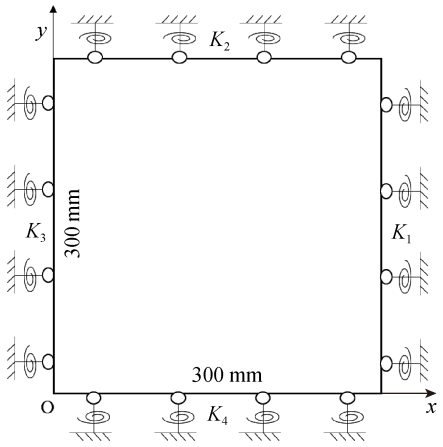


图 1 边缘转动受弹性约束的矩形板

Fig. 1 Rectangular plates with elastic rotational constraints

$$y=b,w=0,\frac{\partial w}{\partial x}=-\frac{D}{K_3}\left\{\frac{\partial^2 w}{\partial y^2}+\mu\frac{\partial^2 w}{\partial x^2}\right\} \tag{6}$$

$$y=0,w=0,\frac{\partial w}{\partial x}=-\frac{D}{K_4}\left\{\frac{\partial^2 w}{\partial y^2}+\mu\frac{\partial^2 w}{\partial x^2}\right\} \tag{7}$$

其中：a 和 b 是玻璃面板的长度和宽度；w 为板的挠度；D 为抗弯刚度；K_i(i=1，2，3，4)表示四边转动约束弹簧的刚度，当 K_i(i=1，2，3，4)取极限值(0 或者∞)即可分别得到四边简支和四边固支的条件，即框支玻璃连接松弛在力学模型上可以简化为转动约束弹簧刚度的退化。不同松紧程度下的 K_i 通过最小余能原理进行求解。将图 1 中的边界条件简化成简支边界且有分布力偶作用 M_i(i=1，2，3，4)，则该结构总余能可表示为：

$$\prod=\frac{1}{2D(1-\mu^2)}\iint[M_x^2+M_y^2-2\mu M_xM_y+2(1+\mu)M_{xy}^2]\mathrm{d}x\mathrm{d}y-\int_0^{s_i}M_i\bar{\theta}\,\mathrm{d}s-\iint\frac{(\bar{m}\omega^2w)^2}{2\bar{m}\omega^2}\mathrm{d}x\mathrm{d}y \tag{8}$$

其中：M_x 和 M_y 分别为玻璃面板在 x 和 y 方向的内力矩；μ 为 Possion 比；s_i 为第 i 条边界；$\bar{m}$ 为单位面积的玻璃幕墙的质量；ω 为固有频率。基于最小余能原理$\partial\prod/\partial M_i=0$ (此处步骤较多，由于篇幅限制不做展开)，可得固有频率 ω 为：

$$\omega=\frac{\pi^2\left(\frac{1}{a^2}+\frac{1}{b^2}\right)\sqrt{\frac{D}{\bar{m}}}}{\sqrt{1-\frac{2}{\pi^2}(e_1+e_2)(1+\mu)}} \tag{9}$$

其中：e_1 和 e_2 为柔性影响系数。因幕墙结构对称因此相等，其中，e_1 的表达式为：

$$e_1=[1-0.101(1+\mu)(\alpha_1+\alpha_3)]/[1-0.025(1+\mu)(\alpha_1+\alpha_3)+0.002(1+\mu)^2\alpha_1\alpha_3] \tag{10}$$

其中：$\alpha_1=D/K_1$；$\alpha_3=D/K_3$。通过式(8)和式(9)，可

以反算出试验中不同连接松弛程度所对应的各边转动刚度 K_i。

3.2　有限元模型

将以 300 mm×300 mm×4 mm 的四边框支玻璃幕墙试件作为建模对象，通过改变四边转动约束弹簧的刚度对框支玻璃不同程度的连接松弛状态进行模拟。这里采用动力特性分析的方法进行模型的验证，通过不同连接松弛状态下的固有频率试验值[12]反算出对应的转动刚度 K_i 的理论值，将其作为有限元模型的输入参数进行建模，最后通过将有限元模型的中心测点位移计算结果与试验值进行对比，材料参数为：弹性模量 E=70 Gpa，密度 ρ=2 500 kg/m^3，Poisson 比 μ= 0.24，玻璃面板厚度 h= 0.004 m，面板长度 a=b= 0.3 m，采用 20 kPa 的均布荷载进行加载。

首先对 2 种理想情况(四边简支和四边固支)的工况进行模拟。网格数目从 10×10 开始进行尝试，发现网格数目超过 20×20 (即 l/a=20 时)之后模型开始收敛，随着网格数的继续增大，该有限元模型固有频率的变化率小于 0.1%。接着将不同连接松弛工况的有限元计算值与试验值进行对比，如表 1 所示。由表 1 可见，有限元模拟的结果和实验值误差处于可接受的范围内。至此，已经验证了该有限元模型能够较好地反映实际情况。

表 1　有限元模型位移数值解与试验值的对比[12]

Table 1　Comparison between numerical and experimental displacement results[12]

Number of loosening turns	Calculated value/mm	Experiment value/mm	Error/%
0.5	0.93	0.87	–4.12
1.0	1.13	1.05	5.33
1.5	1.19	1.13	5.31
2.0	1.23	1.18	4.23

Four loosening conditions were given in the experiment.

3.3　连接松弛样本库的建立

四边框支玻璃幕墙结构的连接松弛包括单边出现松弛和多边出现松弛的情况，一共包含了 15 种连接松弛模式：单边出现松弛有 4 种(C_4^1)模式，两边出现松弛有 6 种(C_4^2)模式，三边出现松弛有 4 种(C_4^3)模式，四边出现松弛有 1 种(C_4^4)模式。各松弛模式都考虑了给定的边界出现不同程度松弛的情况，在本工作中每种松弛模式包含 12 种松弛工况。

在 2.1 节所提到的实验中，通过调节钢框架上螺栓的松紧对各边界连接的松弛程度进行调节，从低到高共有松弛 0.50 圈、松弛 1.00 圈、松弛 1.50 圈、松弛 2.00 圈、松弛 2.50 圈和松弛 3.00 圈共计 6 种程度。在有限元模型验证中，也发现在四边松弛模式(即对照实验所选用的松弛模式)中，松弛程度与频率的递减幅度大致成线性关系。为了保证连接松弛识别样本库中的训练样本和识别样本的数量，取松弛 0.25 圈、0.50 圈、1.00 圈……、3.00 圈共计 12 种松弛程度，分别记为松弛程度 1、2、3、…、12，即生成共 180 个不同连接松弛工况的样本。采用 python 语言随机选取其中的 25%的样本作为测试集，其余样本连同完好情况作为训练样本，则共计 136 个训练样本用于支持向量机的训练。通过有限元软件的仿真可以根据需求尽可能多的得到样本数据，因此测试集只考虑 SVM 分类算法的内推效果，不考虑对于机器学习方法普遍比较难的外推效果。

3.4　结构响应向量的形成

考虑到间隔式松弛(即出现松弛的边界并未完全松弛的情况)对于动态响应(如固有频率)不敏感，而对静态响应(如位移和弯曲转角)更为敏感，因此采用的动静态结构响应向量相较于较动态结构响应向量或是静态响应向量，会有更好的识别效果。由于支持向量机算法的复杂程度和计算量不会随着损伤特征向量维数的增多有明显的变化[14]，因此为了比较准确的描述结构的健康状态，采用前 4 阶自振频率和 9 个测点的弯曲转角位移组成结构响应向量 $\boldsymbol{V}$ 作为样本的输入属性。测点采用对称布置，测点布置如图 2 所示。

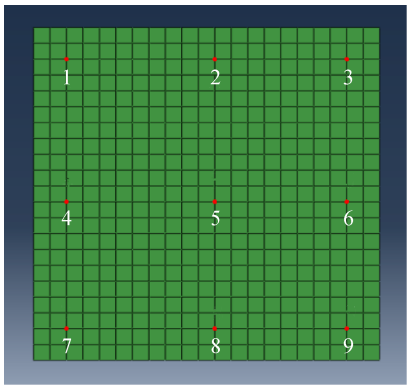


图 2　有限元模型及测点布置

Fig. 2　Finite element model and measured points

结构响应向量可以将其表示为：

$$\boldsymbol{V}^i=\{\psi_1,\cdots,\psi_4,\xi_{11},\cdots,\xi_{19},\xi_{21},\cdots,\xi_{29}\} \tag{11}$$

其中：ψ_m 为归一化后的第 m 阶频率；ξ_{lk} 为归一化

后的第 k 个测点在 l 方向(有 x，y 两个方向)的角位移，其归一化公式为：

$$\psi_m^i=\frac{\alpha_m^i}{a_m^0},\ \xi_{lk}^i=\frac{\beta_{lk}^i}{\beta_{lk}^0} \tag{12}$$

其中：α_m^i为第 i 个松弛工况下第 m 阶的频率值；α_m^0为无松弛状态下第 m 阶的频率值；β_{lk}^i为第 i 个松弛工况下第 k 个测点在 l 方向的角位移值；β_{lk}^0为无松弛状态下第 k 个测点在 l 方向的角位移值。不同工况的结构响应向量如表 2 所示，考虑到 SRV 维数较多(共 22 维)，由于篇幅限制，在此处并未列全。

表 2　各松弛工况下的结构响应向量

Table 2　structural response vector (SRV) under different loosening conditions

Loosening boundaries	Level of loosening	SRV	Output
1	1	0.9918, 0.9801, 0.9916, ⋯, 1.007 9	(1, 1)
1	2	0.9828, 0.9499, 0.9836, ⋯, 1.0142	(1, 2)
⋮	⋮	⋮	⋮
1&2&3&4	12	0.7549, 0.7357, 0.7357,⋯, 5.0327	(15,12)

4　连接松弛状态识别结果分析

4.1　连接松弛对于结构响应向量的影响

在 2.4 节已经求解出各松弛工况下的框支玻璃幕墙的结构响应向量。下面从空间向量的 2 个基本属性——模和空间角出发，探讨连接松弛对于结构响应向量的影响。

4.1.1　连接松弛对于结构响应向量模的影响　根据空间向量模的定义，SRV 模 M^i 的计算公式为：

$$M^i=\sqrt{(\psi_1)^2+\cdots+(\psi_4)^2+\cdots+(\xi_{29})^2} \tag{13}$$

特别的，当上述的玻璃幕墙处于无松弛状态时，M^0 =4.690 4。

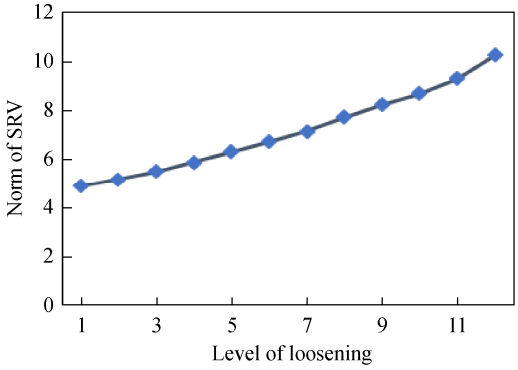


图 3　单边 1 松弛下 SRV 模的演化

Fig. 3　Norm of SRV for pattern 1

将表 2 中的数据带入式(13)，可以求解出各松弛工况下的模。以单边 1 松弛为例，SRV 的模随连接松弛的演化见图 3。如图 3 所示，在给定连接松弛模式下，SRV 的模与松弛程度近似成线性的关系，在其他连接松弛模式中也有同样的现象。

4.1.2　连接松弛对于结构响应向量方向角的影响　SRV 的方向角定义为特定松弛工况下的 SRV 与无松弛状态下的 SRV 之间的夹角，SRV 的方向角 θ^i 的计算公式为：

$$\theta^i=\cos^{-1}\left(\frac{V^i\cdot V^0}{M^i\cdot M^0}\right) \tag{14}$$

当上述的玻璃幕墙处于无松弛状态时，θ^0=1。

表 2 中的数据带入式(14)中，可以求解出各松弛工况下的模。以单边 1 松弛为例，SRV 的方向角随连接松弛的演化如图 4 所示。

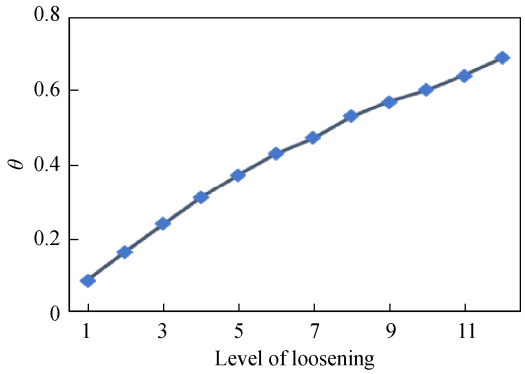


图 4　单边 1 松弛下 SRV 方向角 θ 的演化

Fig. 4　Direction angle θ of SRV for pattern 1

在给定连接松弛模式下，SRV 的方向角与松弛程度近似成线性关系。其他连接松弛模式(如双边)的 SRV 的模和方向角都有类似的趋势。经由上述分析，可以看到 SRV 对于玻璃幕墙连接松弛的模式和程度，尤其是给定松弛模式下的松弛程度具有非常良好的识别效果。但是考虑到玻璃幕墙结构本身的对称性质，连接松弛定位问题仅仅通过结构响应向量进行识别存在一定的难度，而支持向量机则在结构损伤定位上一直有比较好的应用效果。因此将结构响应向量作为支持向量机的输入量进行连接松弛识别。

4.2　不同核函数的连接松弛识别效果

采用一对一(OVO)方法构造 SVM 分类器，k=15 种松弛模式，共需要构造 $k(k–1)/2$=105 个二类分类器。这种方法可以减少训练数据不均匀带来的影响，提高分类精度。采用 python 中的专门用于机器学习的 SciKit learn 库进行支持向量机的训练以及识别。

分别采用线性核函数、RBF 核函数和 Sigmoid 核函数作为 SVM 的核函数进行松弛识别，不同惩罚参数下，松弛识别效果见表 3。

如表 3 所示，不同的核函数的性能有比较明显的差异。惩罚函数 C 过小时，会导致欠拟合的情况，而惩罚函数过大时，则会出现过拟合的情况。在惩罚函数 $C\leqslant 10$ 的情况下，线性核函数的性能要明显优于 RBF 核函数和 Sigmoid 核函数。但随着惩罚函数 C 的逐渐增大，后两者的性能提升非常明显，考虑到线性核函数主要针对线性可分的情况，对更为复杂的线性不可分的情况(如大尺寸试件动力特性可分性会变差)适用性一般要差一些，因此针对外推性通常更好的 RBF 核函数[15]的优化展开讨论。

表 3　不同核函数和惩罚参数的识别结果

Table 3　Accuracy under different kernel functions and penalty parameters

Penalty function	Kernel					
	Linear		RBF		Sigmoid	
	Accuracy	Misrecognized conditions	Accuracy	Misrecognized conditions	Accuracy	Misrecognized conditions
C=0.5	89.13%	(6,1),(4,1),(9,1),(10,1),(13,1)	17.32%	(6,1),⋯,(12,5)	6.22%	(1,7),⋯,(14,8)
C=1.0	89.13%	(6,1),(4,1),(9,1),(10,1),(13,1)	50.00%	(1,4),⋯,(5,7)	19.56%	(1,7),⋯,(14,8)
C=3.0	97.82%	(6,1)	73.91%	(6,1),⋯，(11,2)	54.34%	(6,1),⋯,(5,7)
C=5.0	100.00%		82.61%	(6,1),(12,2),(10,1),(9,1),(4,1),(3,2),(13,1),(11,2)	71.73%	(6,1),⋯,(11,2)
C=10.0	100.00%		89.13%	(6,1),(10,1), (9,1),(4,1),(13,1)	82.61%	(6,1),(12,2),(10,1),(9,1),(4,1),(3,2),(13,1),(11,2)

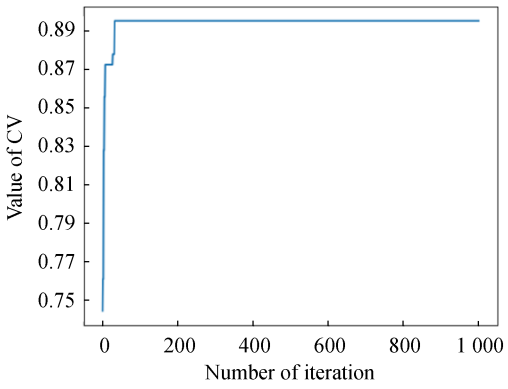
RBF is radial basis function.

以 C=1 的线性核函数组成的 SVM 为例，识别率为 89.13%，松弛识别错误的工况为(6，1)、(4，1)、(9，1)、(10，1)和(13，1)，即模式 4 (单边 4 松弛)、6 (对边 1 和 3 松弛)、9 (对边 2，4)、10 (邻边 3，4 松弛)、13 (三边 2，3，4 松弛)产生 1 等级的松弛，即该向量机对于松弛程度较轻的情况误判的概率会更高。RBF 核函数和 Sigmoid 核函数随着 C 的增加也体现了相同的趋势。

至此，验证了 SRV-SVM 对于框支玻璃幕墙边界连接松弛识别的适用性。另外，将误判工况的误判值与实际值进行对比，可以发现误判值往往是比实际情况更严重，因此从工程应用的角度偏安全。

4.3　运用粒子群算法参数优化的效果

运用粒子群算法搜索 RBF 核函数的最优参数，从而对 RBF 核函数所构成的 SVM 性能进行优化。参数设置如下：粒子数取 100、c_1=c_2=2、w=0.8，取值范围[0.001,15.000]。优化所得的最佳参数为 C= 11.919 6，Gamma 为 0.004 131。如图 5 所示，从实验结果来看，粒子群算法能够更准确、有效地进行核函数的优化，使得支持向量机的测试误差相应的减少。于此同时，识别的准确率也没有下降，也就是说在玻璃幕墙监测应用方面，与传统的交叉检验方法相比，采用粒子群算法的参数选择方法不但能够保证支持向量机的学习能力，并在一定程度上提高了 SVM 的推广能力，进而从整体上提高了 SVM 的性能。



Value of CV is the detection accuracy after cross valuation.

图 5　PSO 优化结果

Fig. 5　Parameter optimization using particle swarm optimization (PSO)

5　结论

以四边框支玻璃幕墙为研究对象，通过有限元模型生成连接松弛状态样本库，利用 SRV–SVM 方法进行松弛位置和程度的识别，得到以下结论：

1) 动静态响应组成的结构响应向量对于框支玻璃幕墙连接松弛的识别(尤其是松弛程度的识别)具有良好的效果，可以作为支持向量机的较为理想的输入值，用于松弛样本库的训练和识别。

2) 支持向量机的 3 种核函数对于本工作算例中的四边框支玻璃幕墙的连接松弛识别都有很好

的效果，其中线性核函数的识别效果最佳。

3) 在玻璃幕墙监测应用方面，粒子群算法能够准确、有效地进行支持向量机 RBF 核函数的参数优化，同时保证框支幕墙连接松弛识别的准确率，也一定程度上保证了支持向量机的推广能力。

参考文献:

[1] 徐涵, 杨健, 王星尔, 等. 反向传播神经网络在隐框玻璃幕墙脱胶损伤识别中的应用[J]. 硅酸盐学报, 2019, 47(8): 1073–1079.
XU Han, YANG Jian, WANG Xing′er, et al. J Chin Ceram Soc, 2019, 47(8): 1073–1079.

[2] 罗文奇, 方治华. 基于频率变化率的全隐框玻璃幕墙损伤检测研究[J]. 建筑技术开发, 2017, 7: 1–2.
LUO Wenqi, FANG Zhihua. S Build Technol Dev (in Chinese), 2017, 7: 1–2.

[3] 刘军香, 王立新, 姜慧, 等. 基于加速度二次协方差矩阵和神经网络的结构损伤识别[J]. 地震工程与工程振动, 2019, 3: 214–221.
LIU Junxiang, WANG Lixin, JIANG Hui, et al. Earthq Eng Eng Dyn (in Chinese), 2019, 3: 214–221.

[4] 孙艳丽, 杨娜, 张正涛, 等. 基于核主元分析和支持向量机的结构损伤识别研究[J]. 应用基础与工程科学学报, 2018, 4: 888–900.
SUN Yanli, YAN Na, ZHANG Zhengtao, et al. J Basic Sci Eng (in Chinese), 2018, 4: 888–900.

[5] 谢建宏. 智能结构损伤自诊断的PSO-LSWSVM方法[J]. 计算机应用研究, 2017, 34(12): 146–148+157.
XIE Jianhong. Appl Res Comput (in Chinese), 2017, 34(12): 146–148+157.

[6] 罗旭. 基于结构响应向量的桥梁结构损伤识别研究[D]. 广州: 华南理工大学, 2012.
LUO Xu. The research of bridge structure damage identification based on structure response vector (in Chinese, dissertation). Guangzhou: South China University of Technology, 2012.

[7] 涂成枫. 基于SRV的支持向量机损伤识别方法研究[D]. 广州: 华南理工大学, 2018.
TU Chengfeng. Support vector machine method based on SRV for damage identification (in Chinese, dissertation). Guangzhou: South China University of Technology, 2018.

[8] VAPNIK V N. The Nature of Statistical Learning Theory[M]. New York: Springer, 2000.

[9] XIE J. Improved least square support vector machine for structural damage detection[C]//2010 2nd International Conference on Computer Engineering and Technology, Chengdu, China, 2010: 237–240.

[10] 周涛丽. 基于支持向量机的多分类方法研究[D]. 成都:电子科技大学, 2015.
ZHOU T L. Research on multi-classification method based on support vector machine (in Chinese, dissertation). Chengdu: University of Electronic Science and Technology of China, 2015.

[11] 袁小艳, 刘爱伦. 基于PSO算法的支持向量机核参数选择问题研究[J]. 自动化技术与应用, 2007, 26(5): 5–8.
YUAN Xiaoyan, LIU Ailun. Tech Automa Appl (in Chinese), 2007, 26(5): 5–8.

[12] 刘小根, 包亦望. 基于固有频率变化的框支承玻璃幕墙安全评估[J]. 沈阳工业大学学报, 2011，33(5): 118–123.
LIU Xiaogen, BAO Yiwang. J Shenyang Uni Technol (in Chinese), 2011, 33(5): 118–123.

[13] 刘小根. 玻璃幕墙安全性能评估及其面板失效检测技术[D]. 北京: 中国建筑材料科学研究总院, 2010.
LIU Xiaogen. Failure dectection of the glass panel and safety evaluation of glass curtain wall (in Chinese, dissertation). Beijing: China Building Materials Aacademy, 2010.

[14] ZHENG H, ZHANG S, SUN X. Classification recognition of anchor rod based on PSO-SVM[C]// 2017 29th Chinese Control And Decision Conference (CCDC), Chongqing, China, 2017: 2207–2212.

[15] 李盼池, 许少华. 支持向量机在模式识别中的核函数特性分析[J]. 计算机工程与设计, 2005, 26(2): 302–304.
LI Panchi, XU Shaohua. Comput Eng Des (in Chinese), 2005, 26(2): 302–304.