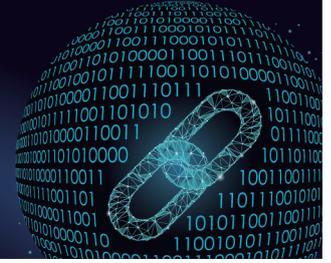




中国科技期刊卓越行动计划项目入选期刊

控制与决策

CONTROL AND DECISION



基于深度神经网络的高轨最优Lambert变轨规划

徐杭, 宋斌, 余建慧, 郭延宁, 马广富

引用本文:

徐杭, 宋斌, 余建慧, 郭延宁, 马广富. 基于深度神经网络的高轨最优Lambert变轨规划[J]. 控制与决策, 2024, 39(9): 2969–2976.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2023.0699>

您可能感兴趣的其他文章

Articles you may be interested in

基于MCPDDPG的智能车辆路径规划方法及应用

The method and application of intelligent vehicle path planning based on MCPDDPG

控制与决策. 2021, 36(4): 835–846 <https://doi.org/10.13195/j.kzyjc.2019.0460>

城市低空环境中多旋翼无人机在线航线规划方法

An online route planning method for multi-rotor drone in urban environments

控制与决策. 2021, 36(12): 2851–2860 <https://doi.org/10.13195/j.kzyjc.2020.0557>

基于粒子群算法的满载需求可拆分车辆路径规划

Split vehicle route planning with full load demand based on particle swarm optimization

控制与决策. 2021, 36(6): 1397–1406 <https://doi.org/10.13195/j.kzyjc.2019.1323>

考虑气动效应不确定性的气动辅助变轨制导算法

Aeroassisted orbital transfer robust guidance method considering atmosphere effect uncertainty

控制与决策. 2020, 35(11): 2773–2779 <https://doi.org/10.13195/j.kzyjc.2019.0333>

阴影条件下基于迁移强化学习的光伏系统最大功率跟踪

Transfer reinforcement learning based maximum power point tracker of PV systems under partial shading condition

控制与决策. 2020, 35(12): 2939–2949 <https://doi.org/10.13195/j.kzyjc.2019.0412>

基于深度神经网络的高轨最优Lambert变轨规划

徐杭¹, 宋斌², 余建慧³, 郭延宁^{1†}, 马广富¹

(1. 哈尔滨工业大学航天学院, 哈尔滨 150001; 2. 上海宇航系统工程研究所, 上海 201109;
3. 北京跟踪与通信技术研究所, 北京 100094)

摘要: 针对高轨在轨服务与主动式碎片清除任务中的Lambert变轨规划问题, 提出一种基于深度神经网络的燃料最优快速求解方案. 首先, 考虑J2摄动力影响与共面圆轨道假设, 建立基于Lambert变轨的问题表征; 其次, 针对轨迹规划问题提出考虑J2摄动力影响的两步PSO优化算法, 并经过仿真实验总结变轨过程 ΔV 消耗相对转移时长的变化规律($\Delta V-T$ 曲线特性), 定义样本形式, 构建燃料最优变轨知识库, 基于总结的变化规律及样本非线性函数关系的特征, 引出基于深度神经网络的快速轨迹规划策略, 从而将Lambert计算次数缩小为两次; 最后, 通过仿真实验, 验证所提出高轨最优Lambert变轨规划策略的有效性, 在测试集上实现了关键区域变轨时长预测0.0140%的平均绝对误差, 新策略具备广泛的应用前景.

关键词: 深度神经网络; 在轨服务; Lambert变轨; 高轨; 燃料最优优化; PSO

中图分类号: V448.2

文献标志码: A

DOI: 10.13195/j.kzyjc.2023.0699

引用格式: 徐杭, 宋斌, 余建慧, 等. 基于深度神经网络的高轨最优Lambert变轨规划[J]. 控制与决策, 2024, 39(9): 2969-2976.

Optimal high-orbit Lambert transfer planning based on deep neural network

XU Hang¹, SONG Bin², YU Jian-hui³, GUO Yan-ning^{1†}, MA Guang-fu¹

(1. School of Astronautics, Harbin Institute of Technology, Harbin 150001, China; 2. Shanghai Institute of Aerospace System Engineering, Shanghai 201109, China; 3. Beijing Institute of Tracking and Telecommunications Technology, Beijing 100094, China)

Abstract: A fast solution scheme based on a deep neural network is proposed to solve the Lambert transfer planning problem for high-orbit on-orbit service and active space debris removal missions. Firstly, considering the J2 perturbation and coplanar circular orbit assumption, a representation of planning based on the Lambert transfer is established. Secondly, a two-step PSO algorithm considering the J2 perturbation is proposed for trajectory planning. The variation rules of ΔV cost relative to transfer time ($\Delta V-T$ curve characteristic) are summarized through simulation experiments, the sample form is defined, and the optimal fuel transfer knowledge base is constructed. Based on the summarized rules and the characteristics of the sample's nonlinear relationship, a fast trajectory planning strategy based on a deep neural network is proposed, which can reduce the number of calculating the Lambert transfer to two. Finally, simulation results demonstrate the effectiveness of the proposed optimal high-orbit Lambert transfer planning strategy. On the test set, the average absolute error of predicting time is 0.0140% in the key area. The proposed strategy has wide application prospects.

Keywords: deep neural network; on-orbit service; Lambert transfer; high-orbit; fuel-optimal optimization; PSO

0 引言

随着近年来人类太空活动的增加和研究的深入, 空间飞行器的组成与任务日趋复杂, 空间在轨服务(on-orbit servicing, OOS)因其显著的经济效益受到了研究者的重视, 其中的规划问题已成为学术研究热

点. 自1984年起, 空间在轨服务从概念研究逐渐转向为现实技术研究, 美国多次使用“挑战者”号、“哥伦比亚”号等航天飞机执行在轨捕获、修理、装配、释放等服务任务^[1]. 这些空间在轨服务的成功案例验证了相关技术的可行性, 并在世界范围内掀起了研究的风

收稿日期: 2023-05-22; 录用日期: 2023-10-16.

基金项目: 国家自然科学基金项目(61973100, 62273118, 12150008); 中国航天科技集团有限公司青年拔尖人才支持工程资助项目.

责任编辑: 魏秀琨.

[†]通讯作者. E-mail: guoyn@hit.edu.cn.

潮. 针对高轨高价值卫星的服务需求, 在过去20年中, 各主要航天大国均围绕其开展了一系列关键技术研究并转向应用, 相关技术具备巨大的发展空间^[2]. 另一方面, 随着空间碎片的增长, 缓解措施效果有限, 主动式碎片清除已经成为一种重要的处理手段^[3]. 在上述这些场景的任务执行过程中, 均涉及到航天器的轨迹规划问题, 且以服务星和目标的近似接触式交会形式为主.

目前在航天器的工作模式中, “一对多” “多对多” 模式逐渐受到人们的关注. 在航天器服务能力足够前提下, 上述模式相比传统的 “一对一” 模式效率更高, 并有望在将来得到在轨应用^[4]. 以 “多对多” 模式为例, 其规划过程包括三层框架的求解: 任务分配、 “一对多” 序列规划、 “一对多” 轨迹优化^[5]. 作为上述问题求解的基本过程, 航天器单次的轨迹规划是研究的基础. 无论是在大规模求解中多次的 “一对一” 轨迹规划, 还是在星上计算资源受限情况下的实时规划, 均对其计算效率提出了更高的要求. 快速的轨迹规划具备应用的现实需求, 尤其是对于数值法进行求解的 Lambert 机动.

目前针对于 “一对一” 的 Lambert 机动轨迹规划已有很多相关研究成果, 多数以燃料最优为规划目标. Shen 等^[6]忽略了 ΔV - T 关系曲线中的少数曲线段对应的情况, 并近似为整数规划问题进行处理. Daneshjou 等^[7]采用粒子群优化算法 (particle swarm optimization, PSO) 进行最优的转移时长获取. Zhang 等^[8]针对多个碎片清除任务的规划问题, 采用连续化的蚁群算法进行求解. Zhao 等^[9]对于 PSO 的结果进一步逐步二次规划 (sequential quadratic programming, SQP), 提出了一种改进的加速粒子群算法来进一步增强求解时的快速收敛能力.

然而, 上述研究均以优化策略为主, 需要多轮迭代求解 Lambert 问题. 在以 Lambert 机动为变轨方式的任務规划中存在求解效率低的问题^[10], 尤其是在考虑摄动力影响时, 计算的迭代次数更多^[11]. 针对于空间碎片清除任务, 目前考虑碎片的大多数文献研究数量都过少, 面对未来大规模空间碎片清除场景存在难以短时间快速求解的问题^[12]. 目前, 以大量标签数据进行训练的学习方法具备快速给出结果的优势. 得益于深度学习网络近年来蓬勃发展的优势, 该技术在诸多领域得到了应用, 空间任务方面也有不少研究. Yang 等^[13]针对考虑摄动 Lambert 问题求解提出了一种快速求解策略, 采用深度学习网络提供 Lambert 问题的结果初值, 并结合有限差分打靶

法给出迭代校正结果. Li 等^[14]将规划问题视为一个高级控制问题, 通过深度神经网络确定过程中的动作. Zhao 等^[15]针对不规则小行星的自主安全着陆问题, 提出了一种基于深度神经网络的实时无碰撞轨迹优化方法. Gong 等^[16]利用深度神经网络强大的非线性拟合能力, 实现快速的角度相关相对轨道确定. 曾晨东等^[17]针对空间机器人双臂捕获非合作卫星过程中的避撞柔顺控制问题, 提出一种基于事件采样输出反馈的 RBF 神经网络的控制方案. 黄旭辰等^[18]针对 GEO 卫星动力学模型参数进行拟合, 有效地提高了转移轨迹制导效率. 关于变轨过程中速度增量的预测也有采用监督学习的尝试^[12], 但针对于包含完整变轨策略参数的在轨服务规划问题, 目前通过学习方式对最优 Lambert 机动进行预测尚缺乏相关研究.

综上所述, 为了提高在轨服务任务规划效率, 需探索快速高效的燃料最优 Lambert 交会轨迹获取策略. 本文以高轨在轨服务规划过程为分析对象, 考虑双方均为共面圆轨道, 提出了考虑 J2 摄动力影响的两步 PSO 优化算法, 构建了燃料最优变轨知识库, 提出了基于深度神经网络的快速获取策略, 并在测试集上进行了验证. 结果表明, 所提出策略在快速获取的前提下仍然能够达到较高求解精度.

1 数学模型

1.1 共面异高 Lambert 交会问题

针对高轨服务场景, 考虑不同轨道面之间转移燃料代价极大, 实际任务中交会服务主要发生在共面场景, 且多数高轨卫星轨道偏心率极小. 因此, 本文只考虑共面圆轨道情况下的在轨任务, 服务星和目标轨道高度不同. 同时, 本文主要针对高轨的静态任务规划展开研究, 没有考虑转移过程中目标位置发生临时变化的情况.

服务星与目标初始分别位于空间中共面轨道两处不同位置, 服务星采取双脉冲 Lambert 机动方式, 经过转移时长 T , 与目标在某处交会. 对于燃料最优的 Lambert 轨迹规划, 首先是确定相应的转移时长 T_{best} , 常用智能优化算法进行迭代获取, 变轨机动指令通过求解 T_{best} 对应的 Lambert 轨迹获取. 服务星执行服务任务时, 与目标在空间中同位置、同速度.

分析不同转移时长下变轨过程的燃料消耗 (以速度增量消耗 ΔV 近似), 取双方高度相同与不同两种工况:

- 1) 工况 A: 轨道半长轴均为 42 164 140 m, 目标超前相位角 30° ;
- 2) 工况 B: 服务星半长轴为 42 164 140 m, 目标半

长轴为42 464 140 m,超前相位角30°.

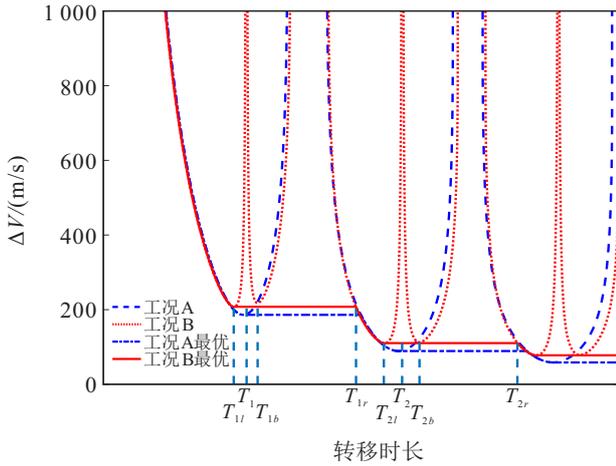


图1 ΔV消耗与转移时长关系曲线

所选工况为高轨情况, Lambert 求解过程参见文献[19]进行,摄动力因素主要受J2摄动力影响,基于打靶法^[20]可以对二体计算结果进行校正分析.考虑多圈情况下,每一个转移时长下ΔV的计算过程通过对相邻两圈的计算结果进行取优获得^[21].机动过程的ΔV-T曲线如图1所示.由图1可知,当双方轨道高度不同时,曲线原各波谷段最低处ΔV消耗急剧增加,形成一前一后两个子波谷段.为了简化问题,本文中不涉及目标滞后超过60°后第1个波谷(速度增量较大)^[22].图1中实线表示当对应的转移时长为时长约束时,ΔV消耗最小的取值呈单调递减特性.当双方轨道高度相同时,曲线的各波谷段近似在调相机动转移时长附近,服务星近似转过360°的整数倍.考虑在二体模型下,调相机动的转移时长为

$$T_m = (2m\pi - \varphi) \sqrt{\frac{a_t^3}{GM_e}},$$

$$-\pi \leq \varphi < \pi, m = 1, 2, 3, \dots \quad (1)$$

其中:G表示万有引力常量,Me表示地球质量,φ为目标超前相位角,at为目标轨道半长轴.每一个Tm附近,主要存在Tml与Tmr两个转折点,每个Tm附近两个子波谷段的最小ΔV消耗相近,一般前者更小.然而在某些工况下情况发生了变化,在某些工况下可能出现ΔVml消耗大于后子波谷Tmb对应ΔVmb的情况.本文中近似忽略该情况,设变轨过程的约束时长为T0,在不同的服务时长约束下,燃料最优对应的Tbest可主要划分为3段,表述为

$$T_{\text{best}} = \begin{cases} T_0, & 0 < T_0 \leq T_{1l}; \\ T_{ml}, & T_{ml} < T_0 \leq T_{mr}; \\ T_0, & T_{mr} < T_0 \leq T_{(m+1)l}; \end{cases} \quad m = 1, 2, 3, \dots \quad (2)$$

1.2 两步PSO算法

目前已有算法种类很多,本文采用针对连续优化表现出色的PSO算法进行燃料最优下的转移时长变量获取.作为一种全局随机搜索算法,PSO自1995年被提出以来,已广泛应用于各个领域.它对非线性和多模态问题具有较强的全局搜索能力,拥有操作简单的特点.

在搜索过程中,由于涉及到大量的迭代计算过程,每次适应度函数求解考虑J2摄动项存在效率低的问题.考虑到图1中ΔV-T曲线变化相对平滑,没有在局部剧烈变化,因此本文考虑采用两步优化策略:第1步在PSO优化中不考虑J2摄动影响,第2步考虑J2摄动影响对第1步结果进行校正.在第1步优化后将变量取值约束在一个最优值附近的范围内,从而在第2步考虑J2摄动影响优化时可以较少迭代次数收敛到最优值.

在第1步优化中,对于变量的初始种群,采用随机初始化方式,在变轨时长取值范围内随机选取多个初始变量.每个粒子在搜索空间中聚集到其历史上的最佳位置p和全局历史上的最佳位置g,并以一定的速度收敛.在第n次迭代中,更新k号粒子Xn+1(k)位置(变量T)和速度Vn+1(k)的方程,即

$$V_{n+1}(k) = wV_n(k) + c_1r_1[p_n(k) - X_n(k)] + c_2r_2[g_n - X_n(k)], \quad (3)$$

$$X_{n+1}(k) = X_n(k) + V_{n+1}(k). \quad (4)$$

其中:w为权重系数,可在迭代过程中取为从wmax线性衰减至wmin的可变参数;c1和c2为学习因子参数;r1和r2为[0, 1]范围内的随机数;k(k = 1, 2, ..., L)表示粒子的编号,L表示粒子的数量.算法的停止条件设置为达到一定迭代次数.在寻找燃料最优转移时长时,目标函数设置为

$$J_1 = \min(\Delta V), \quad (5)$$

位置的上下限约束为

$$0 < X_n(k) \leq T_0. \quad (6)$$

在搜索Tml时,为了保证结果收敛于前子波谷,位置的上下限约束更改为

$$T_m - \alpha_1\pi\sqrt{\frac{a_t^3}{GM_e}} < X_n(k) \leq T_m + \alpha_2\pi\sqrt{\frac{a_t^3}{GM_e}}. \quad (7)$$

在第2步中,位置的上下限约束进一步缩小,可参考目标轨道半长轴at进行设置,有

$$X_{\text{best}1} - \beta\pi\sqrt{\frac{a_t^3}{GM_e}} < X_n(k) \leq X_{\text{best}1} + \beta\pi\sqrt{\frac{a_t^3}{GM_e}}. \quad (8)$$

其中: $X_{\text{best}1}$ 为第1步的优化结果, β 为人为设定参数. 考虑到 β 的经验设置偏差, 需要对左右边界处的适应度进行校验, 当其均不满足大于 $X_{\text{best}1}$ 处适应度函数值的条件时, 调整公式为

$$\beta = \eta\beta, \quad (9)$$

其中 η 为设定边界膨胀系数, 大于1即可. 在确定边界之后, 初始变量也在位置上下限约束范围内随机初始化设定.

设定第1步中迭代次数为 N_f , 粒子数量为 L_f ; 第2步中迭代次数为 N_s , 粒子数量为 L_s . 考虑摄动力影响 Lambert 取优过程重复次数为 n_p , 对比标准 PSO 迭代次数为 N_0 , 粒子数量为 L_0 , Lambert 取优过程计算复杂度为 f_l . 在算法复杂度上, 标准 PSO 为 $O(N_0L_0n_p f_l)$, 本文中两步 PSO 为 $O(N_f L_f f_l + N_s L_s n_p f_l)$. 虽然两者复杂度在数量级上相同, 但是由于第1步将优化范围缩小, 实际应用中外者复杂度更小.

2 基于BP神经网络的燃料最优Lambert快速求解

由前述 PSO 算法求解过程可知, 常用的优化算法需要耗费大量的运算量在迭代取优上, 运算效率极低, 尤其是在考虑摄动力因素进行修正后.

本节将探索快速的最优转移时长获取方式. 综合前述结论, 可以制定出结合 T_{ml} 预测的 Lambert 燃料最优变轨时长规划策略. 针对约束时长 T_0 , 对小于其的最大 T_{ml} 进行分析, 按照 Lambert 过程计算 T_0 与 T_{ml} 对应的转移轨道参数, ΔV_0 、 ΔV_{ml} 、 T_{best} 可重新表述为

$$T_{\text{best}} = \begin{cases} T_0, & 0 < T_0 \leq T_{1l}; \\ T_{ml}, & T_{ml} < T_0 \leq T_{(m+1)l}, \Delta V_{ml} < \Delta V_0; \\ T_0, & T_{ml} < T_0 \leq T_{(m+1)l}, \Delta V_{ml} \geq \Delta V_0; \end{cases} \quad (10)$$

$$m = 1, 2, 3, \dots$$

当 T_{best} 为 T_0 时, 前述 T_0 对应转移轨道参数, 计算结果即为燃料最优规划结果; 当 T_{best} 为 T_{ml} 时, 前述 T_{ml} 对应转移轨道参数, 计算结果即为燃料最优规划结果. 可以看出, 本文所提出策略最多只需要计算两次考虑摄动影响的 Lambert 过程 (T_0 与 T_{ml} 对应的转移轨道参数). 考虑到 J2 影响轨道递推与训练后神经网络在线输出的计算量相对于 Lambert 取优过程 (涉

及数值解迭代计算) 较小, 计算复杂度可近似归纳为 $O(2n_p f_l)$. 从计算复杂度上可以看出, 本文所提出规划策略相对两步 PSO 算法大幅减小了计算量.

此外, 对于 ΔV_{ml} 、机动脉冲等对应于变轨时长 T_{ml} 的规划结果信息也可以通过网络直接进行预测而不是在线计算, 但考虑到实际应用的误差, 本文策略仅将误差约束在对变轨时长 T_{best} 的预测及对应规划信息计算的关联误差上. 具体而言, 一方面对于转移时长的估计误差仅在 $\Delta V_{ml} < \Delta V_0$ 区域的边缘产生, 本文称此区域为关键区域.

1) 预测 $T_{ml} < T_0 \leq T_{(m+1)l}$ 、 $\Delta V_{ml} < \Delta V_0$, 实际 $T_{ml} < T_0 \leq T_{(m+1)l}$ 、 $\Delta V_{ml} \geq \Delta V_0$ 或 $0 < T_0 \leq T_{1l}$, 此时实际 T_{best} 应取 T_0 ;

2) 预测 $0 < T_0 \leq T_{1l}$ 或 $T_{ml} < T_0 \leq T_{(m+1)l}$ 、 $\Delta V_{ml} \geq \Delta V_0$, 实际 $T_{ml} < T_0 \leq T_{(m+1)l}$ 、 $\Delta V_{ml} < \Delta V_0$, 此时实际 T_{best} 应取 T_{ml} .

另一方面, 与 1.1 节所述相同, 当 $\Delta V_{ml} < \Delta V_0$ 时直接取 T_{ml} 的处理方式会在 ΔV_{mb} 小于 ΔV_{ml} 情况下造成误差, 没有把最优取值更新为后子波谷取值, 需对该误差进行判别.

2.1 V-T 曲线特性分析

定义偏差 Δt_{ml} 为

$$T_{ml} = T_m - \Delta t_{ml}. \quad (11)$$

可见基于 T_m , 可以通过预测 Δt_{ml} 间接预测 T_{ml} . 考虑到 ΔV - T 曲线特性与多种因素相关, 为预估预测质量, 采用前述两步 PSO 算法对偏差 Δt_{ml} 进行获取并进一步分析, 相关参数见仿真实验章节, 分析结果如图 2 所示.

在分析场景中, 包含考虑 J2 摄动和不考虑 J2 摄动两种情况. 考虑约束与假设, 问题将以波谷序列数 N 、目标半长轴 a_t 、服务星半长轴 a_c 、相角差 φ 为控制变量, 绘制偏差的相对各变量的变化关系. 其中图 2(a) 是对工况 B 中各波谷段进行分析, 图 2(b) 和 2(d) 是以工况 A 为基础取第 1 个波谷段, 改变目标、服务星半长轴进行分析, 图 2(c) 是以工况 B 为基础取第 1 个波谷段, 改变相角差进行分析.

从仿真实验结果可以看出: 偏差量与 N 呈单调关系, 与 a_c 、 a_t 、 φ 均有关, φ 越大或 a_c 与 a_t 偏差越大, Δt_{ml} 越大. 曲线的非线性特性在相位角差绝对值较小时尤为明显. 同时考虑 J2 摄动力影响之后, 在高轨上偏差很小, 曲线相关特性规律无变化, 因此其非线性映射关系函数存在一定规律, 且变化关系相对平稳, 可尝试利用拟合手段进行预测. 通过深度神经网络对样本进行训练, 可获得拟合后的函数关系. 同时,

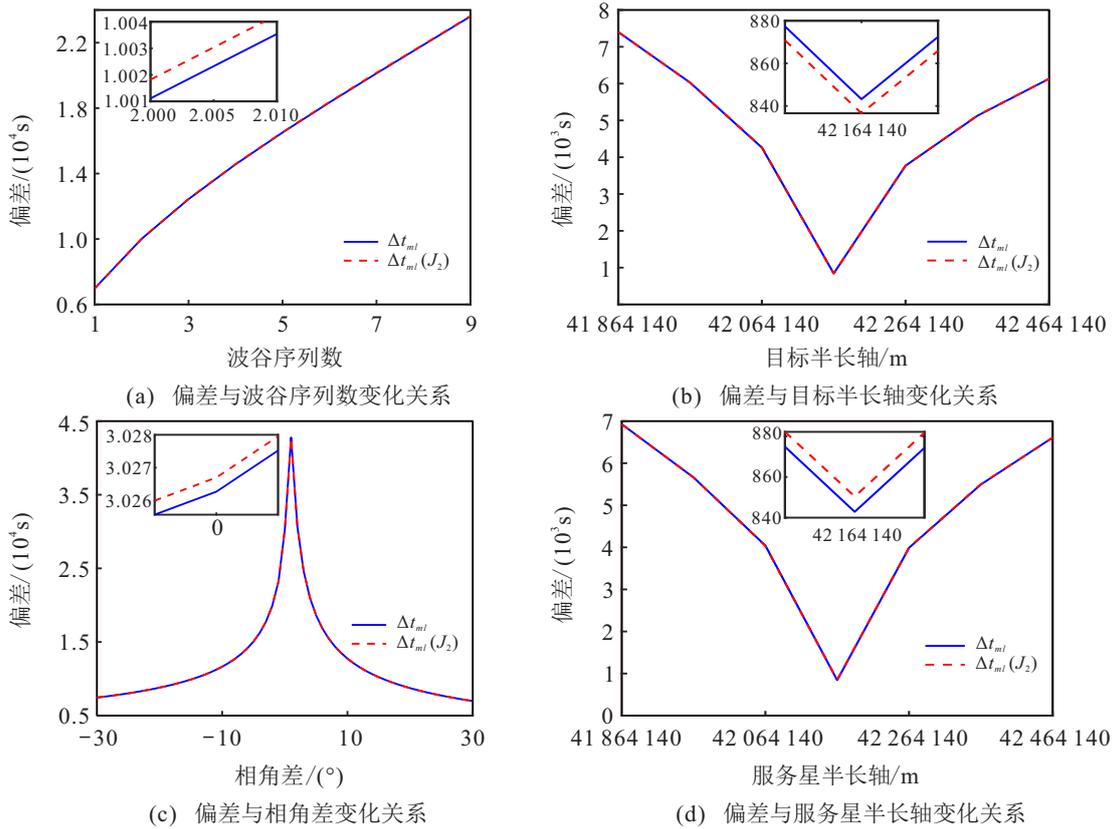


图 2 偏差与不同因素变化关系图

网络的良好预测与样本质量关系很大,高质量的样本对于训练效率、预测精度有较大提升,考虑到 T_{ml} 本身取值随 T_0 增长而增长,上述过程是预测 Δt_{ml} 而不是直接预测 T_{ml} . 样本的形式可以被定义为

$$S = \{[N, a_c, a_t, \varphi], [\Delta t_{ml}]\}. \quad (12)$$

2.2 BP神经网络预测

针对前述非线性函数关系,根据通用逼近定理^[23],可采用监督学习式的深度神经网络对其进行预测.首先需要在不同 a_c 、 a_t 、 φ 、 N 下,计算相应的偏差 Δt_{ml} ,构建在共面圆轨道下 Lambert 机动的变轨知识库.针对本文中样本的输入,由于不同输入彼此独立,采用多层前馈神经网络即可(单层网络结构过于简单,拟合能力弱),不考虑递归神经网络^[24].

常用的监督学习多层前馈神经网络包括 BP、CNN、RBF. CNN 主要用于图像识别领域;RBF 一方面对样本噪声的容忍度较低,另一方面训练样本很大时,会占用大量内存资源,对硬件要求过大^[23].相比之下,BP神经网络具备简单易用的优势,尤其对于非线性函数拟合问题. BP神经网络是一种使用误差反向传播技术训练的多层前馈神经网络,通过调整各层节点的权重、偏置使得网络输出逼近标记值,训练完成后可以快速根据输入映射输出.其中隐藏层数 N_y 、隐藏层上的节点数 N_j 均可以根据不同的样本

进行调整.在训练学习的过程中,样本的4维特征(a_c 、 a_t 、 φ 、 N)首先通过正向传播被送到输入层,由每个隐藏层处理,第1个隐藏层各节点对输入的处理可表示为

$$b_{1j} = f\left(\sum_{u=1}^{n_1} \omega_{ju}^1 x_u + \beta_{ij}\right). \quad (13)$$

其中: β_{ij} 表示偏置量, x_u 表示输入量, n_1 表示输入量个数, ω_{ju}^1 表示权重参数, f 表示激活函数.当涉及多个隐藏层时,处理过程类似,可表示为

$$b_{ij} = f\left(\sum_{u=1}^{n_i} \omega_{ju}^i b_{(i-1)u} + \beta_{ij}\right). \quad (14)$$

最后从输出层输出,处理过程类似,可表示为

$$y = f\left(\sum_{u=1}^{n_i} \omega_{ju}^i b_{(i-1)u} + \theta_j\right), \quad (15)$$

其中 θ_j 表示输出的偏置量.中间每个神经元的输出均由输入向量、权重、偏置量、激活函数确定,一旦网络被构建,输入输出格式、激活函数便被确定.对于输出与期望值的误差需要反向传播,采用梯度下降法不断优化模型参数(权重、偏置量),直到拟合值误差减小到期望阈值之下.

对于本文中的高轨 Δt_{ml} 预测目标,在构建训练集与测试集时, a_c 、 a_t 以 GEO 半长轴 a_X 为基准,设置对应的高度偏差以及对应的 N 、 φ (即平近点角).

除此以外,考虑到小相角差下 $\Delta V-T$ 曲线的强非线性,可以在该区域多设置一些工况. 样本的输出偏差 Δt_{ml} 通过前述两步PSO算法获得.

3 仿真实验

3.1 仿真工况

本节将通过仿真实验对本文中涉及到的算法进行验证. 实验过程采用个人PC完成, CPU型号为Intel Core i5-10210U@1.6 GHz, 内存16 GB. 在具体参数设置上, 两步PSO中 c_1 和 c_2 均为1.5, w_{max} 和 w_{min} 为0.9、0.1, N_f 为50, L_f 为100, N_s 为5, L_s 为5, n_p 为10, α_1 、 α_2 、 β 、 η 分别为2、0.0002、0.001、1.5. 训练集中每个样本服务星与目标偏心率、升交点赤经、近地点幅角、倾角均设置为零, a_X 取42 164.140 km, 半长轴相对 a_X 分别考虑-100 km, -50 km, -10 km, +0 km, +10 km, +50 km, +100 km共7种情况, 波谷序列取数1至5, 平近点角在 -90° 至 90° 间隔 1° 取1种情况(-2° 至 2° 间隔 0.2° 取1种情况, -10° 至 -2° 和 2° 至 10° 间隔 0.5° 取1种情况). 同时, 上述样本中将 a_c 与 a_t 相等、 φ 为零的情况(高误差)舍去, 针对 Δt_{ml} 共计52 150组优化结果训练样本.

3.2 前后子波谷偏差分析

本文所提出策略认为前子波谷的 ΔV_{ml} 相对于后子波谷的 ΔV_{mb} 通常较小, 忽略了 ΔV_{mb} 小于 ΔV_{ml} 时部分区域的偏差. 为验证该近似处理方式所造成的影响, 在所述考虑服务星半长轴、目标半长轴、相位角差、波谷序列数范围内, 随机选取100组工况, 比较 ΔV_{ml} 与 ΔV_{mb} 的差异, 实验结果如图3所示. 可以看出, ΔV_{ml} 与 ΔV_{mb} 整体非常接近, 多数情况下 ΔV_{mb} 均大于 ΔV_{ml} , 100次实验仅有1次情况 ΔV_{ml} 大于 ΔV_{mb} , 本文中近似处理方式存在实用性.

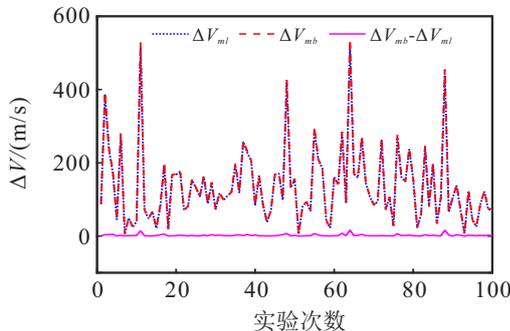


图3 前后子波谷对比曲线

3.3 两步PSO算法精度验证

在本文中, 采用两步PSO算法进行训练集、测试集的构建. 针对 Δt_{ml} 的计算过程, 在训练集的 a_c 、 a_t 、 φ 、 N 范围内, 随机选取10组工况, 各计算100次前子波谷段的 ΔV 消耗最小值, 绘制最优适应度函数值的

结果箱线图, 如图4所示, 实验结果中每组工况下最优结果几乎完全相同, 验证了本文中两步PSO算法的稳健性.

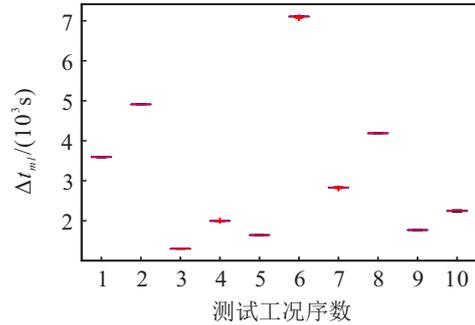


图4 Δt_{ml} 偏差优化计算值箱线图

3.4 BP网络结构选取

对于BP神经网络, 不同的网络结构最终效果也会不同. 本文中对于隐藏层, 分析比较tansig与logsig两种常用的传递函数, 输出层采用purelin传递函数, 优化算法均采用Levenberg-Marquardt算法, 训练过程学习速率为0.01, 均方误差(mean square error, MSE)停止迭代阈值设为0.00001, 最大迭代次数为1000次. 为了测试网络的泛化能力, 本文构建了1000组测试集, 均采用两步PSO算法进行优化创建. 不同结构训练后网络在测试集上测试结果如表1所示, 所有结果均取10次测试中最好结果, 即MSE与平均绝对误差(mean absolute error, MAE)百分比乘积最小.

表1 不同网络结构下 Δt_{ml} 测试结果

隐藏层数	隐藏层节点数	隐藏层传递函数	MSE	MAE占比/%
2	20	tansig	253.015	4.36
2	20	logsig	463.355	8.34
2	30	tansig	411.331	7.70
2	30	logsig	270.731	4.23
2	40	tansig	190.833	3.34
2	40	logsig	236.234	4.19
3	20	tansig	212.299	3.53
3	20	logsig	223.295	4.09
3	30	tansig	218.744	4.60
3	30	logsig	256.253	5.24
3	40	tansig	324.082	7.92
3	40	logsig	263.212	5.15
4	20	tansig	266.287	4.32
4	20	logsig	200.354	4.41
4	30	tansig	299.474	6.78
4	30	logsig	310.120	6.86
4	40	tansig	264.518	6.09
4	40	logsig	281.611	5.83

由于实验中设置了相同的迭代停止条件, 考虑每个网络训练状态不同, 很难从上述结果中总结出规律. 关于网络结构的选择也有很多经验策略, 但一方面上述结果相近, 并没有出现误差特别大的情况; 另一方面关注重点为监督学习手段规划的可行性, 并不

是选取最佳效果的网络结构,因此这边取相对适中情况分析即可. 取隐藏层数3层、隐藏节点数40、隐藏层传递函数为 logsig 进一步分析,改变均方误差停止迭代阈值后测试结果如表2所示,实验结果依然是取10次测试中最好结果.

表 2 不同迭代停止条件下 Δt_{ml} 测试结果

停止迭代 MSE 阈值	MSE	MAE 占比 / %	MSE与MAE 占比乘积
10^{-3}	777.558	11.79	91.674
10^{-4}	388.516	7.91	30.732
10^{-5}	237.054	4.47	10.596
10^{-6}	150.173	3.14	4.715
10^{-7}	148.906	2.30	3.425
10^{-8} (提前结束)	126.234	1.77	2.234

由实验结果可以看出, 10^{-8} 作为停止迭代 MSE 阈值时,网络在测试集上的表现最出色,此时训练过程受限于最大迭代次数提前结束,对应的网络在训练过程中 MSE 迭代收敛曲线已经很难继续减小.

得益于 $\Delta V-T$ 曲线的相对平滑、拟合目标特性比较理想,整体网络拟合 MSE 越小,在测试集上效果越好,过拟合的负面作用相对不明显. 此时,训练网络在测试集上预测 Δt_{ml} 的 MAE 为 1.77%,对于转移波谷 T_{ml} 预测的 MAE 为 0.0140%,预测结果如图 5(a) 和 5(b) 所示.

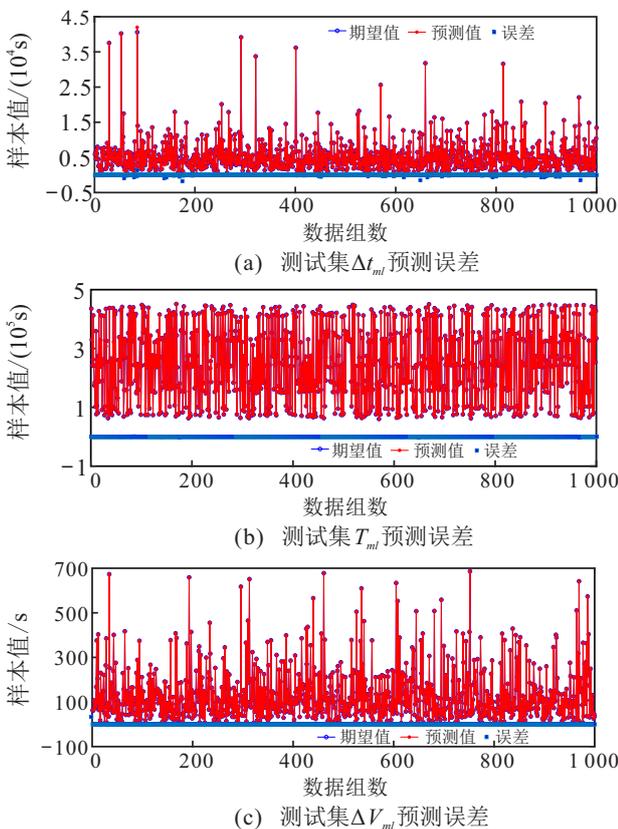


图 5 测试集预测偏差

此外,通过预测的 T_{ml} 计算 ΔV_{ml} ,将计算结果与优化期望值对比,对比结果如图 5(c) 所示, MAE 为 0.0335%,在该指标上预测网络也实现了良好的预测能力. 由此可见,本文所提出算法在提升求解速度的同时,相对于传统优化策略并没有造成较大的精度丢失.

4 结 论

本文针对高轨航天器 Lambert 机动规划问题,探索运用神经网络的方式对燃料最优规划结果进行预测,设计了考虑 J2 摄动力影响的两步 PSO 优化算法用于训练集、测试集构建,分析了 Lambert 双脉冲变轨 $\Delta V-T$ 曲线变化特性,提出了基于 BP 神经网络的变轨时长预测策略,解决了传统优化算法解决规划问题耗时久、计算资源消耗大的问题. 最后,在测试集上通过仿真实验验证了所提出策略的求解精度. 本文所采取的策略同时也可用于在轨规划初值的选取,具备广泛的应用前景.

参考文献(References)

- [1] 崔乃刚, 王平, 郭继峰, 等. 空间在轨服务技术发展综述[J]. 宇航学报, 2007, 28(4): 805-811.
(Cui N G, Wang P, Guo J F, et al. A review of on-orbit servicing[J]. Journal of Astronautics, 2007, 28(4): 805-811.)
- [2] 肖余之, 靳永强, 陈欢龙, 等. 在轨服务若干关键技术研究进展[J]. 上海航天: 中英文, 2021(3): 85-95.
(Xiao Y Z, Jin Y Q, Chen H L, et al. Research progress on several key technologies of on-orbit service[J]. Aerospace Shanghai: Chinese & English, 2021(3): 85-95.)
- [3] Hakima H, Emami M R. Prioritizing orbital debris for active debris removal missions[C]. 2017 IEEE Aerospace Conference. Big Sky, 2017: 1-11.
- [4] Chen X Q, Yu J. Optimal mission planning of GEO on-orbit refueling in mixed strategy[J]. Acta Astronautica, 2017, 133: 63-72.
- [5] Huang A Y, Luo Y Z, Li H N. Global optimization of multiple-spacecraft rendezvous mission via decomposition and dynamics-guide evolution approach[J]. Journal of Guidance, Control, and Dynamics, 2022, 45(1): 171-178.
- [6] Shen H J, Tsiotras P. Optimal scheduling for servicing multiple satellites in a circular constellation[C]. AIAA/AAS Astrodynamics Specialist Conference and Exhibit. Monterey, 2002: 4907.
- [7] Daneshjou K, Mohammadi-Dehabadi A A, Bakhtiari M. Mission planning for on-orbit servicing through multiple

- servicing satellites: A new approach[J]. *Advances in Space Research*, 2017, 60(6): 1148-1162.
- [8] Zhang T J, Shen H X, Yang Y K, et al. Ant colony optimization-based design of multiple-target active debris removal mission[J]. *Transactions of the Japan Society for Aeronautical and Space Sciences*, 2018, 61(5): 201-210.
- [9] Zhao Y, Cao Y, Chen Y, et al. Mission planning of GEO active debris removal based on revolver mode[J]. *Mathematical Problems in Engineering*, 2021, 2021: 1-10.
- [10] 魏倩, 蔡远利. Lambert问题的改进算法[J]. *控制与决策*, 2016, 31(7): 1339-1344.
(Wei Q, Cai Y L. Modified algorithm for Lambert's problem[J]. *Control and Decision*, 2016, 31(7): 1339-1344.)
- [11] 桑艳, 周进. 基于 Lambert 算法的脉冲精确变轨策略[J]. *国防科技大学学报*, 2009, 31(3): 29-32.
(Sang Y, Zhou J. An approach of accurate impulse transfer based on Lambert algorithm[J]. *Journal of National University of Defense Technology*, 2009, 31(3): 29-32.)
- [12] 许英杰, 刘晓路, 贺仁杰, 等. 空间碎片主动移除任务规划研究综述[J]. *控制与决策*, 2024, 39(2): 371-380.
(Xu Y J, Liu X L, He R J, et al. Space debris active removal mission planning: A review[J]. *Control and Decision*, 2024, 39(2): 371-380.)
- [13] Yang B, Li S, Feng J L, et al. Fast solver for J2-perturbed Lambert problem using deep neural network[J]. *Journal of Guidance, Control, and Dynamics*, 2022, 45(5): 875-884.
- [14] Li Z Y, Xu R, Cui P Y, et al. Artificial neural network based mission planning mechanism for spacecraft[J]. *International Journal of Aeronautical and Space Sciences*, 2018, 19(1): 111-119.
- [15] Zhao Y J, Yang H W, Li S. Real-time trajectory optimization for collision-free asteroid landing based on deep neural networks[J]. *Advances in Space Research*, 2022, 70(1): 112-124.
- [16] Gong B C, Ma Y Q, Zhang W F, et al. Deep-neural-network-based angles-only relative orbit determination for space non-cooperative target[J]. *Acta Astronautica*, 2023, 204: 552-567.
- [17] 曾晨东, 艾海平, 陈力. 空间机器人双臂捕获卫星操作的事件采样输出反馈神经网络避撞柔顺控制[J]. *控制与决策*, 2021, 36(9): 2113-2122.
(Zeng C D, Ai H P, Chen L. Collision avoidance and compliance control based on event sampling output feedback neural network for space robot dual arm capture satellite operation[J]. *Control and Decision*, 2021, 36(9): 2113-2122.)
- [18] 黄旭辰, 黄旭星, 杨彬, 等. 面向 GEO 空间碎片清除任务的智能轨迹制导算法[J]. *宇航学报*, 2023, 44(5): 719-730.
(Huang X C, Huang X X, Yang B, et al. An intelligent guidance algorithm for GEO space debris removal mission[J]. *Journal of Astronautics*, 2023, 44(5): 719-730.)
- [19] Curtis H D. *Orbital mechanics for engineering students*[M]. Butterworth-Heinemann, 2013: 247-257.
- [20] Battin R H. *An introduction to the mathematics and methods of astrodynamics*[M]. Reston: American Institute of Aeronautics and Astronautics, 1999.
- [21] Shen H J, Tsiotras P. Optimal two-impulse rendezvous using multiple-revolution Lambert solutions[J]. *Journal of Guidance, Control, and Dynamics*, 2003, 26(1): 50-61.
- [22] 徐杭, 梁维奎, 刘鲁江, 等. 面向 GEO 目标的快速在线在轨服务任务规划[J]. *宇航学报*, 2022, 43(11): 1454-1465.
(Xu H, Liang W K, Liu L J, et al. Fast on-board on-orbit servicing task planning for GEO targets[J]. *Journal of Astronautics*, 2022, 43(11): 1454-1465.)
- [23] Simon H. *Neural networks and learning machines*[M]. New Jersey: Pearson Education, Inc, 2008.
- [24] 刘建伟, 宋志妍. 循环神经网络研究综述[J]. *控制与决策*, 2022, 37(11): 2753-2768.
(Liu J W, Song Z Y. Overview of recurrent neural networks[J]. *Control and Decision*, 2022, 37(11): 2753-2768.)

作者简介

徐杭(1996—), 男, 博士生, 从事在轨服务任务规划的研究, E-mail: 13738012377@163.com;

宋斌(1981—), 男, 研究员, 博士, 从事导航、制导与控制等研究, E-mail: 18602171978@163.com;

余建慧(1980—), 男, 副研究员, 硕士, 从事航天器控制的研究, E-mail: Jhy2003@tom.com;

郭延宁(1985—), 男, 教授, 博士, 从事深空探测制导与控制、航天器姿态控制等研究, E-mail: guoyn@hit.edu.cn;

马广富(1963—), 男, 教授, 博士, 从事航天器控制、最优控制等研究, E-mail: magf@hit.edu.cn.