

doi: 10.3969/j.issn.1006-1576.2011.11.007

基于 SVM 的导弹自由飞行阶段可靠性评估

薛继明^{1,2}, 左磊¹, 黄岩¹, 李春¹

(1. 国防科学技术大学机电工程与自动化学院, 长沙 410073;

2. 第二炮兵装备研究院, 北京 100085)

摘要: 为更好地评估巡航导弹自由飞行阶段的可靠性, 对小样本回归问题进行研究。首先对实验数据进行特征选择与提取得到学习样本, 在此基础上利用支持向量机(support vector machine, SVM)方法进行可靠性评估研究, 然后通过仿真实验对比神经网络与支持向量机 2 种方法的评估效果。结果证明: SVM 的训练学习效率更高, 同时能够保证较好的泛化性能, 提高自由飞行阶段可靠性的评估效果。

关键词: 导弹; 可靠性; 支持向量机; 神经网络

中图分类号: TJ760.6+23 **文献标志码:** A

Reliability Evaluation for Missile Free Flight Based on SVM

Xue Jiming^{1,2}, Zuo Lei¹, Huang Yan¹, Li Chun¹

(1. College of Electromechanical Engineering & Automation, National University of Defense Technology, Changsha 410073, China; 2. Second Artillery Equipment Academy, Beijing 100085, China)

Abstract: In order to improve the performance of the missile reliability estimation in free flight phase, the research of the regression problem with small scale of samples is carried out. Firstly, the learning samples are obtained after feature selection and abstraction, based on which the SVM is used to estimate the reliability of the missiles. Then the estimation performance of the neural network and SVM is compared by simulation. The results indicate that the efficiency of SVM was higher than the neural network, and SVM also has good generalization ability and can improve the performance of the reliability estimation.

Keywords: missile; reliability; SVM; neural network

0 引言

现代战争需要的导弹武器除具有准确的打击性能外, 还要求武器装备拥有良好的可靠性和可用性, 以保障武器系统能随时应对打击需求^[1]。随着导弹的广泛应用, 人们对其可靠性的要求越来越高^[2]。巡航导弹作为一种高端的远程精确制导武器, 其可靠性的评估预测显得尤为重要。在美国, 空中发射的巡航导弹(air launched cruise missiles, ALCMs)和高级巡航导弹(advanced cruise missiles, ACMs)会定期进行维护, 试验和练习, 然后将试验结果记录下来用以评估预测导弹的可靠性^[3]。美国空军利用飞行试验结果和评估退化因子对当年巡航导弹的可靠性进行预测。他们最初使用的是简单的 Logistic 回归方法。由于每年的飞行试验很少, 导致可用的训练样本很小, 传统的统计方法无法有效地保证预测的准确率, 而通过引入衡量函数集性能的指标——VC 维^[3-4]和结构风险最小化原则(structural risk minimization, SRM)可以很好地解决小样本训练问题。

20 世纪 90 年代, 在 Vanpanik 等人不断地研究完善下, 机器学习领域一个新的理论体系——统计学习理论, 逐渐成熟, 并在此基础上提出了支持向量机^[4-5](support vector machine, SVM)。与传统方法相比, SVM 既克服了传统方法的大样本要求, 又克服了维数灾难及局部极小问题, 并在处理非线性问题时显示了其优越性, 已经在模式识别、回归估计、时间序列预测等多方面得到成功应用。因此, 笔者将 SVM 用于巡航导弹自由飞行阶段可靠性的评估预测问题中。

1 巡航导弹可靠性评估问题

巡航导弹的试验测试是分阶段进行的, 包括很多测试项目, 详见文献[3]。测试项目及结果举例见表 1。

表 1 中的测试项目很多, 如果利用所有的测试结果进行可靠性评估固然能够提高评估结果的准确性, 但是会增加计算量。因此, 在学习训练前要进行特征提取, 选择能够表征数据内在规律的一组特征, 并能够保证评估预测的准确性。经过特征提取,

收稿日期: 2011-07-25; 修回日期: 2011-08-26

作者简介: 薛继明(1971—), 男, 山西人, 硕士研究生, 高级工程师, 从事机器学习、人工智能研究。

得到所用的实验数据, 见表 2^[3]。其中, MIT, Level A 和 Prev Yr 是 3 种不同的测试, 其结果作为输入, Flt Test 是自由飞行阶段的可靠性评估, 作为训练时的期望输出。

表 1 典型的测试及结果举例

测试项目	通过次数	失败次数	测试总数	通过率/%
LLT Type A	167	15	182	92
LLT Type B	16	2	18	89
LPT Type A	230	8	238	97
LPT Type B	13	11	24	54
CSRL SIT	0	0	0	0
Pylon SIT	0	0	0	0
CSRL MIT	319	5	324	98
Pylon MIT	380	19	399	95
Level I Type A	159	50	209	76
Level I Type B	15	22	37	41
Level III Type B	0	0	0	0
INE	124	15	139	89
Auto-Cal				

表 2 训练学习所用数据 %

年份	ALCM 模型特征			目标值
	MIT	Level I A	Prev Yr	
1990	93.88	82.66	67.00	75.00
1991	96.84	81.87	75.00	75.00
1992	99.10	78.63	75.00	50.00
1993	98.18	79.57	50.00	67.00
1994	98.75	80.43	67.00	75.00
1995	96.84	81.22	75.00	50.00
1996	99.00	79.07	50.00	67.00
1997	97.96	78.05	67.00	75.00
1998	98.65	79.58	75.00	100.00
1999	97.67	73.49	100.00	100.00
2000	99.37	83.46	100.00	100.00
2001	99.21	71.10	100.00	75.00
2002	99.46	55.15	75.00	100.00

2 神经网络可靠性评估

Donald L. Hoffman 在文献[3]中利用神经网络对巡航导弹自由飞行阶段的可靠性进行了评估预测。他用到了 2 种网络—前馈神经网络和径向基神经网络, 并且将这 2 种网络得到的结果和 Logistic 网络得到的结果按照一定的比例进行了融合。

2.1 Logistic 网络

Logistic 回归方法的网络结构如图 1。




图 1 Logistic 回归网络结构

图 1 中 X_i 是输入样本的各个分量, 即模型各特

征的取值。首先各特征值加权求和得到 s , 然后再通过一个挤压函数 $\frac{1}{1+e^{-s}}$ 得到输出 z 。计算网络输出 z 与期望输出 T 之间的误差平方和, 并沿误差平方和的负梯度方向调整权值 w , 直到使误差平方和达到特定范围。

2.2 前馈神经网络

前馈神经网络在 Logistic 网络结构基础上的延伸, 它由 3 层网络构成, 增加了一层隐藏的神经节点。如图 2。

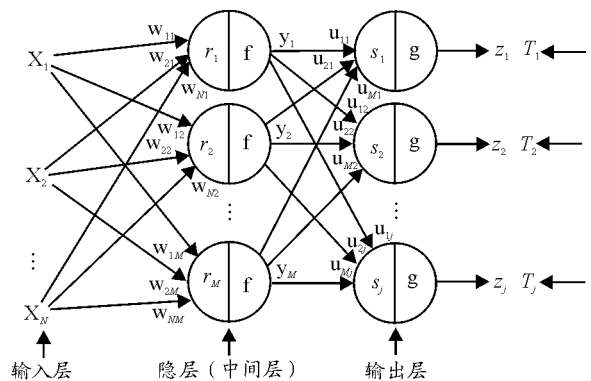


图 2 前馈神经网络结构

$$\text{图中 } r_m = \sum_{n=1}^N w_{nm} \cdot X_n, \quad y_m = f(r_m) = \frac{1}{1 + e^{-r_m}},$$

$s_j = \sum_{m=1}^M u_{mj} \cdot y_m, \quad z_j = g(s_j) = \frac{1}{1 + e^{-s_j}}$ 。该网络通过一种监督学习算法——BP 算法进行训练^[6]。

2.3 径向基神经网络

另一种经常用到的神经网络为径向基神经网络, 其结构如图 3。




图 3 径向基神经网络结构

$$\text{图中 } v = X, \quad y_m = \exp\left(\frac{-\|X - v_m\|^2}{2\sigma^2}\right), \quad z_j = \frac{\sum_{m=1}^M u_{mj} \cdot y_m}{M}。$$

径向基神经网络不同于 BP 网络, 除了各神经节点

的激发函数不同之外，它们在训练时权值的调整策略也不同。对于每个输入-输出对，BP 网络的所有权值都会进行相应的调整，而径向基网络只有部分权值进行调整，因此，径向基的训练速度要比 BP 网络快^[6]。

3 基于 SVM 的自由飞行阶段可靠性评估

SVM 方法是首先从解决分类问题(模式识别问题)发展起来的，SVM 回归是模式识别问题中得到的结果在回归情况下的推广。

3.1 ϵ -SVM 可靠性评估基本设计思路

对于巡航导弹测试得到的用于可靠性评估的训练数据：

$$(x_1, y_1), (x_2, y_2), \dots, (x_\ell, y_\ell) \in R^3 \times R$$

假设用线性函数 $f(x) = \langle w, x \rangle + b$ 来进行拟合，以评估导弹自由飞行的可靠性。其目标是使利用 $f(x)$ 得到的评估结果和实际结果 y_i 之间的误差不超过 ϵ ，同时尽可能使评估函数 $f(x)$ 平滑。一种实现方法是最小化准则函数 $\|w\|^2 = \langle w, w \rangle$ 。问题可表示成一个最优化问题：

$$\begin{aligned} \min \quad & \frac{1}{2} \|w\|^2 \\ \text{s.t.} \quad & \begin{cases} y_i - \langle w, x_i \rangle - b \leq \epsilon \\ \langle w, x_i \rangle + b - y_i \leq \epsilon \end{cases} \end{aligned} \quad (1)$$

注意式 (1) 的前提是该最优化问题的约束条件可行。但是，有时该前提并不成立，为了解决约束条件不可行的情况，引入松弛变量 ξ_i, ξ_i^* ，进而将该最优化问题表示为

$$\begin{aligned} \min \quad & \frac{1}{2} \|w\|^2 + C \sum_{i=1}^{\ell} (\xi_i + \xi_i^*) \\ \text{s.t.} \quad & \begin{cases} y_i - \langle w, x_i \rangle - b \leq \epsilon + \xi_i \\ \langle w, x_i \rangle + b - y_i \leq \epsilon + \xi_i^* \\ \xi_i, \xi_i^* \geq 0 \end{cases} \end{aligned} \quad (2)$$

其中常数 $C > 0$ 决定了 $f(x)$ 平滑性与允许误差之间的折衷。

为了对实值函数构造 SVM，采用一种新的损失函数类型，即 ϵ 不敏感损失函数 $|\xi|_\epsilon$ ^[7]，其形式为：

$$|\xi|_\epsilon = \begin{cases} 0 & |\xi| \leq \epsilon \\ |\xi| - \epsilon & \text{其他} \end{cases} \quad (3)$$

ϵ 不敏感损失函数描述的是这样的损失模型：

如果用 $f(x)$ 得到评估值和实际值之间的差别小于 ϵ ，则损失等于 0，尽管预测值与观测值可能并不完全相等。其中 ϵ 是事先取定的一个正数，如图 4。




图 4 线性函数的 ϵ 不敏感损失函数

3.2 求解对偶二次优化问题

笔者利用 Lagrange 方法求解前面的最优化问题。通过引入 Lagrange 函数，并对 Lagrange 函数求鞍点，可得最优化问题 (2) 的对偶问题^[7]：

$$\begin{aligned} \max \quad & \begin{cases} -\frac{1}{2} \sum_{i,j=1}^{\ell} (\alpha_i - \alpha_i^*)(\alpha_j - \alpha_j^*)(x_i \cdot x_j) \\ -\epsilon \sum_{i=1}^{\ell} (\alpha_i + \alpha_i^*) + \sum_{i=1}^{\ell} y_i (\alpha_i - \alpha_i^*) \end{cases} \\ \text{s.t.} \quad & \begin{cases} \sum_{i=1}^{\ell} (\alpha_i - \alpha_i^*) = 0 \\ \alpha_i, \alpha_i^* \in [0, C] \end{cases} \end{aligned} \quad (4)$$

求解得到权值：

$$w = \sum_{i=1}^{\ell} (\alpha_i - \alpha_i^*) x_i \quad (5)$$

从而判别函数为

$$f(x) = \langle w, x \rangle + b = \sum_{i=1}^{\ell} (\alpha_i - \alpha_i^*) \langle x_i, x \rangle + b \quad (6)$$

这里只有部分 α_i 或 α_i^* 大于 0，它们对应的样本就是支持向量。阈值 b 可以通过下式计算^[7]：

$$\begin{aligned} b &= y_i - \langle w, x_i \rangle - \epsilon, \alpha_i \in (0, C) \\ b &= y_i - \langle w, x_i \rangle + \epsilon, \alpha_i^* \in (0, C) \end{aligned} \quad (7)$$

3.3 核函数

上面的方法只适用于线性回归估计问题，但是巡航导弹可靠性评估问题并不是线性的，而是非线性的。支持向量机的方法是，将输入向量映射到一个高维特征向量空间，如果选用的映射函数适当且特征空间的维数足够高，则可将该非线性问题转化为线性问题，进而可在该特征空间构造最优超平面解决问题。将输入向量映射到高维特征空间的变换函数即为核函数。核函数对于 SVM 的构造是至关重要的，采用不同的核函数，可以构造实现输入空

间中不同类型的非线性决策面的学习机。

SVM 对核函数的要求是满足 Mercer 定理, 其选择有一定的自由度, 常用的核函数有以下 3 种:

1) 多项式核函数

$$K(X, X_i) = [\langle X, X_i \rangle + c]^q \quad (8)$$

该函数对应 SVM 的是一个 q 阶多项式分类器, 其中 q 可根据需要设置。

2) 高斯核函数

$$K(X, X_i) = \exp\left(-\frac{|X - X_i|^2}{2\sigma^2}\right) \quad (9)$$

高斯核函数具有良好的局部调节特性性质, 应用最为广泛, 其参数主要有中心向量和宽度系数^[8-9]。

3) Sigmoid 核函数

$$K(X, X_i) = \tanh(k \langle X, X_i \rangle + c) \quad (10)$$

与此对应的 SVM 实现的就是一个单隐层的感知器神经网络, 但是网络的权值、隐层节点数目都是由算法自动确定的。

核函数的选择需要一定的先验知识, 目前还没有一般性的结论, Scholkopf 等在文献[10]中就核函数的选择和构造作了讨论。一般而言, 高斯核函数应用最广, 因此, 笔者在导弹可靠性评估问题中使用了高斯核函数。

4 实验结果

4.1 神经网络得到的结果

利用不同的神经网络训练学习得到的拟合结果如图 5。





图 5 神经网络拟合结果


从图 5 中可以看到, 由于训练样本较少, 训练得到的网络在拟合时存在较大误差。

4.2 SVM 回归估计结果

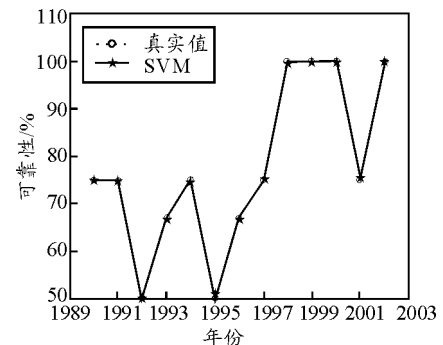
首先将 13 各样本全部用于训练, 核函数选用高斯核函数, 参数 σ 分别取 0.3, 0.2, 0.1, 得到的结果如图 6。



(a) 当 $\sigma = 0.3$ 时的拟合结果



(b) 当 $\sigma = 0.2$ 时的拟合结果




(c) 当 $\sigma = 0.1$ 时的拟合结果

图 6 所有样本用于训练所得拟合结果


从图 6 中可以看到, 随着核函数参数 σ 取值不同, 得到的拟合结果也不同, 只要 σ 的取值合适, 就可以达到很好的拟合结果。但是, 函数的拟合效果好并不代表其泛化能力强。

将样本分为 2 部分, 其中前 12 个样本作为训练样本集, 用以训练学习, 最后一个样本作为测试集, 用以检验 SVM 回归估计的泛化性能。得到的结果如图 7, 当 $\sigma = 1$ 时, 无论是 SVM 的拟合结果还是预测结果都存在较大的误差; 当 $\sigma = 0.1$ 时, SVM 的


拟合结果有所改善，但是预测误差仍然很大；当 $\sigma = 0.01$ 时，SVM 经训练后的拟合精度很高，而且具有较好的预测结果。



(a) 当 $\sigma = 1$ 时的拟合预测结果



(b) 当 $\sigma = 0.1$ 时的拟合预测结果



(c) 当 $\sigma = 0.01$ 时的拟合预测结果

图 7 训练拟合与预测结果

结果表明，核函数参数选择越合适，训练拟合的效果也越高，SVM 的泛化能力也随之提高，但泛化能力的提高是有限度的，经过实验发现核函数参数 σ 取 0.001 和取 0.01 得到的预测效果基本相同。

4.3 SVM 与神经网络可靠性评估对比结果

将文中提到的各神经网络方法得到的结果和 SVM 进行对比，这里核函数的参数 σ 取 0.3，实验结果如图 8。




图 8 对比结果

可以看到，SVM 的拟合效果最好，体现了 SVM 在小样本情况下的优势。虽然神经网络具有很强的自学习性和自组织性，但从某种意义上说神经网络是一种启发式的学习机，本身有很大的经验成分，需要大量的训练样本作为支撑。而基于统计学习理论的 SVM 算法，将回归问题巧妙的转化为二次规划问题来求解，在小样本情况下，算法的效率和精度都比较高。

5 结束语

实验结果表明：SVM 方法在评估效率和精度上都有改善，证明 SVM 在巡航导弹自由飞行阶段的可靠性评估问题上具有较好的应用价值。

参考文献：

- [1] 耿飞, 刘雨时. 基于马尔科夫过程的导弹贮存可靠性模型的研究[J]. 山东大学学报: 工学版, 2010, 40(1): 33.
- [2] 李根成, 姜同敏. 导弹战斗部任务可靠性评估方法分析[J]. 火炸药学报, 2006, 29(4): 6-13.
- [3] Donald L. Hoffman. Using Neural Networks for Estimating Cruise Missile Reliability[D]. Ohio: Air Force Institute of Technology, 2003.
- [4] Vapnik V. The Nature of Statistical Learning Theory[M]. New York: Springer, 1995.
- [5] Vapnik V. Statistical Learning Theory[M]. New York: John Wiley and Sons, 1998.
- [6] 韩力群. 人工神经网络教程[M]. 北京: 北京邮电大学出版社, 2006: 26-44.
- [7] Smola Alex J. and Schölkopf B. A Tutorial on Support Vector Regression[J]. Statistics and Computing, 2004, 14(3): 199-222.
- [8] 刘靖旭. 支持向量回归的模型选择及应用研究[D]. 长沙: 国防科学技术大学, 2006.
- [9] 褚蕾蕾, 陈绥阳, 周梦. 计算智能的数学基础[M]. 北京: 科学出版社, 2002.
- [10] Scholkopf B, Simard P, Smola A J. Prior Knowledge in Support Vector Kernels[C]. Advanced in Neural Information Processing Systems. MA: MIT Press, 1998: 640-646.