

引用格式:陈侠,艾宇迪.应用改进神经网络的无人机三维航迹规划[J].电光与控制,2018,25(9):7-11.CHEN X, AI Y D. Application of improved neural network in 3D path planning of UAVs[J]. Electronics Optics & Control, 2018, 25(9):7-11.

应用改进神经网络的无人机三维航迹规划

陈 侠, 艾宇迪

(沈阳航空航天大学自动化学院,沈阳 110136)

摘要: 针对无人机的航迹规划问题,提出了并联神经网络结构与动态可调步长策略相结合的三维航迹规划方法。首先根据与威胁之间的距离采取不同策略:当无人机处于威胁区域外,采取基准步长为大步长的策略,实现快速生成航迹的目的;当无人机处于威胁区域内,采取可调步长的策略,实现航迹的精细搜索。然后构建障碍物惩罚函数的神经网络和航迹的能量函数,将梯度下降法与牛顿下山法相结合,建立航迹的运动方程,依据不同的航迹点,采用自适应学习因子不同的学习率,实现快速脱离威胁。仿真结果表明,所提算法不仅能保证无人机安全绕开威胁,同时也提高了算法的收敛速度。

关键词: 无人机; 航迹规划; 神经网络; 自适应学习因子; 可调步长

中图分类号: V279; TP391.9

文献标志码: A

doi:10.3969/j.issn.1671-637X.2018.09.002

Application of Improved Neural Network in 3D Path Planning of UAVs

CHEN Xia, AI Yu-di

(School of Automation, Shenyang Aerospace University, Shenyang 110136, China)

Abstract: Aiming at the problem of UAV path planning, a 3D path planning method is proposed based on the parallel neural network structure and the dynamic adjustable step size strategy. Firstly, different strategies are adopted according to the distance between the UAV and the threat. When the UAV is outside the risk area, the method of taking large steps is adopted to achieve the purpose of rapid generation of the path. When the UAV is inside the risk area, the method of taking the adjustable step is used to achieve the fine search of the path. Then, the neural network of the obstacle's penalty function and the energy function of the path are constructed. By combining the gradient descent method with the Newton Downhill Method, the motion equation of the path is established. According to different path points, learning rates with different adaptive learning factors are used to realize rapid escaping from the threats. The simulation results show that the proposed algorithm not only guarantees the safety of UAV to bypass the threat, but also improves the convergence speed of the algorithm.

Key words: Unmanned Aerial Vehicle (UAV); path planning; neural network; adaptive learning factor; adjustable step size

0 引言

无人机航迹规划作为任务规划系统的关键组成部分,不仅是提高作战效能、实施远程精确打击的有效手段,也是实现自主控制的重要基础。近年来,国内外专

收稿日期:2017-08-23 修回日期:2018-07-31
基金项目:国家自然科学基金(61074159);沈阳科技资助项目(14042200,14231129)
作者简介:陈 侠(1962—),女,辽宁新民人,博士,教授,硕导,研究方向为无人机任务规划。

家学者在无人机航迹规划方面已经取得了许多研究成果。常用的智能优化算法包括A*算法^[1]、稀疏A*算法^[2]、D*算法^[3]、Dijkstra算法^[4]和动态规划方法^[5]等,这些算法在寻找轨迹上能找到一个最优解,但计算时间会随着代价模型的增大呈现爆炸式的增长^[6]。为了优化算法的计算时间,国内外专家学者也研究了许多启发式智能算法,如遗传算法^[7]、蚁群算法^[8]、模拟退火算法^[9]、粒子群算法^[10]等。除了以上这些比较常用算法以外,有关学者也一直在积极尝试一些新的有效方法,使航迹规划技术不断得到改进和提高。如文献[11]针对

无人机三维实时航迹规划问题,提出了一种根据与威胁的距离而动态调整搜索步长的策略,成功规避了威胁,实现了实时规划,并验证了该方法的有效性等。虽然目前关于航迹规划启发式算法的研究取得了一些研究进展,这些启发式算法在寻找最优解时,与传统智能优化算法相比,在一定程度上加快了收敛速度,但在实际空战环境中,随着战场环境的日趋多样化,为了提高无人机的作战效能,如何快速生成有效的航迹规划问题仍然是目前无人机技术的重要研究课题。

神经网络具有高度的输入/输出非线性映射能力、较好的自组织学习能力以及鲁棒性能等优点,所以已被广泛应用于函数逼近、曲线拟合、图像处理、信号处理、控制子系统、系统辨识、故障诊断与预测等工程领域。目前,关于基于神经网络的航迹规划研究已经引起了学者专家的高度重视^[12~14]。文献[12~13]将算法参数连接权通过地形信息反映出来,将无人机约束条件与扩展的 Hopfield 模型相结合,给出了基于 Hopfield 神经网络的无人机二维和三维航迹规划方法;文献[14]解决了移动机器人的全局路径规划问题,利用神经网络结构,通过将神经网络结构与模拟退火算法相结合,寻找出无碰路径,避免了路径规划中出现局部极值的问题,并规划出一条最短无碰且安全的平滑路径。然而,目前基于神经网络的航迹规划研究尚处于探索阶段,研究成果不多见。到目前为止,无论是传统的智能优化算法、启发式智能算法,还是近些年兴起的基于神经网络的航迹规划方法中,均采用逐点发散搜索方式寻找下一步可行的航迹点。虽然这种搜索方式可以规划出满足约束条件的航迹,但在过程中,往往会出现搜索范围较大、搜索节点很多等问题,使得算法计算时间可能会较长,不能满足日趋复杂的航迹规划要求。本文针对三维航迹规划问题,首先生成起始点到目标点的初始航迹,根据无人机与威胁区域之间的距离,当无人机在威胁区域外时,采取基准步长为大步长的策略,避免无人机由于航迹点过多造成姿态切换频繁不利于飞行,实现快速生成航迹的目的。当无人机在威胁区域内时,采取可调步长的策略,实现在威胁区域内对航迹的精细搜索,保障无人机的安全性,进而形成了待调整的航迹点,避免了发散式搜索范围较大的不足。然后采用神经网络结构对初始航迹点进行调整,构建关于障碍物惩罚函数的神经网络和航迹的能量函数,将梯度下降法和牛顿下山法相结合,建立航迹的运动方程,进一步通过引入自适应的学习因子,依据不同威胁范围的航迹点,采用不同的学习率,实现最快速度脱离威胁。通过仿真验证表明,该算法能够安全绕开威胁,加快了整体航迹的收敛速度,最终得到较优的航迹。

1 航迹规划的模型建立

1.1 无人机约束条件

1) 最大航程代价。

由于无人机在执行任务时,受到自身电力的约束,所以有着固定的最大航程。设第 i 段航程为 L_i ,共有 n 段路径,最大航程为 L_{\max} ,则 $\sum_{i=1}^n L_i \leq L_{\max}$ 。

2) 步长代价。

由于步长过小或过大都会对系统造成很大的影响,步长过小,会使整个系统收敛速度降低容易造成冗余,而步长过大,整个系统精度降低,易出现早熟情况,所以要对步长进行限制。设步长为 S 、最小步长为 S_{\min} 、最大步长为 S_{\max} ,则 $S \in [S_{\min}, S_{\max}]$ 。

3) 最低飞行高度代价。

无人机在飞行时,应与地面保持一定的距离。若飞行高度过低,有可能对无人机造成损坏。设最低飞行高度为 H_{\min} ,第 i 段航迹飞行高度为 H_i ,则 $H_i \geq H_{\min}$ 。

1.2 雷达威胁模型

在航迹规划中,雷达威胁代价是一个重要环节。无人机在执行任务时主要受到探测设备对其造成的威胁。为避免雷达威胁建立雷达模型,无人机进入雷达威胁区内时被发现的概率 p 可表示为

$$p = \frac{R^4}{R^4 + R_{\max}^4} \quad (1)$$

式中: R 为无人机与雷达之间的距离; R_{\max} 为雷达所能检测的最大距离。

1.3 动态步长的航迹初始化

以初始点到目标之间的连线作为初始路径。为了安全规避威胁,采用动态可调步长的策略来选取航迹点,若航迹点选取过多,会使整个系统收敛过慢,航迹点过少,易出现早熟现象。根据文献[11],本文采用可变换的步长来选取航迹点,可调步长方法表示为

$$s(d) = \begin{cases} (1 + k \cdot \ln(d/d_{\text{safe}})) * S & d \leq d_{\text{safe}} \\ S & d > d_{\text{safe}} \end{cases} \quad (2)$$

式中: d_{safe} 表示航迹点与威胁的最大安全距离; d 表示航迹点与威胁源中心 (x_0, y_0, z_0) 之间的距离, $d \leq \sqrt{(x - x_0)^2 + (y - y_0)^2 + (z - z_0)^2}$; S 表示一条航迹在自由空间所设定的步长,即基准步长; k 为步长调节幅度。当无人机初始航迹点处于安全位置时,会以基准步长正常前进,若航迹点落在威胁范围内时,则会根据航迹点与威胁源之间的欧氏距离来调节步长,当航迹点距威胁源中心越近时,步长也就越小,以保证精细搜索,使无人机更好地避开威胁,避免了早熟现象。若距离威胁源中心距离较大时,步长也相对较大,以防止冗

余,避免无人机由于航迹点过多造成姿态切换频繁,不利于飞行。

2 基于改进神经网络的航迹规划方法

2.1 网络模型

本文采用神经网络结构对初始航迹点进行调整,构建障碍物惩罚函数的神经网络和整条航迹的能量函数,为建立航迹的运动方程奠定基础。

某航迹点的惩罚函数网络结构如图 1 所示。

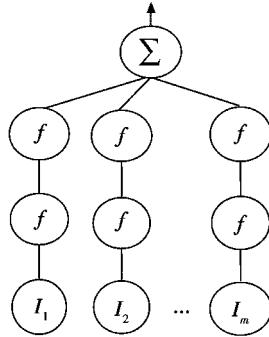


图 1 某航迹点的惩罚函数的网络结构

Fig. 1 The network structure of the penalty function of a track point

由图 1 可知,该网络共有 4 层、输入层有 k 个、输出层为 1 个无互连的网络结构。其中,网络的第一层为输入层,其表达式为

$$I_k = R_k^2 - (x_i - P_k)^2 - (y_i - Q_k)^2 - (z_i - J_k)^2 \quad (3)$$

式中: (x_i, y_i, z_i) 为第 i 个航迹点的坐标; m 为威胁源的个数; R_k 为第 k 个威胁的半径; (P_k, Q_k, J_k) 为第 k 个威胁的圆心坐标,即将第 i 个航迹点与威胁源中心的欧氏距离平方与威胁源半径平方的差值作为输入。

网络的第二层为第一隐含层,输入层与该层连接的权值均为 1、阈值均为 0,表达式为

$$O_k = f(I_k) \quad (4)$$

其中,第一隐含层的激活函数为普遍使用的 Sigmoid 函数,可以表达为

$$f(x) = \frac{1}{1 + e^{-x}} \quad (5)$$

由于 Sigmoid 函数是对输入在 0 到 1 上产生的映射,则该层的输出将在 0 到 1 之间变化,反映了第 i 个航迹点对应的威胁程度,输出越大,即离威胁越近,输出越小,即离威胁越远。

网络的第三层为第二隐含层,第二层与该层连接的权值均为 1,阈值 θ 均为 $-0.5^{[15]}$,表达式为

$$T_k = f(O_k + \theta) \quad (6)$$

第三层的激活函数同样为 Sigmoid 函数,其表示了第 i 个航迹点对应第 k 个威胁的惩罚函数。

网络的第四层为输出层,第三层与该层连接的权

值均为 1,阈值为 0,激活函数为线性函数,表示了第 i 个航迹点对所有威胁的惩罚函数之和,其表达式为

$$C = \sum_{k=1}^m T_k \quad (7)$$

整条航迹的威胁能量函数为

$$E_c = \sum_{i=1}^N C_i \quad (8)$$

式中, N 为航迹点个数。

在航迹规划中,避开威胁与路径最短是最主要的两个关键问题,同样对路径长度构造能量函数,路径长度的能量函数可以定义为每段航迹长度的平方之和。整条航迹的长度能量函数为

$$E_l = \sum_{i=1}^{N-1} [(x_{i+1} - x_i)^2 + (y_{i+1} - y_i)^2 + (z_{i+1} - z_i)^2] \quad (9)$$

则整条航迹的能量函数为

$$E = u_l E_l + u_c E_c \quad (10)$$

式中: u_c 代表威胁权重,即雷达模型威胁概率; u_l 表示航迹长度权重,满足

$$u_l = 1 - u_c \quad u_l > 0, u_c > 0 \quad (11)$$

2.2 运动方程的建立

从上述网络结构可知,当无人机距离威胁范围越远,即 E_c 越小,同时整个路径长度越短,即 E_l 越小,则整条航迹的能量函数越小,即 E 越小。因此,构建关于能量函数 E 的运动方程,使航迹点朝着能量小的方向移动,可以找到所需的轨迹,采用梯度下降法,不断对输入进行调节,进而构建运动方程。

在建立运动方程之前,分析航迹点所在位置,并判断是否在威胁范围内,当航迹点在威胁范围内,则该航迹的能量函数 E 是由威胁能量函数 E_c 和长度能量函数 E_l 两部分构成。若航迹点没有在威胁范围内,则能量函数 E 只包含长度能量函数 E_l 。

当航迹点在威胁范围内时,对航迹点进行分析,将航迹点落在威胁的位置进行记录,引入自适应学习因子 α_k ,其算式为

$$\alpha_k = \begin{cases} \frac{1}{1 + e^{-(r_i - v_i)^2}} & i \in D_k \\ 0 & i \notin D_k \end{cases} \quad (12)$$

式中: r_i 为第 i 个航迹点距离威胁中心的距离; v_i 为第 i 个航迹点脱离威胁范围的最小距离; D_k 表示第 k 个威胁的范围。当 r_i 与 v_i 的差值越小时,则 α_k 越小; 当 r_i 与 v_i 的差值越大时,则 α_k 越大,即当航迹点距离威胁范围越近,自适应学习因子 α_k 越大,使航迹点越快远离威胁。

为了加快整个过程的收敛速度与鲁棒性,根据牛顿下山法,构造运动方程,牛顿迭代格式表示为

$$x_{n+1} = x_n - \lambda \frac{f(x_n)}{f'(x_n)} \quad (13)$$

式中, λ 为下山因子。因此得到了航迹点在威胁范围内时的运动方程为(由于本文模型中二阶导项数值较小,故对方程进行简化)

$$\begin{cases} \dot{x}_i = -\lambda [\eta \cdot u_t (2x_i - x_{i-1} - x_{i+1}) + u_c \sum_{k=1}^n \alpha_k f'[(O_k + \theta)_i] \cdot \\ f'[(I_k)_i] (P^k - x_i)] / [2\eta \cdot u_t - u_c \sum_{k=1}^n \alpha_k f'[(O_k + \theta)_i] \cdot \\ f'[(I_k)_i]] \\ \dot{y}_i = -\lambda [\eta \cdot u_t (2y_i - y_{i-1} - y_{i+1}) + u_c \sum_{k=1}^n \alpha_k f'[(O_k + \theta)_i] \cdot \\ f'[(I_k)_i] (Q^k - y_i)] / [2\eta \cdot u_t - u_c \sum_{k=1}^n \alpha_k f'[(O_k + \theta)_i] \cdot \\ f'[(I_k)_i]] \\ \dot{z}_i = -\lambda [\eta \cdot u_t (2z_i - z_{i-1} - z_{i+1}) + u_c \sum_{k=1}^n \alpha_k f'[(O_k + \theta)_i] \cdot \\ f'[(I_k)_i] (J^k - z_i)] / [2\eta \cdot u_t - u_c \sum_{k=1}^n \alpha_k f'[(O_k + \theta)_i] \cdot \\ f'[(I_k)_i]] \end{cases} \quad (14)$$

当航迹点没在威胁范围内时,通过 E 为时间求导,得到的运动方程为

$$\begin{cases} \dot{x}_i = -\eta [2u_t (2x_i - x_{i-1} - x_{i+1})] \\ \dot{y}_i = -\eta [2u_t (2y_i - y_{i-1} - y_{i+1})] \\ \dot{z}_i = -\eta [2u_t (2z_i - z_{i-1} - z_{i+1})] \end{cases} \quad (15)$$

式中, η 为正数。

该算法对航迹点是否在威胁范围内进行了分析,构建两种运动方程,又对在威胁范围内的点进行了细化,航迹点对不同威胁范围有着不同的学习率,使航迹点较快速地脱离该威胁,并且加快了整体的收敛速度与鲁棒性,最终得到较优航迹。

3 算例仿真

为了验证改进神经网络算法的可行性,在 Matlab2013a 环境下,进行了仿真实验,在 $25 \text{ km} \times 25 \text{ km} \times 25 \text{ km}$ 的战场中,最低飞行高度为 0.5 km 。威胁模型为半球型,初始点 S 为 $(3 \text{ km}, 19 \text{ km}, 0 \text{ km})$,目标点 T 为 $(16 \text{ km}, 10 \text{ km}, 2 \text{ km})$,参数 $\eta = 0.6, k = 1, \lambda = 0.5$ 。

首先对初始步长进行分析,分别采取可调步长与固定步长两种方法对一个较大范围的威胁区域进行了仿真,其中,基准步长为初始点到目标 $1/10$ 。

图 2 和图 3 分别为固定步长和可调步长的路径规划。

从图 2 可以看出,虽然通过神经网络算法调整后的航迹点均在威胁范围外,但由于基准步长较大,则航迹点之间的连线仍处于威胁范围之内,并没有完全避开威胁。

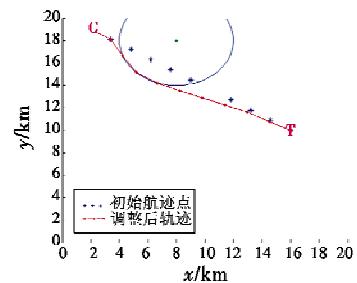


图 2 固定步长的路径规划

Fig. 2 Fixed-step-size path planning

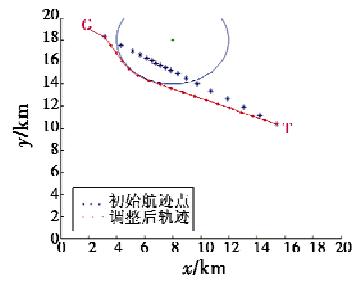


图 3 可调步长的路径规划

Fig. 3 Adjustable-step-size path planning

从图 3 可以看出,采用可调步长方法调整后的轨迹完全避开了威胁。

构建包含多个威胁区域的一个三维环境战场,以初始点到目标的 $1/20$ 为基准步长进行了仿真,结果如图 4 ~ 图 6 所示。

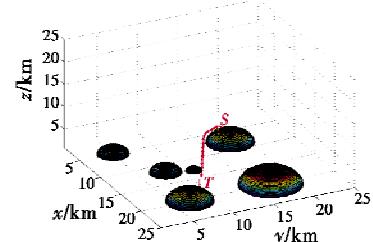


图 4 基于神经网络的三维航迹规划

Fig. 4 3D path planning based on neural network

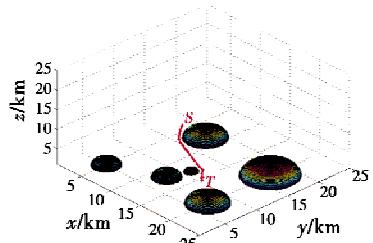


图 5 基于改进神经网络的三维航迹规划

Fig. 5 3D path planning based on improved neural network

在基于神经网络的航迹规划算法中,最短航迹近似为 17.14 km ,收敛次数约为 100,收敛范围约为 0.15 ;而在基于改进神经网络的航迹规划算法中,最短航迹近似

为 16.48 km, 收敛范围约为 0.05, 收敛次数约为 30。基于改进神经网络的三维航迹规划采取了以下 3 种方式对图 4 原算法进行了改进:1) 通过分析航迹点所在威胁范围的位置, 引入了自适应学习因子, 对处在不同威胁范围的航迹点采用不同的学习率, 实现最快速度脱离威胁, 加快了收敛速度, 收敛次数变少;2) 依据式(2)和式(12), 根据与威胁之间的距离, 计算出的自适应值 u_i 和 u_e 为实时动态值, 并非固定值, 当距离威胁越远时, 即 u_e 越来越小, 则路径长度的权值 u_i 将越来越大, 可以得到一个更理想的航迹能量函数;3) 引入牛顿下山法, 构造新的迭代格式, 使整体的收敛范围较小, 并加快收敛速度。因此, 基于改进神经网络的三维航迹规划算法能够实现安全绕开威胁, 并加快了航迹的整体收敛速度。

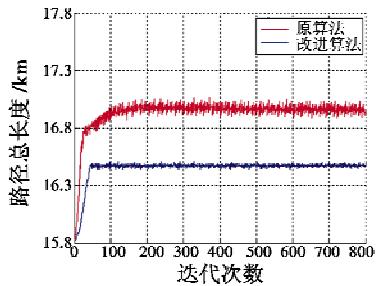


图 6 基于神经网络的路径长度与迭代曲线

Fig. 6 Path length and iteration curve
based on neural network

4 结论

本文针对三维环境下的航迹规划问题进行了研究, 利用动态步长对初始航迹点进行调整, 有效地降低了威胁程度, 然后再与改进后的神经网络相结合, 给出了无人机三维航迹规划方法。仿真结果证明, 基于改进神经网络的三维航迹规划算法能够实现安全绕开威胁, 并加快了航迹的整体收敛速度。但本文只是利用雷达模型构建了威胁环境, 对于其他威胁模型并未涉及。为了使无人机更好地适应作战环境, 如何在基于改进神经网络的三维航迹规划算法中考虑多威胁模型共存的航迹规划, 将是未来需要深入研究的问题。

参 考 文 献

- [1] 张得舒, 黄长强, 丁达理, 等. 基于 A* 算法的无人机攻击轨迹解算 [J]. 电光与控制, 2011, 18(3):18-20, 65.
- [2] 姚远, 周兴社, 张凯龙, 等. 基于稀疏 A* 搜索和改进人工势场的无人机动态航迹规划 [J]. 控制理论与应用, 2010, 27(7):953-959.
- [3] 陈侠, 刘冬. 应用 D* Lite 算法的目标移动时无人机三维航迹规划 [J]. 电光与控制, 2013, 20(7):1-5.
- [4] 胡晓磊, 胡朝晖, 江洋溢. 基于 Dijkstra 算法的水平航迹规划 [J]. 火力与指挥控制, 2004, 29(4):86-88, 92.
- [5] 刘群芳. 基于稀疏 A* 算法与进化算法的无人机动态航迹规划研究 [D]. 南昌: 南昌航空大学, 2016.
- [6] 何兵, 刘刚, 闫建峰, 等. 基于 Voronoi 图和量子遗传算法的飞行器航迹规划方法 [J]. 电光与控制, 2013, 20(1):5-8, 18.
- [7] TIAN L F, COLLINS C. An effective robot trajectory planning method using a genetic algorithm [J]. Mechatronics, 2004, 14: 455-470.
- [8] TAN G Z, HE H, SLOMAN A. Global optimal path planning for mobile robot based on improved Dijkstra algorithm and ant system algorithm [J]. Journal CSUT, 2006, 13(1):80-86.
- [9] 高晓静, 李俊山, 赵宗涛, 等. 基于模拟退火算法的航迹规划方法研究 [J]. 微电子学与计算机, 2000(5):10-14.
- [10] WU X X, MING Y, WANG J. An improved path planning approach based on particle swarm optimization [C]//International Conference on Hybrid Intelligent Systems (HIS), 2011:157-161.
- [11] 张帅, 李学仁, 张建业, 等. 基于动态步长的无人机三维实时航迹规划 [J]. 北京航空航天大学学报, 2016, 42(12):2745-2754.
- [12] 任敏, 沈林成. 基于 Hopfield 人工神经网络的飞行器快速航迹规划算法 [J]. 战术导弹技术, 2007(5):1-6.
- [13] 杨华江, 朱华勇, 沈林成. 一种基于 Hopfield 神经网络的 TF/TA 航迹规划算法 [J]. 航空计算技术, 2006, 36(5):55-58.
- [14] 梁瑾, 宋科璞. 神经网络在移动机器人路径规划中的应用 [J]. 系统仿真学报, 2010, 22(s1):269-272.
- [15] LEON J L. Automatic path planning for a mobile robot among obstacles of arbitrary shape [J]. IEEE Trans. SMC (S1083-4419), 1993, 28(3):467-471.