

控制与决策

Control and Decision

基于大语言模型的交互式多目标旅行方案规划器

赵子涵, 杨唯一, 姚锋, 张君哲, 何磊

引用本文:

赵子涵, 杨唯一, 姚锋, 等. 基于大语言模型的交互式多目标旅行方案规划器[J]. *控制与决策*, 2026, 41(4): 892-904.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2025.0714>

您可能感兴趣的其他文章

Articles you may be interested in

[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>

[基于FWADE-ELM的短时交通流预测方法](#)

Short-term traffic flow forecasting based on hybrid FWADE-ELM
控制与决策. 2021, 36(4): 925-932 <https://doi.org/10.13195/j.kzyjc.2019.1103>

[基于预防维护的单机调度问题](#)

[Single-machine scheduling problem with preventative maintenance activities](#)
控制与决策. 2021, 36(2): 395-402 <https://doi.org/10.13195/j.kzyjc.2019.0626>

[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>

[基于迁移学习灰支持向量回归机的交互式进化计算](#)

Interactive evolutionary computation based on transfer learning grey support vector regression
控制与决策. 2021, 36(10): 2399-2408 <https://doi.org/10.13195/j.kzyjc.2020.0420>

基于大语言模型的交互式多目标旅行方案规划器

赵子涵, 杨唯一[†], 姚锋, 张君哲, 何磊

(国防科技大学 系统工程学院, 长沙 410000)

摘要: 针对融合游客个性化偏好、景点实时拥挤度和通勤时间的多目标旅行路线规划问题, 提出一种基于大语言模型 (LLM) 的交互式旅行方案智能生成规划器。首先, 建立 LLM 信息处理模块, 实现用户需求的识别、推理以及结构化转换; 然后, 构建基于随机森林算法的景点客流预测模块, 整合历史客流、天气、节假日等多维因素以实现精确客流预测, 继而借助 LLM 信息处理模块将预测结果映射为多等级拥挤度; 最后, 构建以并行非支配排序遗传算法 (PNSGA-II) 为核心的多目标旅行路线规划器, 实现旅行路线的智能规划和全局最优解搜索。仿真实验结果表明: 相较于其他多目标优化算法, PNSGA-II 在多目标路径规划问题中展现出更优的解质量和更高的计算效率; 此外, 与其他规划器生成的方案相比, 所提出规划器在方案效果和生成效率上也均展现出显著优势。

关键词: 旅行路线规划; 多目标优化; 并行非支配排序遗传算法; 大语言模型; 景点客流预测; 随机森林算法
中图分类号: TP301 **文献标志码:** A

DOI: 10.13195/j.kzyjc.2025.0714

引用格式: 赵子涵, 杨唯一, 姚锋, 等. 基于大语言模型的交互式多目标旅行方案规划器 [J]. 控制与决策, 2026, 41(4): 892-904.

An interactive multi-objective travel planner based on large language model

ZHAO Zi-han, YANG Wei-yi[†], YAO Feng, ZHANG Jun-zhe, HE Lei

(College of Systems Engineering, National University of Defense Technology, Changsha 410000, China)

Abstract: To address the multi-objective travel route planning problem, which integrates tourists' personalized preferences, real-time congestion levels of scenic spots, and commuting time, an interactive travel plan intelligent generation planner based on a large language model (LLM) is proposed. First, a LLM information processing module identifies, reasons, and transforms user requirements into structured data. Then, a scenic spot tourist flow prediction module based on the random forest algorithm is constructed, which integrates multi-dimensional factors such as historical tourist flow, weather, and holidays to achieve accurate tourist flow prediction. The prediction results are mapped to congestion levels through the LLM information processing module. Finally, a multi-objective travel route planner centered on the parallel non-dominated sorting genetic algorithm-II (PNSGA-II) is built to achieve intelligent route planning and search for global optimal solutions. The simulation experimental results indicate that the PNSGA-II outperforms other multi-objective optimization algorithms in terms of solution quality and computational efficiency. Additionally, this planner demonstrates significant advantages in both plan effectiveness and generation efficiency compared to others.

Keywords: tourism route planning; multi-objective optimization; parallel non-dominated sorting genetic algorithm-II; large language model; scenic spot tourist flow prediction; random forest algorithm

0 引言

近年来, 国内旅游市场持续升温, 景点游客接待量屡创新高。然而, 随之而来的游客体验感下降、景点拥堵等问题凸显, 亟待解决。此外, 随着游客对个性化旅行方案需求的显著增加, 传统的旅行路线规

划方法已经难以满足动态化、场景化的服务要求。

针对旅行路径规划问题, 常见解决方法可分为精确求解算法和智能优化算法两类。精确求解算法通过 Dijkstra、A*算法、动态 A*算法等经典路径搜索方法来实现最优路径的求解, 理论成熟且应用广

收稿日期: 2025-07-06; 录用日期: 2025-08-08.

基金项目: 国家自然科学基金项目 (72271240).

责任编委: 王凌.

[†]通信作者. E-mail: yangweiyi15@nudt.edu.cn.

本文附带电子附录文件, 可登录本刊官网该文“资源附件”区自行下载阅览.

泛. Wang 等^[1]对 A*算法进行了改进,通过在评价函数中引入路况影响因子,实现了考虑路况因素的最优路径求解,但是由于其计算复杂度较高,仅适用于景点较少场景.对于多目标问题,精确求解算法通常采用单目标优化框架而将其他目标作为约束条件的形式进行路径规划,易导致对多目标的潜在忽略.如 Wang 等^[2]通过筛选高体验、低成本景点并逐步扩展游览路径,直至超出时间约束的方法,实现了游览成本最小化与景点数量最大化的多目标优化.然而,由于贪心算法仅以景点体验感为路径构建依据,忽略了景点间距离对于时间的影响,导致在实际路径规划中难以保障景点数量最大化目标的有效达成.此外,以粒子群算法、蚁群算法等为代表的智能优化算法,作为一种受自然规律和生物行为启发的优化方法,通过模拟生物进化、物理现象等过程,实现从初始解到最优解的逐步逼近,为旅行路径规划问题的解决提供了更多可能^[3-5]. Estil-Les 等^[6]利用粒子群算法,规划了综合考虑距离、道路拥堵以及天气状况等因素的旅行路线; Liu 等^[7]则根据用户的历史签到数据识别用户的个性化兴趣偏好,并通过蚁群算法构建了个性化路径.然而,上述求解方案缺乏对景点拥挤度的考虑,使得旅行方案缺乏一定的实用性.徐书扬等^[8]提出了通过蚁群算法生成综合考虑景点热度以及拥挤程度因素的路线方案,但是,其仅以当前时刻的观测值替代全时段拥挤度预测,并未考虑到拥挤程度的动态时变性.

随着通用人工智能和大模型推理技术的进步,尤其是依托机器学习的景点状态预测^[9-10]以及基于大语言模型(LLM)的旅行需求理解和推理技术^[11-16]发展,为路线路径智能推荐问题的解决开辟了新思路.然而,以 Kambhampati 等^[17]的 LLM-Modulo 框架为例,由于大模型自身存在的领域知识不足^[18]、模型认知能力弱^[19]、幻觉输出^[20-22]等问题,该框架在复杂多目标景点路径规划问题上仍然存在局限性; de La 等^[23]在 LLM-Modulo 框架的基础上提出了旅行路线规划器(TRIP-PAL),为用户生成考虑景点推荐程度因素的旅行方案,然而,该框架基于精确求解规划器,无法实验复杂动态特性下的旅行路线规划.

综上所述,关于旅行路径规划技术已有诸多研究,但是仍然存在以下不足:1) 路径规划以基于单一优化方向的问题求解方法为主,无法适应用户在多种优化偏好下的旅行路线需求;2) 当前方法多数局限于静态路径规划问题的求解,然而,景点路径推荐问题具有强实时性和动态性,需要着重考虑景点的客流量和拥挤度等动态因素对于最终路径规划方案

的影响;3) 缺乏融合用户偏好推理和景点状态预测的旅行路径推荐技术研究,难以应对用户复杂旅行偏好需求.现有研究推荐多数将上述问题解耦并分别研究,缺乏考虑三者间的联系以实现旅行路径智能推荐.

鉴于此,本文从预测、推理、规划3个层面开展交互式旅行方案智能生成技术研究,具体展开需求智能推理、景点状态预测和多目标景点路径规划的融合研究,旨在为用户推荐一套智能、高效、个性化的旅行路径规划方案.本文主要内容如下.

1) 提出“预测、推理、规划”融合的基于大语言模型的交互式旅行方案智能生成框架.设计 LLM 信息处理模块,通过思维链提示词设计,引入大模型对用户自然语言下的个性化旅行需求进行推理、识别和旅行场景分类,同时,建立景点状态预测模块,引入随机森林回归算法以实现景点未来状态的有效预测.结合上述场景和预测数据作为输入,设计通用旅行路线规划器来生成旅行路径方案,以实现从用户指令输入到旅行方案输出的全流程技术,精准适配用户多样化需求,实现用户偏好推理与景点状态预测的深度融合.

2) 设计基于并行非支配排序遗传算法(PNSGA-II)的多目标旅行路线规划器.针对旅行路径规划问题中景点游览唯一性以及单日最长时限等约束,PNSGA-II 引入改进的交叉操作以及动态协同修复策略来实现对解空间的高效探索以及对不可行解的高效修复,并通过消融实验测试算法的有效性.在两类不同测试集上与3类经典多目标算法相比,PNSGA-II 算法在超体积指标、非支配解质量和算法耗时方面具有显著优势.

3) 开展旅行路径规划实验分析,在6组不同仿真用户测试案例下,将与现有最先进的大模型旅行方案推荐器 TRIP-PAL 以及基于 Deepseek 的直接问答交互模式进行对比.实验结果表明,所提出基于大语言模型的交互式旅行方案智能生成规划器(LITP)结合 LLM 需求理解推理优势和路线规划器算法性能优势,在方案生成速度、用户偏好理解准确度和可行方案数量方面提升明显.与 TRIP-PAL 相比,所提出规划器方案在缩短路径时间的同时,拥挤度最大降幅可达 25.8%,运行时间可缩短数 10 倍.

1 系统建模与问题定义

本节研究基于大语言模型的交互式旅行方案智能生成规划器的构建问题,该问题可描述如下:用户通过与大语言模型进行自然语言交互,提出自己的旅行偏好和路线要求. LITP 将基于用户所提需求与

历史同期及近期客流数据,最终生成旅行路径规划方案.为方便阅读,将本文涉及的相关数学符号进行统一定义,如表1所示.

表1 符号定义与说明

符号	说明
H	历史客流数据
F	客流数据预测值
y	客流影响因素的特征向量
D	距离矩阵,其中 $D_{i,j}$ 为景点 x_i 与景点 x_j 两地间的距离
t_i	景点游玩时间
$t_{ij}^{(k)}$	第 k 天景点 x_i 到景点 x_j 间平衡拥挤度的空闲时间间隔
T_{\max}	每日最大游览时长
$C_{i(t)}$	第 i 个景点在 t 时刻的拥挤程度
C	影响舒适度的最低拥挤临界值
C_{\max}	拥挤程度最大值
W_c	拥挤程度权重系数
W_{c_0}	拥挤程度权重系数基准值
$W_{c_{\max}}$	拥挤程度权重系数上限
N	用户提交的景点个数
K	用户提交的总游览天数
k	游览的第 k 天
x_{ik}	0-1变量,表示景点 i 是否安排在第 k 天
q_k	第 k 天的景点访问序列
h	酒店
σ	一天中空闲时间占总时长的最大比例
α	LLM根据总游览时长提供的单日游览时间差距项系数
β	拥挤度等级划分的指数项系数
γ	LLM根据用户需求所设定的时间与拥挤度平衡比
T_k	每日游览总时间
R	单日游览时间差距
ω	贪心算法初始化个体的比例
n	单日景点数量
l	单日时间基因长度
ε_1	游览时间项与路径距离项比例
$D_{\text{prev}(i),i}$	景点 x_i 与前序景点间的距离
$D_{i,\text{next}(i)}$	景点 x_i 与后继景点间的距离
Pred	景点状态预测模块
Sche	最终旅行方案
Plan	多目标旅行路线规划模块

本文研究聚焦于交互式旅行方案的智能生成问题,具体展开需求智能推理、景点状态预测和多目标景点路径规划的融合研究,该问题经简化后可描述为一个基于用户需求、历史客流以及多种客流影响因素的动态多目标路径规划问题.

首先,在进行景点的分配和规划时,不仅要考虑路径通勤时间最短,同时,需要确保包含景点停留时间的单日总时长不超过最大允许时长约束.此外,在多日路线规划中,景点的分日划分与路径规划具有

同等重要性.由于景点到酒店的往返距离直接影响到每日行程的时间成本,合理地景点进行天数划分可通过优化景点和酒店的空间布局,降低通勤时间.其次,景点的到达时间也直接确定了其拥挤度水平,因此,当景点序列确定时,其对应旅行路径方案的总时间与总拥挤度也随之确定.本问题的求解思路为生成满足所有约束条件的可行解,并根据时间与拥挤度协同优化目标导向的筛选规则,最终生成帕累托最优解集.具体如下:

$$F = \text{Pred}\{H, y\};$$

$$\arg \min(f_1, f_2).$$

$$\text{s.t. } \forall i \in N, \sum_{k=1}^K x_{ik} = 1; \quad (1)$$

$$T_k < T_{\max}; \quad (2)$$

$$\forall k, q_k[0] = q_k[-1] = h; \quad (3)$$

$$\sum t_{ij}^{(k)} \leq \sigma \cdot T_{\max}. \quad (4)$$

where $\text{Sche} = \text{Plan}\{D, t_i, C_i, N, K, \alpha\}$,

$$f_1 = \sum_{k=1}^K T_k + \alpha \cdot R,$$

$$f_2 = \sum_{k=1}^K \sum_{i \in \pi_k} W_c \cdot C_i^\beta.$$

系统建模以路线时间成本与拥挤程度的协同最小化为目标: f_1 为时间成本,由游览总时间 T_k 和单日游览时间差距 R 两部分组成.由于各景点的总游览时长固定,每日总游览时间 T_k 的和最小即等同于路径总通勤时间达到最小.此外,在目标函数 f_1 中引入单日游览时间差距 R 以实现均衡日均出行时间,降低单日游览时长差异过大的情况,从而提升方案的实际适用性.在目标函数 f_1 中,系数 α 用于调节 T_k 和 R 的权重,其取值由LLM通过推理确定. f_2 为拥挤成本,通过为不同区间的拥挤度 C_i 赋予差异化权重 W_c ,并引入指数函数系数 β 对高拥挤度区间施加更大的惩罚权重,强化高拥挤度场景在模型中的影响,降低其发生概率,从而有效引导模型优化方向.

式(1)保证景点分配的唯一性和完整性;式(2)定义单日游览时间限制,以确保单日游览时长不超过其上限;式(3)为路径的连续性约束,确保单日程均以酒店为起点和终点;式(4)为单日总空闲时间设定上限,其中通过在景点间设置合理的空闲时间间隔 $t_{ij}^{(k)}$,尝试以较低的时间成本换取较大拥挤度下降的可能,同时不显著影响用户体验.

此外,结合仿真实践需求给出如下合理假设:

1) 默认游客采用单一固定出行方式, 其行进速度恒定, 路径时间与距离成正比, 简化了通勤时间的计算复杂度, 同时, 符合多数城市内短途旅行中游客倾向于选择单一交通方式的实际场景。

2) 默认游客在同一城市的住宿酒店不发生改变. 该假设减少了住宿变动带来的额外成本计算, 且符合多数城市旅行中固定住宿的普遍习惯, 为多日

行程优化提供稳定约束。

2 智能规划器

在此规划器中, 由 LLM 信息处理模块接收用户信息, 将处理后的信息分别传入至景点状态预测模块和多目标旅行规划器, 经协同处理后生成最终旅行方案. 所建立基于大语言模型的交互式旅行方案智能生成规划器的流程如图 1 所示。

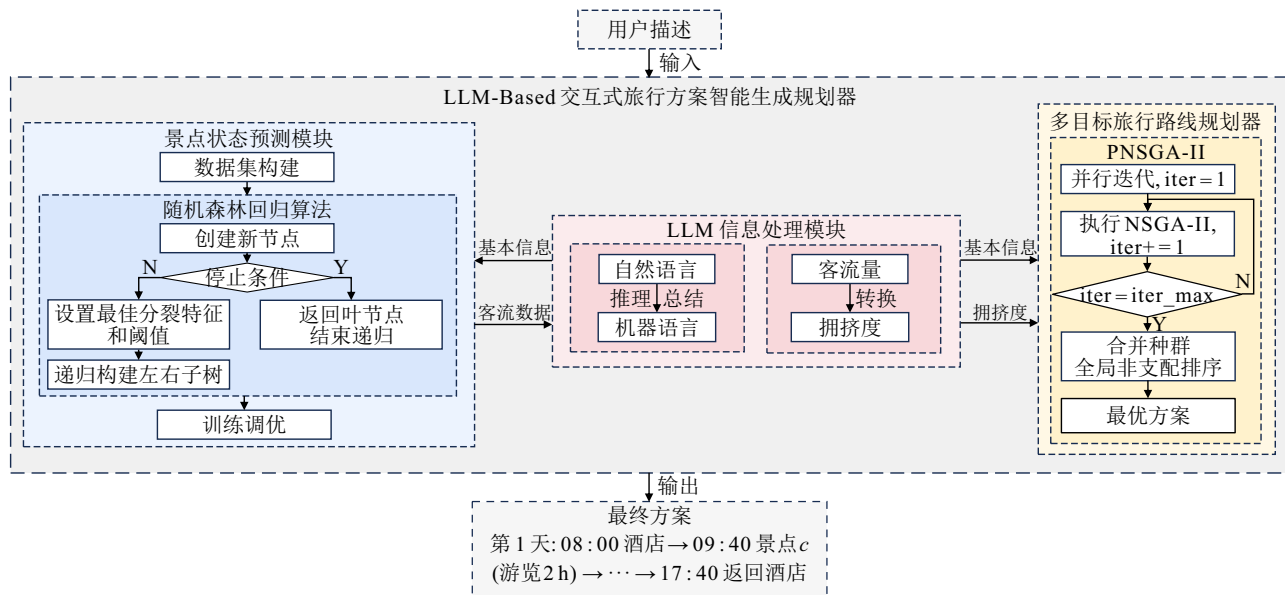


图1 规划器流程

所提出规划器框架包含 3 个核心部分, 分别为 LLM 信息处理模块、景点状态预测模块和多目标景点路径规划器. 1) LLM 信息处理模块: 根据 LLM 与用户的语言交互进行信息提炼、推理和转化, 将用户的旅行意向转化为机器可处理的形式化表示; 2) 景点状态预测模块: 结合节假日信息、天气信息等因素下的历史客流量数据, 该模块基于随机森林回归算法对景点的未来客流量进行预测, 以得到精确至小时级的景点客流预测数据; 3) 多目标旅行路线规划器: 通过 LLM 信息处理模块将客流数据转化为景点拥挤程度后, 多目标旅行路线规划器会结合目标景点、出行时间、景点状态预测拥挤程度等信息, 利用 PNSGA-II 进行路径规划, 最终输出符合用户个性化旅行需求的高效出行方案. 三者协同联动, LLM 信息处理模块为其他两个模块提供基础输入, 并负责景点状态预测模块结果的转化, 规划器则基于前两者的结果完成最终方案生成。

2.1 LLM 信息处理模块

LLM 信息处理模块接收用户以自然语言描述的旅行偏好信息和路线要求, 利用大模型对其进行推理、识别和旅行场景分类, 基于用户出行时长预估大致可游览的景点数目, 最终将用户需求信息 (如目

标城市、计划游览景点个数、旅行天数和预计出行时间等) 以及旅行方案客观信息 (如天气、住宿酒店、交通形式等) 转换为机器可处理的形式化表示, 并生成信息集传入规划器, 以待后续模块调用。

当客流数据预测完成后, 景点状态预测模块将景点各时段的客流数据重新输入至 LLM 信息处理模块. 该模块结合景点面积等信息, 将客流量转换为拥挤度, 并输出至多目标旅行路线规划器。

2.2 景点状态预测模块

随机森林算法作为一种兼具高准确率、抗过拟合能力以及强噪声容忍度的算法, 能够克服协变量间的复杂交互作用且无需预设函数形式, 较神经网络更不易过拟合, 也规避了支持向量机对于使用者技巧的依赖, 在各领域应用广泛. 景点状态预测模块基于此算法, 通过整合历史同期以及近期客流数据、天气预测数据和历史天气信息, 系统性建模影响客流量的多维因素, 实现小时级的精确客流量预测. 具体建模流程包含以下核心步骤。

1) 数据集构建和特征工程: 以历史客流数据为基础, 结合特征变量 (包括天气状况、周末标识、节假日标识、游览时段等) 构建训练数据集. 为解决特征值缺失问题, 采用均值插补法进行预处理, 并通过

特征分箱策略将数据集按照客流量范围进行区域划分. 该策略确保每棵决策树仅依赖基于特定客流量区域数据进行训练, 从而提升局部预测精度.

2) 模型构建和训练机制: 采用随机森林算法构建预测模型, 其决策树生成过程通过遍历所有特征的可能阈值, 选择使得左右子节点加权均方误差 (MSE) 最小的特征阈值组合作为节点的分裂条件, 并通过递归方式构建决策树直至到达最大树深或叶节点创建完毕. 最终预测结果由森林中所有决策树预测结果加权平均后获得, 以此降低单棵决策树的过拟合风险.

算法1 随机森林预测模型.

输入: 训练数据集 H , 特征向量 y ;

输出: 单个随机树模型 T .

```

1. function BestSplit( $H, y$ ):
2.  $m \leftarrow \infty$  //初始MSE值
3. for  $r \in R$  do //遍历所有候选特征
4.  $V \leftarrow \text{SortUnique}(H[r])$  //  $V$  为该  $r$  特征的所有可能值数组
5. for  $v \in V$  do //遍历所有可能阈值
6.  $Hl, Hr \leftarrow \text{SplitData}(H, r, v)$  //根据特征  $r$  和阈值  $v$  将数据集  $H$  划分为左右两部分
7.  $m' \leftarrow \text{CalculateMSE}(Hl, Hr)$  //计算当前划分的加权均方误差
8. if  $m' < m$  then
9.  $m \leftarrow m'$ 
10.  $s \leftarrow (r, v, Hl, Hr)$  //更新最佳分裂点信息
11. return  $s$ 
12. function BuildDecisionTree( $H, R, \text{depth}$ ):
13.  $n \leftarrow \text{CreateN}(H)$  //创建新节点
14. if StopCondition( $H$ ) then //StopCondition() 为到达最大树深或叶节点创建完毕
15.  $n.\text{SetLeaf}(\text{CalculateMean}(H))$  //叶节点存储目标均值, CalculateMean() 为计算均值函数
16. return  $n$  //返回叶节点, 结束当前递归
17.  $s \leftarrow \text{BestSplit}(H, R)$  //找出最佳分裂点
18. if  $s$  not exists then
19.  $n.\text{SetLeaf}(\text{CalculateMean}(H))$  若未找到, 则设为叶节点并存储目标均值
20. return  $n$ 
21.  $cl \leftarrow \text{BuildDecisionTree}(s.Hl, R, \text{depth}+1)$ ,  $cr \leftarrow \text{BuildDecisionTree}(s.Hr, R, \text{depth}+1)$  //递归构建左右子树
22.  $n.\text{SetSplit}(s.r, s.v)$  //设置当前节点的分裂特征和阈值

```

23. $n.\text{AddChildren}(cl, cr)$ //添加左右子节点

24. return n

25. $T \leftarrow \text{BuildDecisionTree}(H_1, y_1, \text{max_depth})$ //划分数据集建立单个随机树

3) 模型优化和验证: 在此基础上, 采用时间序列交叉验证法和网格搜索对该模型进行仿真训练调优, 通过滚动窗口划分训练集和验证集, 确保时间序列数据的时序特性被充分保留, 同时, 利用网格搜索探索超参数空间, 通过穷举候选参数组合的交叉验证表现确定最优参数配置.

当需要对特定时间段内的景点客流量进行预测时, 模型首先提取待预测时段的特征向量, 随后在历史数据中检索特征相似的历史时段, 通过已训练的随机森林模型输出预测结果.

2.3 多目标旅行路线规划器

针对基于景点客流量的旅行路线智能推荐问题的多目标优化问题特性, 本节构建基于并行非支配排序遗传算法 (PNSGA-II) 的多目标旅行路线规划器. 所提出 PNSGA-II 算法在非支配排序遗传 (NSGA-II) 算法的基础上做出了 3 点适应性改进: 1) 构建并行迭代机制, 执行多轮独立遗传算法迭代, 积累每轮迭代产生的帕累托前沿解集合并, 最终对合并的全局解集进行非支配排序; 2) 设计基于基因频率哈希表与景点递归迁移操作的动态协同修复策略, 以实现冲突动态消解; 3) 采用改进的分段交叉的形式, 设计基于自然时间分段的交叉单元划分策略, 在规避传统随机切割操作对现有行程结构破坏的同时, 确保分段交叉机制能够继承父代的优良基因. 具体流程如图 2 所示.

2.3.1 算法流程设计

1) 种群初始化.

为提升收敛效率、维持种群多样性, PNSGA-II 算法采用混合初始化策略. 具体而言, 将种群初始化过程分为两个层级: 景点分配层和路径生成层. 前者负责确定各景点在行程天数中的分配方案, 后者则聚焦于优化单日内的路径和时间规划.

在景点分配层中, 种群个体通过混合初始化策略生成: 占比为 ω 的个体采用改进的贪心算法进行景点分配; 剩余个体采用随机分配机制, 以确保解空间的充分探索.

路径生成层则同时构建单日路径序列基因和时间基因. 路径序列基因通过两种策略生成: 最近邻点优化策略和随机排列策略. 最近邻点优化策略以酒店为起点, 通过迭代添加最邻近景点的方式构建路

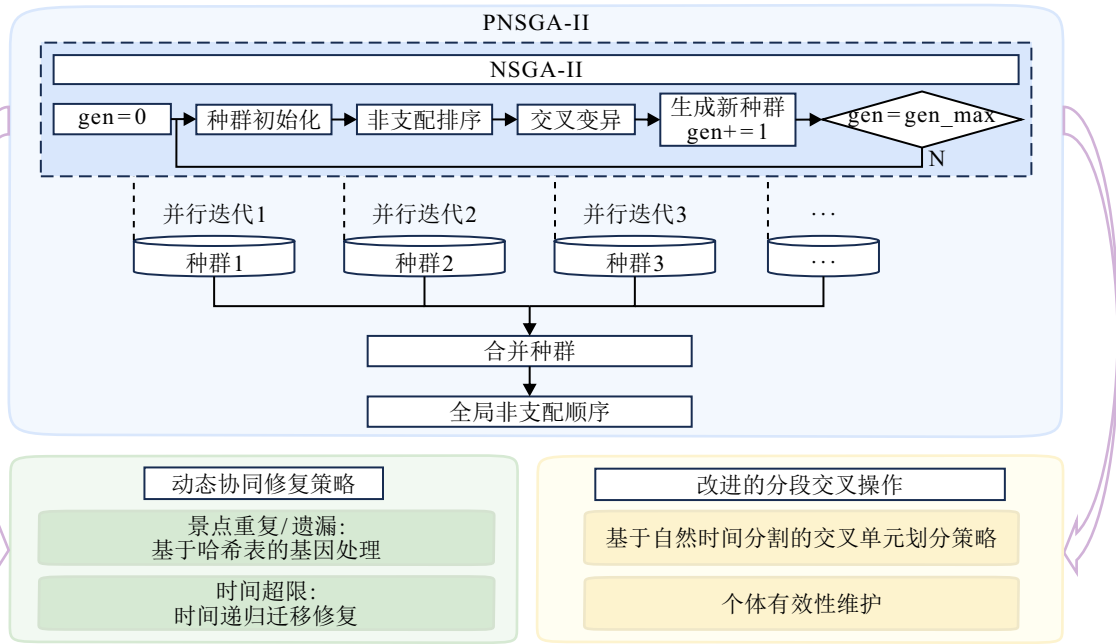


图2 PNSGA-II 算法流程

径,同时实时更新时间预算;随机排列策略则通过随机生成景点序列,若总耗时超限,则逐步移除末尾景点直至满足约束。

时间基因采用动态自适应机制进行初始化,基于单日景点数量自适应调整时间基因长度.初始空闲时间值在一定范围随机赋值,以保留行程的灵活性并增强种群的多样性。

2) 适应度函数设计.

针对问题中路线时间成本和拥挤程度的双优化目标,PNSGA-II 设计了具有阈值响应的动态拥挤感知权重系数,以实现景点拥挤程度对适应度函数的差异化调控.当景点拥挤程度超过临界值时,通过 W_c 值的增长扩大拥挤程度适应度函数的增长程度.权重系数设计如下所示:

$$W_c = W_{c_0} \cdot \left[1 + \frac{\max(C_{i(t)} - C, 0)}{C_{\max} - C} \right].$$

其中: W_{c_0} 为拥挤权重基准值; C 为拥挤度响应阈值,标志着用户体验分界点,一旦拥挤程度超越此等级,用户体验将急剧下降.当 $C_{i(t)} \leq C$ 时, W_c 保持基准权重;当 $C_{i(t)} > C$ 时,触发响应,通过增长的权重系数保障用户体验,并规定 $W_{c_{\max}}$ 以确保时间的优秀性。

此外,算法将时空约束、行程均衡、体验质量等复杂因素编码为可优化目标,通过动态权重、惩罚效应等构建以下双适应度函数。

① 时间维度适应度函数为

$$Fit_1 = \sum_{k=1}^K T_k + \alpha \cdot R, \tag{5}$$

$$T_k = \sum_{i=1}^{|q_k|} \frac{D_{q_k[i-1],q_k[i]}}{v} + \sum_{i \in q_k} t_i + \sum t_{ij}^{(k)}, \tag{6}$$

$$R = \frac{1}{K} \sum_{k=1}^K \left(T_k - \frac{1}{K} \sum T_k \right)^2. \tag{7}$$

其中:式(5)为时间维度适应度函数,由累积时间成本 T_k 和时间均衡项 R 两部分组成;累积时间成本 T_k 由式(6)给出,为用户在第 k 天的游览时间、路程时间与空闲时间的和;时间均衡项 R 由式(7)给出,为累积时间成本的标准差。

② 拥挤程度适应度函数如下所示:

$$Fit_2 = \frac{1}{\gamma} \cdot \sum_{k=1}^K \sum_{i \in q_k} W_c \cdot C_i^\beta.$$

其中:时间依赖型拥挤度 C_i 通过景点状态预测模型输出的各景点实时客流预测值而得到,基于游客在各景点的游览时间戳呈现时变特性;由于拥挤体验阈值效应的存在,引入指数函数强化高拥挤等级的惩罚效应, β 和 γ 为条件拥挤程度适应度函数的参数,以平衡用户设定时间与拥挤度。

2.3.2 动态协同修复策略

针对在遗传算法中可能会产生的违反唯一性约束或游览时间约束的问题,本节提出一种动态协同修复策略:通过基因频率哈希表与贪心-动态规划的混合迁移方法来实现约束的冲突消解。

1) 基于哈希表的基因处理机制.

基于哈希表的基因处理机制通过记录各景点在行程中的出现频次构建基因频率哈希表,以此快速检测重复或遗漏景点.对于重复景点基因,随机保留

一天的景点,并将其他天中的重复景点替换为随机未访问景点,若超时,则用未访问景点中耗时最短者替换.遗漏景点基因则贪心插入剩余时间容量最大的天数.此外,时间基因长度随景点数量扩展或截断.

2) 时间递归迁移修复机制.

为修复违背空闲时间约束(如式(4)所示)的时间基因,设计时间递归迁移修复策略.该策略定义各景点的迁移优先级如下所示:

$$P = \varepsilon_1 \cdot t_i + \frac{D_{\text{prev}(i),i} + D_{i,\text{next}(i)}}{2}. \quad (8)$$

其中: $D_{\text{prev}(i),i}$ 为景点 x_i 与路径中上一个景点间的距离, $D_{i,\text{next}(i)}$ 为景点 x_i 与路径中下一个景点间的距离.式(8)通过 $(D_{\text{prev}(i),i} + D_{i,\text{next}(i)})/2$ 表征新增景点 i 所导致的路径距离增量,并引入权重比例参数 ε_1 ,用于调节该景点的游览时间 t_i 与路径距离增量在迁移优先级计算中的权重.

在完成景点迁移优先级的量化定义后,采用贪心-动态规划混合迁移策略:贪心迁移最低优先级的景点至时间余量最大的行程天数中,并重新规划当日路径;进一步地,递归修复其他超限天数,迭代至所有天数均满足时间约束条件或达到预设最大迭代次数,实现全局约束消解.

算法2 动态协同修复策略.

输入: 当前个体 g , 距离矩阵 D , 最大时长 T_{max} , 天数 K , 景点数 N , 游玩时间 t_i , 空闲时间 $t_{ij}^{(k)}$;

输出: 修复后个体 s .

1. $s \leftarrow g$
2. $h \leftarrow \text{Createhash}(s)$ //建立各景点出现频率哈希表
3. $U, R \leftarrow \text{SpotsFrequency}(h)$ //通过哈希表筛选出遗漏景点集和重复景点集
4. for $r \in R$ do//对于重复景点集合 R 中的每个景点 r
5. $s, U \leftarrow \text{Replace}(U, K, r)$ //随机选择一天保留 r , 其余天数替换 r 为 U 中随机景点 m , 并对 U 进行更新
6. while isOvertime(k) do//第 k 天超时
7. $s, m, U \leftarrow \text{Replace}(U, m, t_i)$ //从 U 中选取 t_i 最小的 m' 替换 m , 更新 U
8. for $m \in U$ do
9. $s, k' \leftarrow \text{InsertMost}(m, s)$ //将 m 插入 s 中剩余时间最多的 k' 天
10. depth $\leftarrow 0$
11. function adjust_day(n, depth)://修复超时的递归函数
12. while isOvertime(n) do

13. $\Delta t \leftarrow \text{OvertimeCalculate}(k)$ //计算第 n 天所超时长
14. $s, t_{ij}^{(n)} \leftarrow \text{Compression}(n, \Delta t, t_{ij}^{(n)})$ //尝试按照比例压缩对等待时间进行压缩
15. if isOvertime(n) then
16. $P \leftarrow \text{Priority}(t_i, D)$ //计算景点迁移优先级
17. $s \leftarrow \text{Movespots}(s, P)$ //迁移优先级最低的景点到剩余时间最多的 k' 天
18. if isOvertime(k') & depth < max_depth then//max_depth 为最大递归深度
19. adjust_day($k', \text{depth} + 1$)
20. for $n \in K$ do
21. adjust_day($n, 0$)
22. return s

2.3.3 基于自然时间分割单元的分段交叉操作

传统遗传算法的随机交叉操作可能会对现有行程在时间上的安排和约束产生破坏.鉴于旅行路线规划问题具有以日为单位的行程单元划分特性,本节提出基于自然时间分割的交叉单元划分操作.该操作将按日划分交叉单元,并在各单元内部实施分段交叉操作,从而避免破坏行程的时间连续性.

算法3 基于自然时间分割单元的分段交叉策略.

输入: 父代个体 p_1, p_2 ;

输出: 子代个体 c .

1. $u \leftarrow \text{RandomUnit}(p_1, p_2)$ //随机选取单元
3. if length(u_1) ≥ 1 & length(u_2) ≥ 1 then
4. $c \leftarrow \text{Exchange}(u, p_1, p_2)$ //在交叉单元内随机选取两切点交换片段产生子代
5. $c \leftarrow \text{RepairTime}(c)$ //时间基因长度校准修复
6. $c \leftarrow \text{Repair}(c)$ //调用动态协同修复策略函数
7. return c

为保证父代优良特性的延续,仅选取一个行程天数作为交叉单元进行交叉,在被选中的单元中,随后在该单元内随机确定两个切割点,以实现路径序列基因与时间基因的协同交换.在子代个体生成后,调用动态协同修复策略函数进行个体的有效性维护,并通过时间基因维度校准确保 n 景点对应 $n - 1$ 空闲时间.该改进分段交叉操作保证子代在维持自身可行性的同时继承父代的优秀基因结构,并实现了解空间的高效探索和约束满足的双重目标.

3 实验验证

本节将通过仿真实验讨论所提出景点状态预测

模块、旅行路线规划算法以及 LITP 的表现. 首先, 对景点状态预测模块开展准确度评估实验, 以验证其在预测不同场景下景点客流量的精度和可靠性; 然后, 在 12 个不同场景下, 对旅行路线规划算法开展算法对比实验和算法消融实验, 以验证 PNSGA-II 在多目标优化中的性能提升以及关键模块对于整体效果的贡献; 最后, 对 LITP 进行规划效果对比实验, 与 Deepseek^[24]、TRIP-PAL^[23] 旅行方案规划器在 6 组不同算例下展开对比, 对比指标包括方案效果、求解效率以及有效方案个数, 以全面验证 LITP 在实际应用中的优越性和综合表现.

3.1 LLM 信息处理模块

本节根据景点客流时序特征, 通过仿真构建 3 类典型场景: 1) 持续高流量型景点: 热门景点, 客流量始终保持在较高水平; 2) 持续低流量型景点: 冷门景点, 客流长期处于低位; 3) 周期脉冲型景点: 客流量具有显著的周期性波动, 周末和节假日期间出现客流高峰, 工作日则回落至较低水平. 算例以中等规模景点为基准设定客流量: 日间时段 (6:00 ~ 20:00), 高客流型景点客流范围为 1.0 万人次/h ~ 1.6 万人次/h; 低客流型景点为 0.2 万人次/h ~ 0.6 万人次/h; 周期脉冲型景点则根据周末和工作日差异化设置, 周末执行高客流标准 (1.0 万人次/h ~ 1.6 万人次/h), 工作日按照低客流标准执行 (0.2 万人次/h ~ 0.6 万人次/h). 夜间时段, 高客流型景点的客流量范围设定为 1000 人次/h ~ 2000 人次/h; 低客流型景点为 10 人次/h ~ 200 人次/h; 周期脉冲型景点延续周末高客流、工作日低客流的模式, 对应上述昼夜时段的高低客流标准动态调整. 采用均方根误差 (RMSE)、平均绝对误差 (MAE) 和决定系数 (R^2) 共 3 项量化指标, 从预测精度和拟合优度两个层面验证所提出模块在各场景下的预测性能. 客流量预测值与真实值对比如图 3 所示.

基于对景点进行客流预测的问题特性, 分析重点聚焦于日间场景, 具体指标数值如表 2 所示.

RMSE 反映了预测值与实际值间误差的平均波动程度, 放大较大误差的影响, 常用于评估模型对于极端误差的容忍度, 且相较于均方误差 (MSE) 更为直观. 在场景 1 中, 日间 RMSE 平均值为 665.5 人次, 占对应流量范围的 4.16% ~ 6.66%; 场景 3 的 RMSE 平均值为 881.9 人次, 占比为 5.51% ~ 8.82%, 最大误差均控制在合理范围内, 表明该模型在这两个场景下具有良好的预测精度和误差控制能力. 而在场景 2 中, RMSE 占流量范围为 7.91% ~ 23.72%, 误差

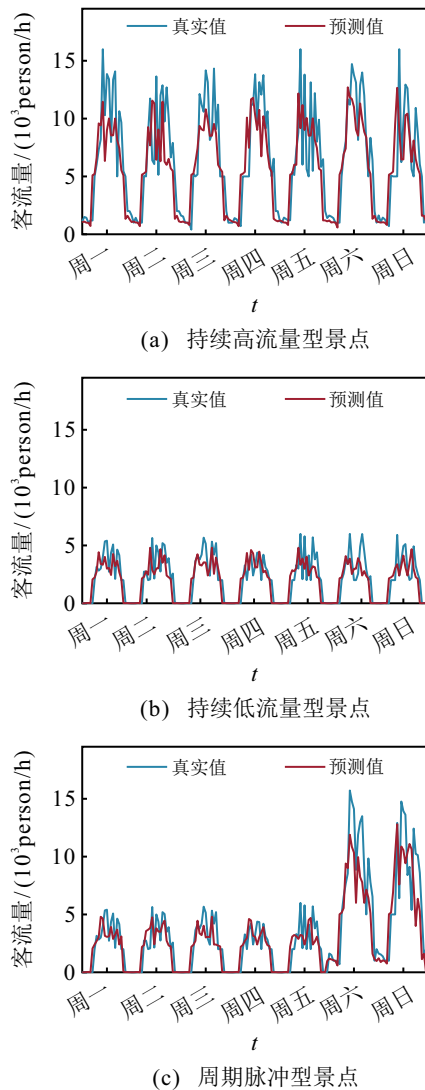


图3 3类典型场景下客流量预测值与真实值对比

表2 不同场景下模型预测准确度

场景	MSE	日间MSE	日间RMSE	MAE	日间MAE	R^2
1	285430.9	442851.7	665.5	324.9	476.0	0.95
2	139205.0	224970.8	474.3	223.5	357.7	0.964
3	531341.4	777735.2	881.9	403.3	575.5	0.980

幅度波动更为显著, 但是模型仍然展现出较优的预测性能, 约 474 万人次/h 的预测偏差在 0.2 万人次/h ~ 0.6 万人次/h 的低客流场景下处于可接受范围, 进一步验证了该模型在不同客流等级下的适应性.

MAE 直接体现预测误差的绝对值水平, 体现预测的平均偏差程度, 常用于评估模型的整体预测偏差. 在场景 1 中, MAE 为 476 人次, 占对应客流范围的 2.98% ~ 4.76%; 在场景 3 中, MAE 为 575.5 人次, 占比为 3.6% ~ 5.76%; 在场景 2 中, MAE 为 357.7 人次, 占比为 5.96% ~ 17.89%. 其中: 场景 1、场景 3 误差占比处于较低区间, 展现出稳定的高精度预测能力; 尽管场景 2 的误差占比区间跨度较大, 但是其绝对误差控制在 360 人次左右, 结合低客流特征, 整

体仍然处于可控范围内。

R^2 衡量模型对于数据波动的解释能力,在3种场景下,该模型 R^2 值均保持在0.95以上,能够解释95%以上的客流波动,体现出算法在趋势预测方面的优异性能。

综合RMSE、MAE以及 R^2 三项指标分析,该模型在3类场景下均展现出稳定的预测精度和优异的趋势拟合能力,尤其对于存在高客流情况的景点客流预测展现出更加显著的优势。

3.2 旅行路线规划算法实验

根据实际生活中的不同情形,本节分别构建12组仿真算例对规划器算法进行多维验证分析。具体而言,分别构建以下两种算例,分别包含3种典型旅行场景:

1) 在景点客流量层面,高峰时段高密度客流、中密度客流以及闲时低密度客流3类典型场景算例,模拟节假日、周末以及工作日的差异化出行特征并验证模型在各类客流场景下的适应性;

2) 在景点游览时长层面,设置景点数量密集但是游览时长较短的打卡式景点集、景点数量较少但是耗时较长的深度游览景点集以及混合型景点集(包含短时间和长时间游览特点),以验证模型在不同类型景点集群下的有效性并模拟3种典型出行方式,即耗时短的打卡式游览、长时间的深度式游览以及综合游览模式。

最终,从输出方案的总时间、总拥挤度、超体积指标以及运行时间4个方面对算法性能进行全面评估。实验相关参数 $t_{ij}^{(k)}$ 、 C 、 σ 、 α 贴合真实场景取值,分别取值为 $[0, 3]$ 、8、0.3、0.3; C_{\max} 为单个景点的拥挤度上限10; ω 为种群初始化时采用贪心算法进行初始化的个体比例,设定为50%; W_{c_0} 设置为1.5,为拥挤度优化提供基础调节力度; $W_{c_{\max}}$ 设置为6,作为取值上限,避免高拥挤场景下权重过度增长导致单一指标极端优化,保障时间与拥挤度多目标协同平衡;同时,为保证最终方案中时间与拥挤度的平衡,引入参数 $\gamma = 4$,表示由LLM根据用户需求设定的时间与拥挤度平衡比;将 ε_1 设为较大值7/3以减少游览时间项与路径距离项单位不统一所带来的影响。

拥挤度相关参数 β 赋值方式如下所示:

$$\beta = \begin{cases} 1, & C_i \in [1, 6); \\ 2, & C_i \in [6, 9); \\ 3, & C_i \in [9, 10]. \end{cases} \quad (9)$$

构建与拥挤程度正相关的分级调节模式,与动态权重共同作用,形成双重调节机制。

3.2.1 算法对比实验

本节将所提出PNSGA-II算法与NSGA-II算法、多种群合作学习算法(MSCL)^[25]以及基于禁忌搜索的非支配遗传排序算法(NSGA-II-TS)^[26]进行对比分析,验证所提出算法的有效性。在各算法所得帕累托前沿解集中,分别选取两个非支配解(以目标函数 f_1 优先和目标函数 f_2 优先)进行比较,并将算例划分为12种场景。其中:单数场景对应时间优先方案,双数场景对应拥挤度优先方案。场景1~场景6按照顺序对应算例1;场景7~场景12对应算例2的不同情况,具体包括:场景7和场景8对应打卡游览模式,场景9和场景10对应综合游览模式,场景11和场景12对应深度游览模式。所提出算法的进化代数设为15,并行迭代2次;其余算法进化代数均设为30,初始种群数均设为200。所有实验结果均为10次实验的平均值。

表3为不同算例下各算法的求解结果,包括两个特殊非支配解(时间优先和拥挤度优先)的总时间、总拥挤度、程序运行所用时间以及对应的超体积指标值(HV)^[27]。由表3中12个算例的结果可知,PNSGA-II在10次独立运算所取得的平均结果和HV值均优于或等于其余对比算法,其中11个算例的结果优于其余对比算法。该结果表明了PNSGA-II在求解多目标旅行路径规划问题上的优势和竞争力。

进一步对HV值进行详细分析,可以看出:在本问题背景下,仅在耗时短的打卡游览模式中,所提出算法与对比算法NSGA-II的HV值较为接近,但是仍然保持微弱优势;而在其余所有场景下,所提出算法的HV值均显著高于其他对比算法。特别是在中密度客流、闲时低密度客流以及综合游览模式这3类典型场景下,PNSGA-II算法展现出卓越的优化效果,显著优于同类方法。这一优势源于算法的核心机制:通过执行并行迭代,结合基于自然时间分割的分段交叉操作和动态协同修复策略,PNSGA-II在提升全局搜索能力的同时,有效维持了解空间中的个体多样性和高效性,从而确保种群能够更贴近真实Pareto前沿并覆盖更广泛的目标空间。

通过方案效果对比可见,所提出算法在所有测试场景下均展现出对拥挤度的显著优化能力。图4为不同景点数量下的方案拥挤度对比。由图4可见,对于场景8~场景12,所提出算法在拥挤度优先方案下的拥挤度优化效果随着景点数量增加而逐步提升,特别是在景点数量较多的打卡式游览模式中,优化效果最为显著,最多可较NSGA-II降低36.2%的拥挤度。而在时间优化层面,当景点数量较少且单

表3 12个算例下各算法结果对比

场景	PNSGA-II			NSGA-II			MSCL			NSGA-II-TS		
	(f_1, f_2)	HV	T	(f_1, f_2)	HV	T	(f_1, f_2)	HV	T	(f_1, f_2)	HV	T
1	(29.5, 71.1)	682.8	6.6	(30.7, 76.6)	77.6	6	(32.5, 77.2)	25.4	23.2	(31.9, 79.0)	92.1	45
2	(31.3, 65.5)			(32.2, 65.9)			(32.5, 77.0)			(32.5, 75.6)		
3	(29.6, 53.4)	794.0	5.5	(30.4, 58.0)	306.6	3.9	(32.5, 56.4)	250.6	9.5	(32.2, 58.4)	246.7	46.8
4	(31.5, 46.9)			(32.2, 51.0)			(32.9, 55.2)			(32.7, 57.1)		
5	(29.6, 15.4)	287.9	6.5	(30.7, 20.8)	83.9	9.1	(32.7, 17.7)	89.4	16.5	(32.7, 19.9)	77	51
6	(31.5, 7.8)			(32.0, 13.8)			(34.7, 15.2)			(34.1, 18.5)		
7	(29.7, 40.3)	123.9	7.5	(30.6, 47.2)	90.7	9.5	(32.7, 51.6)	28	4.6	(32.6, 47.2)	58.4	17.3
8	(31.3, 29.8)			(31.8, 37.6)			(34.7, 44.6)			(33.1, 43.9)		
9	(29.0, 31.7)	465.1	5.9	(30.1, 32.8)	168.3	5.4	(32.5, 33.1)	125.9	13.6	(30.9, 39.2)	104.1	41.4
10	(30.6, 21.4)			(31.1, 27.3)			(33.0, 31.2)			(31.6, 36.2)		
11	(27.4, 23.5)	219.3	5.9	(27.9, 24.8)	80.5	3.3	(28.6, 25.0)	63.8	84.7	(27.6, 28.4)	49	17.6
12	(29.2, 19.0)			(29.1, 19.5)			(30.7, 22.4)			(27.8, 24.8)		
统计	12/12	6/6	1/6	1/12	0/6	4/6	0/12	0/6	1/6	1/12	0/6	0/6
排名	1			2			4			3		

注: 标粗数据为当前场景下算法运行最优值




图4 不同景点数量下的方案拥挤度对比

景点游览时长较长时, 所提出算法优化效果较为明显, 相较于 NSGA-II 求解方案的最大降幅可达 6.2%; 在景点数量密集的场景下, 所提出算法的时间优化平均提升幅度为 2.6%。

由表 3 对实验结果进行进一步分析发现, 相较于 MSCL 与 NSGA-II-TS 混合算法, 所提出算法在全部测试场景中展现出明显优势. 除场景 12, 所提出算法在时间和拥挤度两个优化目标上均取得了最优结果, 两项指标同时达到了最低值. 对于场景 12, 尽管 NSGA-II-TS 使得规划时间降低了 4.8%, 但是, 其生成方案的拥挤度却高出所提出算法 27.2%, 这一结果充分体现了所提出算法在时空协同优化方面的良好性能, 不仅在多目标协同优化中表现出显著优势, 还可有效规避单一指标优化可能会引发的次优解风险. 在运行时间方面, 虽然 NSGA-II 在更多场景下取得了最优值, 但是, 所提出算法与其运行时间差距最大不超过 3 s; 同时, 该算法运行时间显著低于其他对比算法, 且在所有场景中均稳定控制在 10 s 内, 展现出良好的运算性能和高效的求解能力. 这一结果表明, 所提出算法在保证求解质量的同时, 具备与经典算法相当的计算效率, 展现出良好的综合性

能.

3.2.2 算法消融实验

为验证所提出策略的有效性, 本文设计如下 3 组消融实验: 1) 完整算法 PNSGA-II; 2) 将 PNSGA-II 中基于自然时间分割的分段交叉操作替换为 NSGA-II 中模拟二进制交叉算子 (SBX); 3) 去除 PNSGA-II 算法中动态协同修复策略部分, 仅保留其改进交叉操作.

表 4 为不同算例下各消融实验组的求解结果, 图 5 为不同客流密度场景下的方案拥挤度指标降低百分比. 通过表 4 和图 5 的实验结果对比可以发现: 在保留动态协同修复策略的前提下, 用传统 SBX 交叉替代基于自然时间分割的分段交叉操作后, 方案拥挤度在 3 种典型游览模式下分别上升了 15.9%、8.9% 和 13.6%, 在低客流场景中最大增幅可达 15.8%; 同时, 行程时长增加了 1 h ~ 2 h 左右, 尤其是在景点密集场景中这一差异更为明显, 行程时间增长幅度可达 6.1%; 而在保留改进交叉操作但是移除动态协同修复策略的情况下, 低客流场景的拥挤度增长可达 9.9%; 在时间优化层面, 行程时长则出现了 0.5 h ~ 2 h 不等的增加. 该结果表明了改进交叉操作与动态协同修复策略在引入和维护高质量个体后的有效性.

3.3 智能规划器对比实验

为验证所提出 LITP 的最终方案效果, 本节将其与直接基于 Deepseek 提问^[24] 以及 TRIP-PAL^[23]——将 LLM 与自动求解器相结合的旅行方案生成规划器进行对比分析.

Deepseek 作为大语言模型, 无法直接处理多目

表4 不同算例下各消融组的求解结果

场景	PNSGA-II		替换改进的交叉操作			移除修复策略		
	HV	(f_1, f_2)	HV	(f_1, f_2)	Gap/%	HV	(f_1, f_2)	Gap/%
1		(29.5, 71.1)		(30.1, 73.8)	(2.0, 3.7)		(30.1, 73.3)	(2.0, 3.0)
2	682.8	(31.3, 65.5)	3050.3	(32, 65.1)	(2.2, -0.6)	1390	(31.8, 66.3)	(1.6, 1.2)
3		(29.6, 53.4)		(30.4, 57.0)	(2.6, 6.3)		(30.1, 54.8)	(1.7, 2.6)
4	794.0	(31.5, 46.9)	683.2	(32.4, 48.6)	(2.8, 3.5)	683.6	(31.3, 49.7)	(-0.6, 5.6)
5		(29.6, 15.4)		(30.2, 18.3)	(2.0, 15.8)		(30.4, 17.1)	(2.6, 9.9)
6	287.9	(31.5, 7.8)	269.8	(33, 7.9)	(4.6, 1.3)	263.6	(32.8, 8.6)	(4.0, 9.3)
7		(29.7, 40.3)		(29.9, 47.9)	(0.1, 1.6)		(30.1, 43.5)	(1.3, 7.3)
8	123.9	(31.3, 29.8)	244.8	(33.2, 32.6)	(5.7, 8.6)	89.3	(32.2, 34.5)	(2.8, 13.6)
9		(29.0, 31.7)		(29.4, 33.1)	(1.4, 4.2)		(29.4, 31.3)	(1.4, -1.3)
10	465.1	(30.6, 21.4)	456	(32.6, 23.5)	(6.1, 8.9)	445.4	(32.3, 24.2)	(5.3, 11.6)
11		(27.4, 23.5)		(28.6, 27.2)	(4.2, 13.6)		(28.5, 26.3)	(3.9, 10.7)
12	219.3	(29.2, 19.0)	164.2	(30, 19.4)	(2.7, 2.1)	164.2	(29.6, 19.6)	(1.4, 2.9)

注: 标粗数据为当前场景下算法运行最优值.




图5 不同客流密度场景下的方案拥挤度指标降低百分比

标优化问题 (时间和拥挤度), 因此仅基于时间维度进行路径规划. 通过多次提问获取 10 组有效解, 并人工计算各解对应路径的拥挤度. 最终得到通过 Deepseek 直接提问以及 TRIP-PAL 求解所得到的 10 次旅行方案结果的均值对比.

表 5 为旅行路径规划器对比结果. 由表 5 实验结果可见: 与 Deepseek 所给方案相比, LITP 的时间优先方案路径时间更短且拥挤度更低; 拥挤度优先

方案则大幅降低了拥挤度, 为注重舒适度的用户提供了更理想的方案. 此外, 具体分析 Deepseek 方案发现, 其存在时间分配失衡问题, 如在 4 天行程中, 前 3 天每日出行时间高达 8 h ~ 9 h, 最后一天仅有 3 h. 而 LITP 通过目标函数中的时间均衡项规避了此问题, 提升了用户的体验感和行程合理性. 与 TRIP-PAL^[23] 相比, LITP 运行时间缩短数 10 倍, 且无效方案率更低. 进一步对方案效果进行对比发现: 在深度游览场景下, 尽管 TRIP-PAL 的行程时间略短于 LITP 的拥挤度优先方案, 但是其拥挤度却比 LITP 高出 48.4%.

综上, 通过仿真实验和结果分析表明, 相较于其他基于大模型的旅行规划器, LITP 集成了大模型、景点状态预测和线路推荐 3 大部分, 实现了旅行路径规划中对游客体验的全方位改善, 展现出以下 3 点显著优势:

1) 运行效率更高, 相比于 TRIP-PAL, LITP 的求

表5 旅行路径规划器对比结果

场景		LITP		Deepseek			TRIP-PAL			
		(f_1, f_2)	run time	valid plan	(f_1, f_2)	run time	valid plan	(f_1, f_2)	run time	valid plan
1	I	(29.5, 71.1)	28.6	10/10	(32.5, 79.8)	714.3	10/10	(32.8, 80.4)	936.2	6/10
2		(31.3, 65.5)								
3	II	(29.6, 53.4)	26.2	10/10	(33.6, 57.8)	705.7	10/10	(34.7, 56.8)	840.2	6/10
4		(31.5, 46.9)								
5	III	(29.6, 15.4)	26.5	10/10	(30.8, 20.7)	723.1	10/10	(33.7, 20.3)	1249.9	10/10
6		(31.5, 7.8)								
7	IV	(29.7, 40.3)	28.3	10/10	(31.3, 58.3)	710.3	10/10	(32.5, 51.7)	805.7	5/10
8		(31.3, 29.8)								
9	V	(29.0, 31.7)	25.6	10/10	(29.2, 41.4)	621.0	10/10	(31.8, 38.3)	541.3	8/10
10		(30.6, 21.4)								
11	VI	(27.4, 23.5)	25.7	10/10	(28.2, 28.2)	485.4	10/10	(28.7, 25.6)	485.4	10/10
12		(29.2, 19.0)								

注: 标粗数据为当前场景下规划器运行最优值.

解时间大幅缩短, 且无效方案率更低;

2) 方案质量更优, LITP 在时间和拥挤度两个优化目标上均取得优异表现, 特别是在拥挤度优化方面展现突出优势;

3) 用户体验更佳, 通过时间均衡项的设置, LITP 避免了时间分配失衡问题, 确保行程更加合理、用户满意度更高.

4 结论

本文针对旅行方案中时间成本和体验质量的多目标优化需求, 构建了一种多目标旅行路线规划器, 并对经典的 NSGA-II 算法进行了改进, 提出了 PNSGA-II. 通过多仿真场景算例验证了该算法的有效性, 并将其与 LLM 信息处理模块以及景点状态预测模块相结合, 充分整合 LLM 的自然语言交互能力和多目标旅行路线规划器的优化能力, 最终提出了基于大语言模型的交互式多目标旅行方案规划器 (LITP). 该规划器在单城市多景点、不同客流密度以及游览模式下具有良好通用性, 相较于传统方法与其他规划器, 可为游客提供更高质量和更具个性化的旅行方案, 对于解决旅行规划问题或改善旅行体验的实际需求具有重要启发意义, 但是, 在跨城市多住宿点以及多种出行方式等复杂场景中的适用性仍然有待完善. 未来的仿真研究将重点聚焦于跨城市多交通方式的旅行路线规划, 进一步拓展规划器的应用范围和复杂场景适应能力, 以满足更广泛的旅行需求.

参考文献 (References)

- [1] Wang X D, Zhang H W, Liu S, et al. Path planning of scenic spots based on improved A* algorithm[J]. *Scientific Reports*, 2022, 12(1): 1320.
- [2] Wang G J, Wang Y Q, Li W. Research on travel route planning problems based on greedy algorithm[C]. *Proceedings of the 4th International Conference on Electronic Information Engineering and Computer Science*. Yanji, 2024: 755-758.
- [3] 陈仁胜, 吴斌, 闫飞一. 基于混合学习策略的可变速 AGV 与机器绿色集成调度[J]. *控制与决策*, 2024, 39(12): 3955-3963.
(Chen R S, Wu B, Yan F Y. Hybrid learning strategy for green integrated scheduling with variable speed AGV[J]. *Control and Decision*, 2024, 39(12): 3955-3963.)
- [4] 郑小操, 龚文引. 改进人工蜂群算法求解模糊柔性作业车间调度问题[J]. *控制理论与应用*, 2020, 37(6): 1284-1292.
(Zheng X C, Gong W Y. An improved artificial bee colony algorithm for fuzzy flexible job-shop scheduling problem[J]. *Control Theory & Applications*, 2020, 37(6): 1284-1292.)
- [5] 李瑞, 龚文引. 改进的基于分解的多目标进化算法求解双目标模糊柔性作业车间调度问题[J]. *控制理论与应用*, 2022, 39(1): 31-40.
(Li R, Gong W Y. An improved multi-objective evolutionary algorithm based on decomposition for bi-objective fuzzy flexible job-shop scheduling problem[J]. *Control Theory & Applications*, 2022, 39(1): 31-40.)
- [6] Estil-Les M A A D C, Bersani C, Sacile R, et al. Optimal travel planning of short stays in mass tourist destinations[J]. *IEEE Access*, 2023, 11: 89152-89163.
- [7] Liu S, Ma X Y. How social networks affect the spatiotemporal planning of smart tourism: Evidence from Shanghai[J]. *Sustainability*, 2021, 13(13): 7394.
- [8] 徐书扬, 潘华铮, 王海江. 基于蚁群算法的旅游路线优化方案[J]. *软件导刊*, 2020, 19(9): 89-92.
(Xu S Y, Pan H Z, Wang H J. Research on tourism route planning based on ant colony algorithm[J]. *Software Guide*, 2020, 19(9): 89-92.)
- [9] Toto E, Rundensteiner E A, Li Y H, et al. PULSE: A real time system for crowd flow prediction at metropolitan subway stations[C]. *Machine Learning and Knowledge Discovery in Databases*. Riva del Garda, 2016: 112-128.
- [10] 李旻璐, 关志广, 高伟锋. 深度神经网络模型在景区人群流量预测中的应用[J]. *信息与电脑: 理论版*, 2024, 36(17): 44-46.
(Li M L, Guan Z G, Gao W F. Application of deep neural network model in predicting crowd flow in scenic spots[J]. *Information Computer*, 2024, 36(17): 44-46.)
- [11] 周核忠, 罗俊仁, 谷学强, 等. 大语言模型视角下的智能规划方法综述[J]. *系统仿真学报*, 2025, 37(4): 823-844.
(Zhou Y Z, Luo J R, Gu X Q, et al. Survey on intelligent planning methods from large language models perspective[J]. *Journal of System Simulation*, 2025, 37(4): 823-844.)
- [12] Wu Q, Bansal G, Zhang J, et al. Autogen: Enabling next-gen LLM applications via multi-agent conversation[J/OL]. 2023, arXiv: 2308.08155.
- [13] Han Z, Gao C, Liu J, et al. Parameter-efficient fine-tuning for large models: A comprehensive survey[J/OL]. 2024, arXiv: 2403.14608.
- [14] Hong S, Zheng X, Chen J, et al. Metagpt: Meta programming for multi-agent collaborative framework[J/OL]. 2023, arXiv: 2308.00352.
- [15] Valmeekam K, Stechly K, Kambhampati S. LLMs still can't plan; Can LLMs? A preliminary evaluation of OpenAI's o1 on PlanBench[J/OL]. 2024, arXiv: 2409.13373.
- [16] Wong I A, Lian Q L, Sun D N. Autonomous travel decision-making: An early glimpse into ChatGPT and generative AI[J]. *Journal of Hospitality and Tourism Management*, 2023, 56: 253-263.
- [17] Kambhampati S, Valmeekam K, Guan L, et al. LLMs can't plan, but can help planning in LLM-modulo frameworks[J/OL]. 2024, arXiv: 2402.01817.
- [18] Yao J, Xu W, Lian J, et al. Knowledge plugins:

- Enhancing large language models for domain-specific recommendations[J/OL]. 2023, arXiv: 2311.10779.
- [19] Meng S, Wang Y, Yang C F, et al. LLM-A*: Large language model enhanced incremental heuristic search on path planning[J/OL]. 2024, arXiv: 2407.02511.
- [20] Ji Z W, Lee N, Frieske R, et al. Survey of hallucination in natural language generation[J]. *ACM Computing Surveys*, 2023, 55(12): 1-38.
- [21] Huang L, Yu W J, Ma W T, et al. A survey on hallucination in large language models: Principles, taxonomy, challenges, and open questions[J]. *ACM Transactions on Information Systems*, 2025, 43(2): 1-55.
- [22] Xu Z W, Jain S, Kankanhalli M. Hallucination is inevitable: An innate limitation of large language models[J/OL]. 2024, arXiv: 2401.11817.
- [23] de La R T, Gopalakrishnan S, Pozanco A, et al. TRIP-PAL: Travel planning with guarantees by combining large language models and automated planners[J/OL]. 2024, arXiv: 2406.10196.
- [24] Silver T, Dan S, Srinivas K, et al. Generalized planning in PDDL domains with pretrained large language models[C]. *Proceedings of the AAAI Conference on Artificial Intelligence*. Vancouver, 2024: 20256-20264.
- [25] 赵萌, 路辉, 王诗琪, 等. 多种群合作学习的多模态多目标路径规划算法[J]. *北京航空航天大学学报*, 2023, 49(3): 606-616.
(Zhao M, Lu H, Wang S Q, et al. A multimodal multi-objective path planning algorithm based on multi-swarm cooperative learning[J]. *Journal of Beijing University of Aeronautics and Astronautics*, 2023, 49(3): 606-616.)
- [26] 汪文文. 基于改进 NSGA-II 算法的应急配送中心选址模型研究[D]. 武汉: 武汉理工大学, 2018.
(Wang W W. Research on a location model of emergency distribution center based on improved NSGA-II algorithm[D]. Wuhan: Wuhan University of Technology, 2018.)
- [27] 葛媛媛, 陈得宝, 邹锋. 多群多策略差分大规模多目标优化算法[J]. *控制与决策*, 2024, 39(2): 429-439.
(Ge Y Y, Chen D B, Zou F. A large-scale multi-objective optimization based on multi-population and multi-strategy differential algorithm[J]. *Control and Decision*, 2024, 39(2): 429-439.)

作者简介

赵子涵 (2004-), 女, 本科生, 主要研究方向为系统优化与决策, E-mail: 3039750575@qq.com;

杨唯一 (1997-), 女, 讲师, 博士, 主要研究方向为系统规划与管理决策技术、智能航天器任务规划, E-mail: yangweiyi15@nudt.edu.cn;

姚锋 (1978-), 男, 研究员, 博士, 主要研究方向为智能优化调度、人工智能, E-mail: yaofeng@nudt.edu.cn;

张君哲 (2003-), 男, 本科生, 主要研究方向为系统优化与决策, E-mail: 2167266263@qq.com;

何磊 (1991-), 男, 副教授, 博士, 主要研究方向为航天大规模资源调度与任务管控、复杂系统建模与仿真、运筹规划与智能系统工程, E-mail: helei@nudt.edu.cn.