

# 结构可靠性分析的支持向量机方法<sup>\*</sup>

李洪双, 吕震宙, 岳珠峰

(西北工业大学 航空学院, 西安 710072)

(本刊编委岳珠峰来稿)

**摘要:** 针对结构可靠性分析中功能函数不能显式表达的问题, 将支持向量机方法引入到结构可靠性分析中。支持向量机是一种实现了结构风险最小化原则的分类技术, 它具有出色的小样本学习性能和良好的泛化性能, 因此提出了两种基于支持向量机的结构可靠性分析方法。与传统的响应面法和神经网络法相比, 支持向量机可靠性分析方法的显著特点是在小样本下高精度地逼近函数, 并且可以避免维数灾难。算例结果也充分表明支持向量机方法可以在抽样范围内很好地逼近真实的功能函数, 减少隐式功能函数分析(通常是有限元分析)的次数, 具有一定的工程实用价值。

**关键词:** 结构可靠性; 隐式功能函数; 支持向量机

**中图分类号:** TB114.3      **文献标识码:** A

## 引 言

隐式极限状态函数的可靠性分析是结构可靠性学科所面临的主要困难之一。从理论上讲任何针对显式极限状态函数发展的可靠性分析方法均可用于隐式情况<sup>[1,2]</sup>, 但在实际操作时会遇到难以克服的困难: 如基于梯度计算的可靠性分析方法<sup>[3-5]</sup>, 在用于隐式情况的可靠性分析时, 就因隐式梯度函数不易求得而很难实施; 基于数字模拟的可靠性分析方法<sup>[2,4]</sup>, 则由于需要反复计算抽样点处隐式功能函数值的工作量太大而不能为工程所接受。上个世纪 90 年代逐步发展的回归算法<sup>[6]</sup>, 在一定程度上解决了隐式极限状态函数的可靠性分析问题, 这类算法的基本思想是在经验风险最小的前提下, 构造隐式功能函数的近似显式表达式, 以近似显式表达式的失效概率替代真实的失效概率, 响应面法<sup>[1,5-10]</sup>(response surface method, RSM)和人工神经网络方法<sup>[1,2,6,11-13]</sup>(artificial neural network, ANN) 是这类回归算法的代表。尽管这类算法已经成功地解决了一些隐式极限状态函数的可靠性分析问题, 但其采用“经验风险最小”的原则严重影响了其适应范围, 选定响应面函数的形式及经验参数是响应面法还没有完全解决的问题, 而神经网络的拓扑结构及参数选择、过学习和局部最优等问题则是神经网络在隐式极限状态可靠性分析中主要的障碍。

\* 收稿日期: 2005-12-26; 修订日期: 2006-07-09

基金项目: 国家自然科学基金资助项目(10572117); 航天基金资助项目(N3CH0502, N5CH0001); 新世纪优秀人才支持计划(NCET\_05\_0868)

作者简介: 李洪双(1978—), 男, 黑龙江巴彦人, 博士研究生, 主要从事结构可靠性研究;

吕震宙(1966—), 女, 湖北黄石人, 教授, 博士生导师, 主要从事飞行器结构可靠性工程研究(联系人, Tel/Fax: + 86\_29\_88460480; E\_mail: zhenzhou@nwpu.edu.cn)。

支持向量机<sup>[14-17]</sup> (support vector machine, SVM) 是与神经网络类似的一种智能化模式识别方法, 但是理论基础不同。ANN 是基于经验风险最小化原则 (empirical risk minimization, ERM) 的, 而 SVM 的基础是结构风险最小化原则 (structural risk minimization, SRM)。ERM 原则仅强调训练样本误差最小, ANN 方法可能得到很小的训练误差, 但是对于未经训练的新数据, 其泛化能力较差, 给出不可信的估计值。SRM 原则不仅最小化经验风险值, 还要最小化置信范围值, 尽量提高学习机的泛化能力。与 ANN 相比, SVM 不存在局部最优问题, 并且提高了学习机的泛化能力, 因而具有更大的优越性。

SVM 方法用于可靠度计算始于 Rocco 和 Moreno, 他们将 SVM 方法用于评估网络系统的可靠性<sup>[18]</sup>。Hurtado 和 Alvarez 将结构可靠性分析问题考虑成模式识别问题, 采用 SVM 方法结合随机有限元对结构进行可靠性分析<sup>[19]</sup>。Hurtado 借助统计学习理论讨论了多层前向感知器神经网络 (MLP)、SVM 等分类算法在含有隐式功能函数的结构可靠性分析的可能性, 确定了只有 MLP 和 SVM 适合于结构可靠性分析问题, 尤其是小样本情况<sup>[6]</sup>。从现有文献来看, SVM 在可靠性分析方面的应用研究仍相当缺乏, 本文针对结构可靠性分析中经常遇到的功能函数为隐式的情况, 采用与 ANN 方法类似的思路<sup>[13]</sup>, 提出了 2 种基于 SVM 的可靠性分析方法: 基于支持向量机的 Monte Carlo 模拟法 (Monte Carlo simulation, MCS) 和基于支持向量机的一次二阶矩方法 (first order reliability method, FORM)。

## 1 支持向量机简介

SVM 是在统计学习理论指导下发展起来的实现了结构风险最小化思想的新学习算法。支持向量机将分类和回归问题转化为二次优化问题, 其解具有全局最优性, 并且与样本点的具体分布无关。以下简要介绍 SVM 的基本思想<sup>[14-17]</sup>。

### 1.1 线性支持向量机

给定训练样本集

$$(\mathbf{x}_1, y_1), (\mathbf{x}_2, y_2), \dots, (\mathbf{x}_l, y_l), \quad \mathbf{x} \in R^n, y \in \{+1, -1\}, \quad (1)$$

式中  $\mathbf{x}_i$  为训练样本,  $l$  为样本量,  $y$  为  $\mathbf{x}_i$  的类别标识。定义一个能够将两类样本点正确分开的超平面

$$(\mathbf{w} \cdot \mathbf{x}) + w_0 = 0, \quad (2)$$

式中  $(\cdot)$  是  $n$  维矢量空间的两个矢量的内积。

对于线性可分的训练集, 可能存在无数个能够正确分开两类样本的超平面, SVM 方法确定出一个超平面使离超平面最近的样本点到超平面的距离 (分类间隔) 最大, 称为最大间隔超平面或最优超平面 (maximal margin hyperplane or optimal hyperplane)。

构造最优超平面问题可转化为最小化下列泛函问题<sup>[15-17]</sup>

$$\begin{aligned} \min \quad & \|\mathbf{w}\|^2/2 = (\mathbf{w} \cdot \mathbf{w})/2, \\ \text{s. t.} \quad & y_i[(\mathbf{w} \cdot \mathbf{x}_i) + w_0] \geq \pm 1. \end{aligned} \quad (3)$$

(3) 式描述的是一个二次优化问题, 解可由 Lagrange 函数的鞍点给出

$$L(\mathbf{w}, w_0, \alpha) = (\mathbf{w} \cdot \mathbf{w})/2 - \sum_{i=1}^l \alpha_i \left\{ y_i [(\mathbf{w} \cdot \mathbf{x}_i) + w_0] - 1 \right\}, \quad (4)$$

式中  $\alpha_i \geq 0 (i = 1, 2, \dots, l)$  为 Lagrange 系数, 求 Lagrange 函数关于  $\mathbf{w}$  和  $w_0$  的极小值得到

$$\sum_{i=1}^l \alpha_i y_i = 0, \quad (5)$$

$$w = \sum_{i=1}^l \alpha_i y_i x_i \tag{6}$$

同时,解一定满足最优化问题的 KKT(Karush\_Kuhn\_Tucker) 互补条件

$$\alpha_i \{ y_i [ (w \cdot x_i) + w_0 ] - 1 \} = 0 \tag{7}$$

KKT 条件意味着仅有少数训练样本具有非零 Lagrange 系数  $\alpha_i > 0$ , 称为支持向量(support vector, SV), 则式(6)变为

$$w = \sum_{i \in SV} \alpha_i y_i x_i \tag{8}$$

把式(5)和(6)代入到式(4), 并考虑 KKT 条件, 得到原始问题的对偶优化问题

$$\min \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l y_i y_j \alpha_i \alpha_j (x_i \cdot x_j) - \sum_{j=1}^l \alpha_j, \tag{9}$$

$$\text{s. t. } \sum_{i=1}^l \alpha_i y_i = 0, \quad \alpha_i \geq 0, \quad i = 1, 2, \dots, l \cdot$$

获得  $\alpha$  的解后, 最优超平面的参数矢量  $w$  可表示为 SV 的线性组合((8) 式),  $w_0$  和最优超平面方程也完全由 SV 确定。

对于线性不可分的情况, 在优化问题(3) 式的约束条件中引入松弛变量  $\xi_i \geq 0$ , 对偶优化问题演化为

$$\min \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l y_i y_j \alpha_i \alpha_j (x_i \cdot x_j) - \sum_{j=1}^l \alpha_j, \tag{10}$$

$$\text{s. t. } \sum_{i=1}^l \alpha_i y_i = 0, \quad C \geq \alpha_i \geq 0, \quad i = 1, 2, \dots, l,$$

其中  $C > 0$  是事先选定的惩罚参数, 它反映了在模型复杂性和不可分样本所占比例之间的折中。

### 1.2 非线性支持向量机

对于非线性可分样本, 线性支持向量机分类能力有限, 求得的解常常因为误差太大而失去了实际意义。非线性支持向量机算法的基本思想是通过非线性变换  $x \rightarrow \Phi(x)$ , 将输入向量映射到高维特征空间  $Z$ , 在特征空间内构建最优分类超平面。图 1 解释了这种映射思想。在特征空间构建最优分类超平面, 仅涉及到矢量的内积计算, 核函数提供了更简单实用的方法, 它不需要知道非线性变换的表达式。高维特征空间两个矢量  $z_i$  和  $z_j$  的内积是输入空间中的向量  $x_i$  和  $x_j$  的函数

$$(z_i \cdot z_j) = (\Phi(x_i) \cdot \Phi(x_j)) = K(x_i, x_j), \tag{11}$$

式中  $K(x_i, x_j)$  为核函数, 只要  $K(x_i, x_j)$  满足 Mercer 条件, 即可用来计算内积<sup>[15-17]</sup>。

常用的满足 Mercer 条件的核函数有以下一些多项式核:  $K(x_i, x_j) = [(x_i \cdot x_j) + 1]^d (d \in \mathbf{N})$ 、Gauss 基核函数  $K(x_i, x_j) = \exp(-\|x_i - x_j\|/2\sigma^2)$ 、多层感知核  $K(x_i, x_j) = \tanh[v(x_i \cdot x_j) + a]$ 。选定核函数后, 对于非线性可分训练样本, 在高维特征空间, 最优分类面是个超平面, 而在输入空间最优分类面是个超曲面(非线性的), 据此可以构造出决策函数(指示函数):

$$f(x) = \text{sgn} \left[ \sum_{j=1}^l \alpha_j y_j K(x_i, x_j) + w_0 \right], \tag{12}$$

式(12)表示了基于支持向量机的分类规则。

## 2 基于支持向量机的可靠性分析方法

将落入失效域的抽样点记为  $-1 (g(x) \leq 0)$ , 落入安全域的抽样点记为  $+1 (g(x) > 0)$ ,

则结构可靠性分析问题可以转化为分类问题。文献[6]利用统计学习理论阐明了 SVM 可用于结构可靠性分析,因为它有 3 个优势: 1) 可采用小样本数据逼近函数; 2) 采用柔性自适应模型; 3) 能够克服维数灾难。




图 1 输入空间到特征空间的映射<sup>[10]</sup>

结合经典结构可靠性方法,本文提出了两种基于 SVM 的结构可靠性分析方法:基于 SVM 的 MCS 和基于 SVM 的 FORM。这两种方法使用 SVM 的目的略有不同,基于 SVM 的 MCS 方法把训练后的 SVM 作为分类器,输出值仅依赖抽样点的位置;基于 SVM 的 FORM 方法利用 SVM 逼近结构的真实极限状态方程。

## 2.1 抽样过程

如何产生训练样本是基于 SVM 结构可靠性分析最基本的问题之一。直接 MCS 方法根据基本随机变量的概率分布进行抽样,然而这样做是不合适的,尤其是失效概率较小的结构,经过多次抽样有可能不出现失效点,无法作为分类问题的训练样本。

对于训练样本,可以利用均匀分布在随机变量的均值两侧  $k$  倍标准差范围内随机产生,例如基本随机变量  $X \sim N(\mu, \sigma^2)$ , 抽样范围为  $[\mu - k\sigma, \mu + k\sigma]$ 。这种抽样方法保证了在较大范围内都有抽样点,而且能够满足训练 SVM 时对落入失效域抽样点的需求。如果确切知道某个随机变量对结构可靠度的影响,甚至可以缩小抽样范围,增加落入失效域的点。对载荷变量,其分布的右尾部对失效概率的影响较大,因此抽样范围可以控制在载荷的均值到载荷的均值加  $k$  倍载荷的标准差范围内;对强度变量,其分布的左尾部对失效概率的影响较大,因此抽样范围可以控制在强度的均值减  $k$  倍强度的标准差到强度均值的范围内。

## 2.2 尺度变换

对输入数据进行尺度变换的目的是减少计算机的舍入误差,提高训练 SVM 的稳定性和 SVM 的泛化性。基本随机变量作为输入数据常常因为物理意义和量纲不同,造成各自取值范围的差别较大,在 SVM 训练中容易出现不稳定现象,即使训练成功,泛化性能也很差。所以,基本随机变量按下式变换,使它们在训练中具有同等重要的地位

$$x_i' = \frac{x_i - \mu_i}{\sigma_i}, \quad (13)$$

式中  $x_i$  为随机变量  $x$  的第  $i$  个样本,  $\mu_i$  和  $\sigma_i$  分别为这个随机变量的均值和标准差,  $x_i'$  为尺度变换后的样本。

## 2.3 基于支持向量机的 Monte Carlo 模拟方法

图 2 给出了基于 SVM 的 MCS 可靠性分析方法流程图。SVM 可作为分类器,根据随机变量的概率分布抽取样本点,代入到训练成功的 SVM 中获得响应值。结构的失效概率由下式计算

$$P_f = P(g(x) \leq 0) \approx P(f(x) \leq 0) = N_f/N, \quad (14)$$

式中  $g(x)$  为真实的功能函数,  $f(x)$  为由 SVM 方法求得的近似功能函数,  $N$  为按基本随机变量概率密度函数抽取的样本总数,  $N_f$  为落入失效域  $f(x) \leq 0$  的样本数。

### 2.4 基于支持向量机的一次二阶矩方法

SVM 用来逼近结构的隐式极限状态函数, 从而可以计算功能函数对各个基本随机变量的一阶偏导数, 解决了 FORM 方法对偏导数的需要。一般的, SVM 逼近的功能函数可以表示成

$$f(x) = \sum_{i \in SV} \alpha_i y_i K(x_i, x_j) + w_0, \quad (15)$$

式中  $x$  为  $n$  维随机变量向量。选定核函数后, 可以较容易地计算偏导数, 例如对  $d$  次多项式核函数  $K^d(x_i, x_j)$  有

$$\frac{\partial f}{\partial x_i} = \sum_{j \in SV} \alpha_j x_j^i y_j K^{d-1}(x \cdot x_j). \quad (16)$$

## 3 算 例


本节给出几个假定的隐式极限状态函数算例, 来研究 SVM 在结构可靠性分析中的应用并考察计算精度。算例结果的比较均列于表格中, 在所有的表格中, FORM 表示一次二阶矩方法计算结果, 类似的, MCS, SVM\_based FORM 和 SVM\_based MCS 表示相应方法的计算结果。

### 例 1 二次极限状态函数的可靠性分析<sup>[10]</sup>


式(17)给出了一个常用来考核隐式极限状态可靠性分析方法精度的二次极限状态函数

$$g(x) = 4 - \frac{4}{25}(x_1 - 1)^2 - x_2, \quad (17)$$

其中  $x_1, x_2$  是标准正态随机变量。按照本文的抽样方法抽取 100 个样本(样本点略), 选取多项式核函数训练样本, 分别选取多项式的阶数  $d = 2, 3, 4, 5$  经多次训练后, 极限状态方程的逼近情况见图 3, 实线是真实的极限状态方程, 虚线为由支持向量机得到的近似极限状态方程, 加圈的样本点为支持向量, 表 1 给出了失效概率的计算结果。



(a)  $d = 2$



(b)  $d = 3$

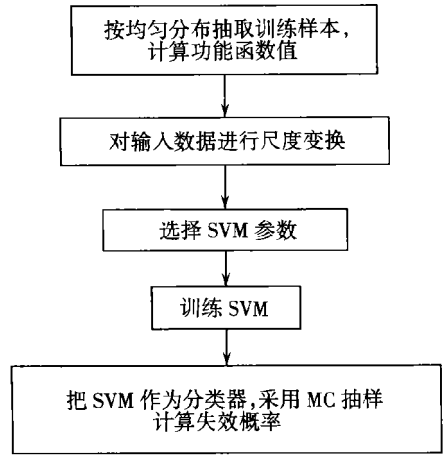




图 2 基于 SVM 的 MCS 方法分析流程



(c)  $d = 4$



(d)  $d = 5$

图3 二次极限状态方程的逼近

表1

例1的失效概率( $\times 10^{-4}$ )

FORM	MCS	SVM_based ( $d = 2$ )		SVM_based ( $d = 3$ )		SVM_based ( $d = 4$ )		SVM_based ( $d = 5$ )	
		FORM	MCS	FORM	MCS	FORM	MCS	FORM	MCS
6.36	8.0	4.35	5.67	6.25	6.43	6.03	6.32	4.94	7.53


从图3可以看出多项式核函数的阶数对拟合曲线的形状有一定的影响;而支持向量的个数均不超过训练样本的10%,去掉非支持向量样本对结果无任何影响。从失效概率计算结果可以看出:SVM结果与直接Monte Carlo方法存在一定差别,这是因为抽样范围被限制在一定的区域内,拟合的极限状态曲面在抽样区域与实际的曲面吻合较好。

例2 四次极限状态函数的可靠性分析<sup>[19]</sup>


考察更一般情况,

$$g(\mathbf{x}) = 2 + \exp\left[-\frac{x_1^2}{10}\right] + \left[\frac{x_1}{5}\right]^4 - x_2, \quad (18)$$

式中 $x_1, x_2$ 是标准正态随机变量。例1的极限状态方程是一个凸函数,而本例函数图像则呈现凸、凹两部分。抽取100个样本点,选取多项式核函数,极限状态方程的拟合情况见图4,结果比较见表2。



(a)  $d = 2$



(b)  $d = 3$

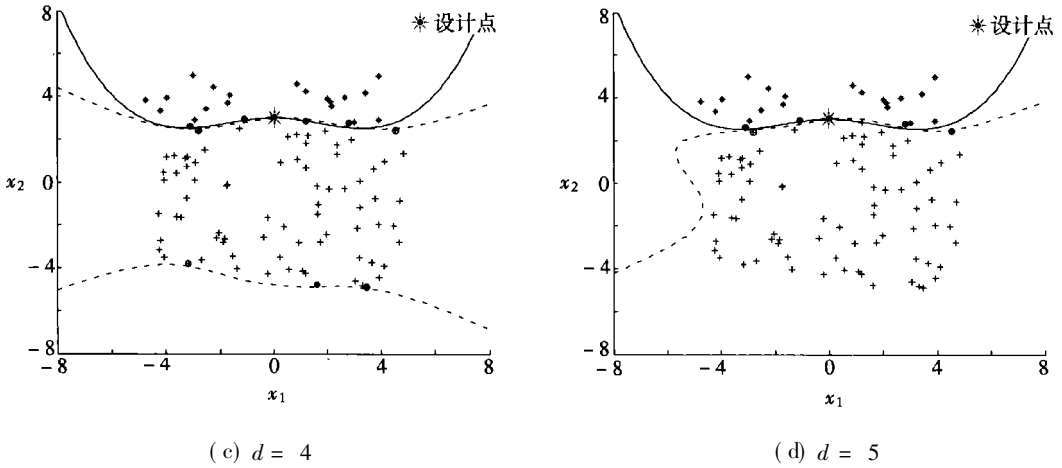


图4 四次极限状态方程的逼近

表2 例2的失效概率(×10<sup>-3</sup>)

FORM	MCS	SVM_based (d = 2)		SVM_based (d = 3)		SVM_based (d = 4)		SVM_based (d = 5)	
		FORM	MCS	FORM	MCS	FORM	MCS	FORM	MCS
1.35	1.84	2.09	2.25	1.60	1.90	1.50	1.91	1.54	1.82

例3 三跨度梁的可靠性分析

本例分析了如图5所示的三跨度梁可靠性,其中L = 5 m。考虑三跨度梁挠度最大允许值为L/360,可以建立极限状态函数

$$g(w, E, I) = L/360 - 0.0069 wL^4/EI, \tag{19}$$

式中w为分布载荷,E为弹性模量,I为惯性矩,基本随机变量相互独立,其分布参数见表3。失效概率计算结果见表4。与文献[4]给出的“精确解” $P_f = 7.5436 \times 10^{-4}$ (可靠度指标 $\beta = 3.173$ )比较而言,SVM方法精度能够满足工程要求。

表3 例3基本随机变量的分布参数

随机变量	均值	标准差
w	10 kN/m	0.4 kN/m
E	$2 \times 10^7$ kN/m <sup>2</sup>	$0.5 \times 10^7$ kN/m <sup>2</sup>
I	$8 \times 10^{-4}$ m <sup>4</sup>	$1.5 \times 10^{-4}$ m <sup>4</sup>

表4 例3的失效概率(×10<sup>-4</sup>)

FORM	MCS	SVM_based (d = 3)	
		FORM	MCS
7.5436	8.960	8.3778	8.6530




图5 三跨度梁示意图

4 结 论

本文提出了两种基于SVM的结构可靠性分析方法,它们充分利用了SVM的最大特点——SRM原则,由小样本得到的小训练误差能够保证未参加训练样本保持小的预测误差。算例表明,本文方法实施简单,计算结果具有很高的精度,并且可以得出如下结论:

- 1) SVM方法不但可以作为分类方法用于结构可靠性分析,也可以作为函数逼近方法用于结构可靠性分析;

2) 在计算过程中,核函数参数的选择对失效概率的运算速度和精度有很大的影响。目前,这个问题还没有很好的解决,目前主要依赖交叉验证技术。

3) SVM 方法最终解凸二次优化问题得到全局最优结果,既提高了结果的精度,同时又避免在拟合功能函数时陷入局部最优。

### [参 考 文 献]

- [1] Gomes H M, Awruch A M. Comparison of response surface and neural network with other methods for structural reliability analysis[J]. *Structural Safety*, 2004, **26**(1): 49—67.
- [2] Schueremans L, Gemert D V. Benefit of splines and neural networks in simulation based structural reliability analysis[J]. *Structural Safety*, 2005, **27**(3): 246—261.
- [3] Rackwitz R. Reliability analysis—a review and some perspectives[J]. *Structural Safety*, 2001, **23**(4): 365—395.
- [4] Nowak A R, Collins K R. *Reliability of Structures* [M]. Boston: McGraw\_Hill, 2000.
- [5] Zhao Y G, Ono T. A general procedure for first/ second order reliability method (FORM/ SORM) [J]. *Structural Safety*, 1999, **21**(2): 95—112.
- [6] Hurtado J E. An examination of methods for approximating implicit limit state functions from the viewpoint of statistical learning theory[J]. *Structural Safety*, 2004, **26**(3): 271—293.
- [7] Bucher C G, Bourgund U. A fast and efficient response surface approach for structural reliability problems[J]. *Structural Safety*, 1990, **7**(1): 57—66.
- [8] Rajashekhar M R, Ellingwood B R. A new look at the response surface approach for reliability analysis[J]. *Structural Safety*, 1993, **12**(3): 205—220.
- [9] Kim S, Na S. Response surface method using vector projected sampling points[J]. *Structural Safety*, 1997, **19**(1): 3—19.
- [10] Guan X L, Melchers R E. Effect of response surface parameter variation on structural reliability estimates[J]. *Structural Safety*, 2001, **23**(4): 429—444.
- [11] Hurtado J E, Alvarez D A. Neural\_network\_based reliability analysis: a comparative study[J]. *Computer Methods in Applied Mechanics and Engineering*, 2001, **191**(1/2): 113—132.
- [12] Papadrakakis M, Lagaros N D. Reliability\_based structural optimization using neural networks and Monte Carlo simulation[J]. *Computer Methods in Applied Mechanics and Engineering*, 2002, **191**(32): 3491—3507.
- [13] Deng J, Gu D S, Li X B, et al. Structural reliability analysis for implicit performance functions using artificial neural network[J]. *Structural Safety*, 2005, **27**(1): 25—48.
- [14] Cortes C, Vapnik V N. Support vector networks[J]. *Machine Learning*, 1995, **20**(3): 273—297.
- [15] Vapnik V N. An overview of statistical learning theory[J]. *IEEE Transaction on Neural Networks*, 1999, **10**(5): 988—998.
- [16] Vapnik V N. *The Nature of Statistical Learning Theory* [M]. New York: Springer\_Verlag, 1995.
- [17] 邓乃扬, 田英杰. 数据挖掘中的新方法——支持向量机[M]. 北京: 科学出版社, 2004.
- [18] Rocco C M, Moreno J A. Fast Monte Carlo reliability evaluation using support vector machine[J]. *Reliability Engineering and System Safety*, 2002, **76**(3): 237—243.
- [19] Hurtado J E, Alvarez D A. Classification approach for reliability analysis with stochastic finite element modeling[J]. *Journal of Structural Engineering*, 2003, **129**(8): 1141—1149.



# Support Vector Machine for Structural Reliability Analysis

LI Hong\_shuang, LÜ Zhen\_zhou, YUE Zhu\_feng  
( School of Aeronautics , Northwestern Polytechnical University ,  
Xi' an 710072, P . R . China )

**Abstract:** Support vector machine (SVM) was introduced to analyze the reliability of the implicit performance function, which is difficult to implement by the classical methods such as the first order reliability method (FORM) and the Monte Carlo simulation (MCS). As a classification method where the underlying structural risk minimization inference rule is employed, SVM possesses excellent learning capacity with a small amount of information and good capability of generalization over the complete data. Hence, two approaches, i. e. SVM\_based FORM and SVM\_based MCS, were presented for the structural reliability analysis of the implicit limit state function. Compared to the conventional response surface method (RSM) and the artificial neural network (ANN), which are widely used to replace the implicit state function for alleviating the computation cost, the more important advantages of SVM are that it can approximate the implicit function with higher precision and better generalization under the small amount of information and avoid the “curse of dimensionality”. The SVM\_based reliability approaches can approximate the actual performance function over the complete sampling data with the decreased number of the implicit performance function analysis (usually finite element analysis), and the computational precision can satisfy the engineering requirement, which are demonstrated by illustrations.

**Key words:** structural reliability; implicit performance function; support vector machine