

基于在线支持向量机的无人机航路规划技术

李晓俊¹, 陈瑞²

(1. 海军装备部, 北京 100841; 2. 中国航空工业集团公司洛阳电光设备研究所, 河南 洛阳 471009)

摘要: 研究了一种基于在线支持向量机的无人机航路规划方法, 以保证无人机在完成任务时候能以最小的被发现概率以及最短航程安全到达目标点。首先建立多约束的无人机航路规划数学模型, 并进行分析。应用 A* 算法产生初始航迹获取样本数据, 在此基础上应用在线支持向量机具有在线训练、模型精确度高、需要样本少、泛化能力强等特点, 实现无人机航路优化。最后将所研究的方法应用于无人机的航路规划仿真, 仿真结果表明所研究的基于在线支持向量机的无人机航路规划方法是有效的。

关键词: 无人机; 航路规划; 在线支持向量机; A* 算法

中图分类号: V249 **文献标志码:** A **文章编号:** 1671-637X(2013)05-0044-05

Path Planning of UAVs Based on Online Support Vector Machine

LI Xiaojun¹, CHEN Rui²

(1. Navy Armament Department of PLA, Beijing 100841, China;

2. Luoyang Institute of Electro-Optical Equipment, AVIC, Luoyang 471009, China)

Abstract: A path planning method for Unmanned Aerial Vehicles (UAV) was proposed based on the online Support Vector Machine (SVM) to ensure UAVs reach the destination safely with the minimum probability of being found and through the shortest path. Firstly, the mathematic model was established and analyzed for the path planning of UAV considering the various constraints. The initial path was given by using A* algorithm to obtain the sample data for UAV. On the basis of the initial path, the online SVM, which has the features of online training, high precision model, small training sample and strong approximation ability, was employed to optimize the path of UAV. Finally, the path planning based on the online SVM was used to the simulation of path planning for UAV. The simulation results proved the effectiveness of the proposed method.

Key words: Unmanned Aerial Vehicle (UAV); path planning; online support vector machine; A* algorithm

0 引言

无人机航路规划就是在无人机初始位置、终止位置和一些目标任务节点确定之后的航路优化问题, 其基本功能是根据无人机性能和飞行的地理环境、威胁环境和政治条件等因素, 对已知或潜在的目标规划出若干条满足要求的航路, 实际飞行时可以根据需要进行实时局部修改得到最优航路^[1-3]。对于无人机来说, 一条好的飞

行航路既可以降低任务风险又可以降低任务成本。因此, 无人机航路规划技术一直是无人机领域的一个重要发展方向, 也是一个研究热点^[4-6]。

目前, 无人机航路规划方法包括经典规划有梯度法、样条插值法、非线性规划法、最优控制法、动态规划; 智能规划方法有图论、A* 搜索算法、神经网络法、模拟退火法以及群智能优化等算法。文献[7]采用遗传算法研究了低空突防无人机的航路规划问题, 并通过分析算法的收敛速度和精度表明遗传算法可以很快收敛到精度较高的近似解, 但在接近最优解到一定程度之后, 收敛速度会放慢; 文献[8]基于地形和威胁提出一种飞行器航路规划方法, 并将航路规划分为学习阶段和查询阶

段,在路线图中结合环境信息和飞行器的大部分约束,航路搜索在此路线图中进行并最终实现全部约束条件;文献[9-10]利用蚁群算法提出了适用于无人机航路规划的优化算法;文献[11-12]采用改进蚁群算法,实现了无人机的航路优化规划。

支持向量机作为一种以统计学习理论为基础,以结构风险最小化为原则而设计的学习机器,能较好地解决过学习、非线性、高维数、局部极小点等问题,并具有较好的泛化能力。支持向量机已从最初广泛应用于模式识别及函数回归等传统机器学习领域,推广到用以解决动态系统的辨识、建模、控制等问题,并取得了不错的效果^[13]。但对支持向量机来说,在小样本条件下模型参数取值缺少先验信息,搜索区间往往较大,且有多个参数需要优化进而使优化过程花费较多的时间。而在线支持向量机得到了广泛研究,在线学习方法能对每次迭代过程中增加的样本进行学习,利用前一次迭代的运算结果,减少计算复杂程度,实现在较短的时间内完成新样本学习^[13-14]。尽管在线支持向量机在控制与模型预测等领域得到较为广泛的应用,但还未见将其应用于无人机航路规划的报道,仍需深入研究以提高无人机航路规划效果。

本文根据无人机航路规划的油耗指标和威胁指标约束条件,建立无人机航路规划数学模型。在此基础上,利用在线支持向量机回归分析算法进行优化求解,该方法优化速度快,具有预测能力,对无人机来说是一种有效的航路规划方法。

1 航路规划数学模型的建立

通常来说,无人机的航路规划受到各种约束,包括无人机自身性能、地理环境、威胁环境等,因此其可转化为一个带约束的优化问题,进而使得无人机在沿规划所获得的航路飞行的代价最小且安全性最好。性能指标的好坏直接决定了航路的好坏,一般来说,根据具体任务的不同,无人机航路优化性能指标的参数选择也要有所不同。本文主要考虑了油耗指标和威胁指标。其中,油耗指标主要由无人机的飞行距离和飞行速度决定,而威胁指标主要考虑无人机与各威胁点之间的距离。因而,无人机航路规划的综合性能指标选为

$$\min W = k_1 W_f + k_2 W_t \quad (1)$$

式中: $k_1 > 0$ 和 $k_2 > 0$ 为加权因子,且有 $k_1 + k_2 = 1$; W_f 为油耗指标。为了研究方便,假设无人机在飞行中保持油耗率不变,则 W_f 与无人机航路的路程 L 成正比

$$W_f = c_1 \cdot L \quad (2)$$

式中, c_1 为比例因子。式(1)中, W_t 为无人机航路的威胁指标,它与无人机和威胁点之间的距离成反比

$$W_t = c_2 / d_{\min} \quad (3)$$

式中: c_2 为比例因子; d_{\min} 为航路上的每一点离最近威胁点之间的距离。

从式(1)~式(3)可以看出,无人机航路规划主要是在无人机初始位置、终止位置和一些目标任务节点确定之后,找出油耗代价最小和安全性最好的飞行航路。

2 基于在线支持向量机的无人机航路规划

本文把在线支持向量机引入到无人机航路规划过程中,利用在线支持向量机对无人机航路进行动态预测,并增强航路规划的快速性,从而对提高无人机航路规划性能具有重要意义。

2.1 在线支持向量机原理及实现

当支持向量机用于回归估计时,就是支持向量机回归。根据统计学习理论,可以构造出支持向量机的线性回归方程为^[14-15]

$$f(x) = \mathbf{w} \cdot \Phi(x) + b \quad (4)$$

式中:非线性映射 $\Phi(\cdot)$ 的作用是把数据 x 映射到高维特征空间 F ; \mathbf{w} 为在空间 F 中的特征向量; b 为偏置量。

假定一个数据集: $D = \{(x_i, y_i) | i = 1, 2, \dots, n\}$, $x_i \in R^N$ 为第 i 个样本的输入, $y_i \in R$ 为对应于第 i 个样本的期待输出, n 为训练样本数。为了表示样本偏离 ε 的程度,引入松弛变量 ξ_i 和 ξ_i^* ,则寻找最小 \mathbf{w} 的问题可以转化为如下凸优化问题^[13]

$$\min D = \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*) \quad (5)$$

其约束条件为

$$\begin{cases} y_i - (\mathbf{w} \cdot x_i) - b \leq \varepsilon + \xi_i \\ (\mathbf{w} \cdot x_i) + b - y_i \leq \varepsilon + \xi_i^* \\ \xi_i, \xi_i^* \geq 0 \end{cases} \quad (6)$$

式中: $i = 1, 2, \dots, n$; ε 为不敏感损失函数; C 为惩罚因子。

引入拉格朗日函数和对偶变量,则可得到优化问题的Lagrange函数为^[14]

$$\begin{aligned} L(\xi_i, \xi_i^*) = & \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*) - \sum_{i=1}^n \alpha_i (\varepsilon + \\ & \xi_i - y_i + \mathbf{w} \cdot x_i + b) - \sum_{i=1}^n \alpha_i^* (\varepsilon + \xi_i^* + y_i - \mathbf{w} \cdot x_i - \\ & b) - \sum_{i=1}^n (\eta_i \xi_i + \eta_i^* \xi_i^*) \end{aligned} \quad (7)$$

式中: $\alpha_i, \alpha_i^*, \eta_i, \eta_i^* \geq 0; C > 0$ 。

根据KKT(Karush-Kuhn-Tucker)条件^[13-14]可知, $L(\mathbf{w}, \xi_i, \xi_i^*)$ 对 $\alpha_i, \alpha_i^*, \xi_i, \xi_i^*$ 的偏导都应为零,因而有

$$\frac{\partial L}{\partial b} = \sum_{i=1}^n (\alpha_i^* - \alpha_i) = 0, 0 \leq \alpha_i, \alpha_i^* \leq C, i = 1, 2, \dots, n \quad (8)$$

$$\frac{\partial L}{\partial \mathbf{w}} = \mathbf{w} - \sum_{i=1}^n (\alpha_i - \alpha_i^*) x_i = 0 \Rightarrow \mathbf{w} = \sum_{i=1}^n (\alpha_i - \alpha_i^*) x_i$$

$$\frac{\partial L}{\partial \xi_i^{(*)}} = C - \alpha_i^{(*)} - \eta_i^{(*)} = 0 \Rightarrow C = \alpha_i^{(*)} + \eta_i^{(*)} \quad (9)$$

于是可得

$$L(\alpha_i, \alpha_i^*) = \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n (\alpha_i - \alpha_i^*)(\alpha_j - \alpha_j^*) K(x_i \cdot x_j) + \sum_{i=1}^n (\alpha_i + \alpha_i^*) \varepsilon - \sum_{i=1}^n y_i (\alpha_i - \alpha_i^*) \quad (10)$$

式中, $K(x_i \cdot x_j)$ 为支持向量机的核函数。

在式(8)的约束条件下,最小化式(10)可求得 α_i , α_i^* , 将其代入式(9)则可构造一个线性的回归函数为

$$f(x) = \sum_{i=1}^n (\alpha_i - \alpha_i^*) K(x_i, x) + b \quad (11)$$

定义系数偏差为 $\theta_i = \alpha_i - \alpha_i^*$, 第 i 个样本 x_i 的边界函数为 $h(x_i) = f(x_i) - y_i$, 则通过拉格朗日乘子和 KKT 条件, 训练数据可以被分为 3 个集合^[14]:

- 1) 错误支持向量集合 $E = \{i \mid |\theta_i| = C, |h(x_i)| \geq \varepsilon\}$;
- 2) 边界支持向量集合 $S = \{i \mid 0 < |\theta_i| < C, |h(x_i)| = \varepsilon\}$;
- 3) 剩余样本集合 $R = \{i \mid |\theta_i| = 0, |h(x_i)| \leq \varepsilon\}$ 。

上述 3 个集合的分布特征可用图 1 来表示。




图1 集合 S, E, R 的分布特征图

Fig. 1 Distribution characteristics of sets S, E and R

在线支持向量机算法主要由增量算法和减量算法两个部分构成^[13-14]。增量算法是将新样本 (x_i, y_i) 加入训练集中, 并逐步调整 θ_i 及偏置值 b , 直到新样本进入集合 S, E, R 中的任何一个; 而减量算法是通过逐步调整 θ_i 及偏置值 b , 使得需要去除的样本 θ_i 变为 0, 也使样本 (x_i, y_i) 移入保留样本集合 R 。算法的具体实现参考文献^[13]。从上述 3 个集合的定义可知, 一旦有新样本加入时, S 和 E 的边界就可发生改变。也就是在训练过程中, 因为新样本 x_i 的影响会逐步改变系数偏差 θ_i 和样本 x_i 的边界函数 $h(x_i)$, 从而使得原有的一些样本归属的集合也相应发生改变。

2.2 航路规划算法的步骤

为了充分利用在线支持向量机可在线训练、建模速度快、泛化能力强等优点, 所研究的无人机航路规划算法的具体步骤如下。

- 1) 在线支持向量机数据样本的选取。

在无人机航路规划中, 样本的选取很重要, 只有合理选择样本才能得到优化的无人机航路。选取的样本 $D = \{(X_i, Y_i)\}, i = 1, 2, \dots, n$, 包括样本的规模 n 和样本的指标值 (X_i, Y_i) , 样本的规模 n 在本文中具体指无人机航路的条数。

- 2) 在线支持向量机数据样本的处理。

一般可把样本分成两部分, 一部分为训练样本, 另一部分为测试样本。本文采用数据滑动构造 M 个不同的训练样本及 N 个不同的测试样本, 充分利用给定的样本数据分别对预测优化得到的无人航路进行测试, 以检验结果的有效性。本文的航路规划样本数据通过较成熟的 A^* 算法得到, A^* 算法在此不再详述, 可参见相关文献。

- 3) 航路规划过程。

基于在线支持向量机的无人机航路规划算法具体描述如下。

① 获取无人机的起点和终点, 以及无人机所面临的威胁。

② 利用 A^* 算法规划无人机初始化航路。

③ 基于无人机初始航路, 构建在线支持向量机的训练集 $\{(x_i, y_i) \mid i = 1, 2, \dots, M\}$, M 为训练样本数。

④ 利用在线支持向量机的增量算法优化训练无人机航路规划的数学模型, 具体算法如下:

Step 1 置 $\theta_c = 0$;

Step 2 计算 $h(x_c)$, 如果 $|h(x_c)| < \varepsilon$, 转 Step 3, 否则转 Step 4;

Step 3 将新样本加入集合 R , 算法结束;

Step 4 计算 $h(x_i), i = 1, 2, \dots, l, l$ 为样本总数;

Step 5 更新 $\Delta\theta_c$ 计算参数;

Step 6 求出新样本加入 S 、新样本加入 E 造成的 $\Delta\theta_c$ 值, 以及 3 种原样本移动方式中各自造成 $\Delta\theta_c$ 最小的样本移动对象和相应的 $\Delta\theta_c$ 值, 对于 $E \rightarrow S$ 和 $R \rightarrow S$ 这 2 种移动方式, 如果最小的 $\Delta\theta_c$ 值为 0, 则取 $\Delta\theta_c$ 次小的样本进行移动;

Step 7 求出 5 种样本移动方式中最小的 $\Delta\theta_c$ 值, 确定移动方式和移动的样本;

Step 8 更新 $b, \theta_c, \theta_i, i = 1, 2, \dots, l$ 及 $h(x_i), i \in E \cup R$;

Step 9 样本移动, 如果新样本进入 S 或 E , 算法结束, 否则转 Step 5。

⑤ 当训练样本的数量大于设定值 N 时, 利用减量算法删除冗余的训练样本。具体算法如下:

Step 1 如果 $\{x_c, y_c\} \in R$, 将 $\{x_c, y_c\}$ 移出训练集, 否则, 转 Step 2;

Step 2 将 $\{x_c, y_c\}$ 从 S 或 E 中移出;

Step 3 计算 $h(x_i), i=1, 2, \dots, l, l$ 为样本总数;

Step 4 更新 $\Delta\theta_c$ 计算参数;

Step 5 求 $\{x_c, y_c\}$ 加入 R 造成的 $\Delta\theta_c$ 值, 以及3种样本移动方式中各自造成 $\Delta\theta_c$ 最小的样本移动对象和相应的 $\Delta\theta_c$ 值, 对于 $E \rightarrow S$ 和 $R \rightarrow S$ 这2种移动方式, 若最小的 $\Delta\theta_c$ 值为0, 则取 $\Delta\theta_c$ 次小的样本进行移动;

Step 6 求出4种样本移动方式中最小的 $\Delta\theta_c$ 值, 确定移动方式和移动的样本;

Step 7 更新 $b, \theta_c, \theta_i, i=1, 2, \dots, l$ 及 $h(x_i), i \in E \cup R$;

Step 8 样本移动, 如果 $\{x_c, y_c\}$ 进入 R , 将其从训练样本集中删除, 算法结束, 否则转 Step 4。

⑥ 把训练后的模型用于无人机航路预测, 如果加入一个新样本 (x_n, y_n) , 则定义预测误差 $E = y'_n - y_n$, 如果预测误差 E 小于设定值 E_0 , 训练结束, 转到⑦, 否则转到②。

⑦ 用训练后的模型预测无人机的规划航路。

⑧ 如果样本个数 $n \geq N1 (N1 = N + M)$, 转到⑨; 否则, 转到④。

⑨ 输出无人机规划航路。

综上所述, 基于在线支持向量机的无人机航路规划算法具体流程如图2所示。

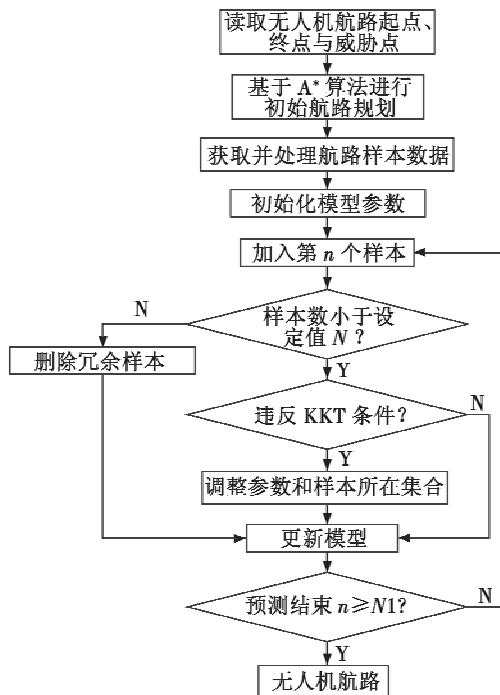


图2 基于在线支持向量机的无人机航路规划算法流程

Fig. 2 Flow chart of path planning algorithm based on online SVM for UAVs

3 仿真实例

主要通过仿真来验证本文所研究的基于在线支持

向量机的航路规划技术的有效性, 航路规划初始任务区如图3所示。




图3 初始化地图

Fig. 3 The initialized map

航路长度1000 m, 最大偏航宽度左右各250 m, 坐标系中, 横轴为航向长度, 纵向为偏航长度, 将区域中横向 $m = 50$ 等分, 纵向 $n = 20$ 等分, 途中标定点为航路点, 其中危险区域内的点为不可行点, 其他各点为可行点, 起点为 $A(0, 0)$, 终点为 $B(1000, 0)$, 危险区域在实际飞行区域既可为地形威胁也可为雷达等威胁, 本文中定义4个威胁区域, 并简化危险区域为半径不等的圆域, 危险区域的中心及半径分别为: $DA1 = (450, 100); R1 = 115; DA2 = (580, -125); R2 = 100; DA3 = (700, 25); R3 = 50; DA4 = (900, 75); R4 = 25$ (单位: m)。

首先, 按 A^* 算法进行无人机初始航路规划, 以获取在线支持向量机的训练样本和测试样本。在此基础上, 利用本文所研究的在线支持向量机的航路规划技术对产生的无人机航路进行优化, 所得到的优化规划结果如图4所示。

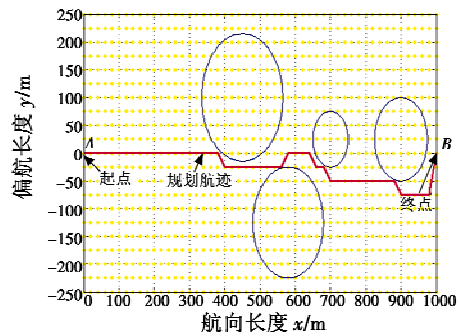


图4 基于在线支持向量机的航路规划图

Fig. 4 Path planning result of UAVs based on online SVM

仿真结果显示, 利用基于在线支持向量机的航路规划方法, 可以有效地解决无人机航路规划问题, 对实际应用有较好的适应性。在线支持向量机由于具有在线训练、模型精确度高、需要样本少、泛化能力强等特点, 对无人机航路有预测优化的能力, 这与未来战场对无人机的要求是相符的, 因而采用在线支持向量机对无人机的航路进行规划具有重要的意义。

4 结 论

本文研究了一种基于在线支持向量机的无人机航路规划方法。通过 A* 算法产生初始航迹, 获取在线支持向量机的样本, 从而以多约束的无人机航路规划数学模型进行无人机航路规划, 保证无人机在完成任务的时候, 能以最小的被发现概率以及最短航程安全到达目标点。仿真结果表明, 在考虑无人机性能约束的条件下, 利用基于在线支持向量机航路规划方法所得到的航路能有效地避开威胁。

参 考 文 献

- [1] 柳长安, 王和平, 李为吉. 无人机的侦察航路规划[J]. 西北工业大学学报, 2003, 21(4): 490-494.
- [2] BORTOFF S A. Path planning for UAVs[C]//Proceeding of the American Control Conference, 2000: 364-368.
- [3] 冯琦, 周德云. 飞行器三维航迹规划算法[J]. 弹箭与制导学报, 2004, 24(4): 85-87.
- [4] YOSHIKI K, HOW J. Three dimensional receding horizon control for UAVs [C]//AIAA Guidance, Navigation, and Control Conference and Exhibit, Providence RI, USA, 2004: 1-14.
- [5] DORIGO M, MANIEZZO V, COLORNI A. Ant system: Optimization by a colony of cooperating agents [J]. IEEE Transactions on Systems, Man and Cybernetics, Part B, 1996, 26(1): 29-41.
- [6] 马向玲, 叶文, 范洪达. 飞机航路规划决策系统研究与开发[J]. 电光与控制, 2004, 11(2): 65-67.
- [7] 马云红, 周德云. 基于遗传算法的无人机航路规划[J]. 电光与控制, 2005, 12(5): 24-27.
- [8] 严平, 叶利民, 张可佳. 一种可实现 TF/TA ~ 2 的无人飞行器三维航迹规划方法[J]. 海军工程大学学报, 2004, 16(1): 5-8.
- [9] 柳长安, 李为吉, 王和平. 基于蚁群算法的无人机航路规划[J]. 空军工程大学学报: 自然科学版, 2004, 5(2): 9-12.
- [10] 白俊强, 柳长安. 基于蚁群算法的无人机航路规划[J]. 飞行力学, 2005, 23(2): 35-38.
- [11] 陈谋, 肖剑, 姜长生. 基于改进蚁群算法的无人机三维航路规划[J]. 吉林大学学报: 工学版, 2008, 38(4): 991-995.
- [12] 叶文, 范洪达. 基于改进蚁群算法的飞机低空突防航路规划[J]. 飞行力学, 2004, 22(3): 36-38.
- [13] 潘以桢, 胡越明. 改进的在线支持向量机训练算法[J]. 计算机工程, 2009, 35(22): 212-215.
- [14] 陈进东, 潘丰. 基于在线支持向量机的非线性内模控制[J]. 计算机工程与应用, 2009, 45(9): 18-20.
- [9] CRIMALDI J P, BRITT R T, RODDEN W P. Response of B-2 aircraft to nonuniform spanwise turbulence[J]. Journal of Aircraft, 1993, 30(5): 652-659.
- [10] CAMP D W, CAMPBELL W, DOW C. Visualization of gust gradients and aircraft response as measured by the NASA B-57B aircraft [C]//Proceedings of the 22nd AIAA Aerospace Sciences Meeting, USA, 1984: 1-4.
- [11] ETKIN B. Turbulent wind and its effect on flight [J]. Journal of Aircraft 1981, 18(5): 327-345.
- [12] GAO Zhenxing, GU Hongbin. Generation and application of spatial atmospheric turbulence field in flight simulation [J]. Chinese Journal of Aeronautics, 2009, 22(1): 9-17.
- [13] 鲁道夫·布罗克豪斯. 飞行控制[M]. 金长江, 译. 北京: 国防工业出版社, 1999: 68-71.
- [14] 仇江, 王鑫怡, 高亚奎, 等. 基于自然飞机的超低空重装空投特性分析[J]. 系统仿真学报, 2012, 24(4): 933-937.
- [15] 肖业伦, 金长江. 大气扰动中的飞行原理[M]. 北京: 国防工业出版社, 1993: 47-72.
- [16] REID L D, ROBINSON P A. The modeling of turbulence and downbursts for flight simulators[J]. Journal of Aircraft, 1990, 27(8): 700-707.
- [17] 乐挺, 王立新, 况龙. 农林飞机近地作业飞行的纵向稳定特性[J]. 北京航空航天大学学报, 2008, 34(6): 634-642.
- [18] BOSCHETTI P J, CARDENAS E M, AMERIO A. Stability and performance of a light unmanned airplane in ground effect[J]. Proceeding of the 48th AIAA Aerospace Sciences Meeting, 2010: 1-17.

欢迎投稿 网址: <http://www.dgykz.com>