

基于图神经网络和多目标粒子群优化的智能路径规划方法及其应用

吴荣康¹, 吴伟佳², 黄惠婷^{1*}

1. 广东技术师范大学 数学与系统科学学院, 广东 广州 510080

2. 广东石油化工学院 自动化学院, 广东 茂名 525000

DOI:10.61369/ASDS.2026060011

摘要 : 随着智能交通以及旅游规划不断发展, 对有限时间、预算的约束条件下优化旅行路线、提高赏花效益的问题越来越突出。为了克服与假日赏花旅游有关的城市访问和路线规划难题, 本文提出了将图神经网络 (GNN) 和多目标粒子群优化 (MOPSO) 结合起来的智能路线规划方法 (GNN-MOPSO)。该方法用 GNN 从城市网络中提取结构特征, 用 MOPSO 优化多个目标, 从而达到同时最大化赏花价值、最小化旅行成本的目的。从实验结果可以看出, 在处理大规模城市网络的时候, GNN-MOPSO 比传统的 PSO、NSGA-II 等方法在解决方案质量和多样性上要更好。另外 GNN-MOPSO 算法可以很好地处理复杂的约束, 具有在智能交通、旅游路线优化等方面的应用前景。最后, 本文对未来的几个研究方向进行了论述, 即强化学习的集成以及算法在更大的城市网络中是否可以推广。

关键词 : 图神经网络; 多目标粒子群优化; 路径规划; 赏花; 智能旅游

Intelligent Path Planning Method Based on Graph Neural Network and Multi-Objective Particle Swarm Optimization and its Application

Wu Rongkang¹, Wu Weijia², Huang Huiting^{1*}

1. College of Mathematics and Systems Science, Guangdong Polytechnic Normal University,
Guangzhou, Guangdong 510080

2. College of Automation, Guangdong University of Petrochemical Technology
Maoming, Guangdong 525000

Abstract : With the development of intelligent transportation and tourism planning, many people have long been eager to find a good travel route and maximise the enjoyment of flowers in a short amount of time and money. To solve the problem of city visits and route planning for holiday flower viewing tourism, this paper puts forward an intelligent route planning method (GNN-MOPSO) based on graph neural networks (GNN) and multi-objective particle swarm optimisation (MOPSO). A GNN is employed to obtain the structure information of the urban network, and then MOPSO is applied for simultaneous multi-objective optimisation of various objectives, that is to say maximisation of flower-viewing value and minimisation of travel cost. According to experiments, GNN-MOPSO is better than the previous optimisation methods PSO and NSGA-II in terms of the quality of solutions and the diversity of solutions for all cases, especially in large-scale urban networks. GNN-MOPSO can also be used to address the problem of multiple constraints in the optimisation of smart transportation and tourism paths. Therefore, based on the reasons mentioned above, the direction of future research in this paper will be to apply reinforcement learning and the scalability of algorithms to large-scale urban networks.

Keywords : graph neural network; multi-objective particle swarm optimization; path planning; flower viewing; smart tourism

基金项目: 2023年度广东省普通高校青年创新人才类项目 (2023KQNCX038)。

作者简介:

吴荣康, 广东技术师范大学数学与系统科学学院, 本科生, 专业应用统计学;

吴伟佳, 广东石油化工学院自动化学院, 本科生, 专业自动化。

通讯作者: 黄惠婷, 广东技术师范大学, 讲师, 研究方向为非参数统计。

引言

随着生活水平的提高以及文化旅游需求的变化,假日短途旅行也成了越来越受欢迎的一种交通方式^[1]。赏花旅游,在清明、五一等节假日的时候特别受人欢迎。赏花旅游有时间敏感性、空间异质性,开花季、花卉种类、天气、交通状况等各地区差别很大^[2]。在有限的假日时间和预算内安排跨城市旅行,使游客可以尽量多的欣赏到盛花期的花朵,又对交通费用加以控制,提出了一项具有挑战性的智能路线规划问题^[3]。

目前一些学者用 TSP (旅行商问题)、贪婪算法、遗传算法、蚁群算法等方法来优化旅行路线。另外一些研究把兴趣点推荐和预算约束等条件结合起来使用多目标建模的方法。但是这些方法大多存在以下问题,不能完全建模城市之间复杂的时空关系,如花期的重叠、城市的吸引力等,容易陷入局部最优,缺少全局视角,缺少针对花卉观赏旅游的专业建模,这是一种“多目标+时间+空间异质”的场景^[4-6]。

本文提出的跨城市花卉观赏路线智能规划方法 (GNN-MOPSO) 是将图神经网络 (GNN) 和多目标粒子群优化算法 (MOPSO) 结合起来的一种方法^[7]。GNN 从城市图中提取节点之间结构特征,即可达性、花期重叠、吸引力评分等。MOPSO 用多目标优化的方法,在一定的预算和时间内最大程度上提高花卉的观赏价值,同时使总旅行成本最小化^[8]。利用 GNN 特征加入到初始化、优化阶段,可以得到更加高效、结构感知的搜索过程^[9]。

此项研究既充实了智能交通及智能旅游领域所用算法的方法,又给实际旅行需求如有限的花期、有限的行程、有限的预算等给予了解决途径。GNN-MOPSO 方法具有很强的可扩展性、可解释性,给之后加入强化学习、实时交通反馈提供算法基础,具有重要的实际应用价值以及广泛的使用前景。

一、路径规划建模主要符号与含义

为了方便读者阅读和理解后面建模所用到的主要符号及意义,表 1 给出了本文中路径规划建模所用到的主要符号及其含义。之后的目标函数和约束会根据符号展开。

表 1: 测试集上的模型性能比较

符号	描述
C	候选城市集合,总共有 N 个城市
S_i	城市 i 的花期开始时间 (小时)
e_i	城市 i 的花期结束时间 (小时)
$[s_i, e_i]$	城市 i 的完全开花区间 (小时)
v_i	城市 i 的赏花价值分数 (例如,花的多样性,用户评分)
C_i	住在城市 i 的日常生活成本 (货币单位)
t_{ij}	从城市 i 到城市 j 的旅行时间 (小时)
C_{ij}	从城市 i 到城市 j 的旅行成本 (货币单位)
t_i	在城市 i 的停留时长 (小时)
x_i	x_i 城市 i 是否被访问;若访问则为 1, 否则为 0
R_j	花期重叠率,表示停留期与开花窗口的对齐程度
Z_1	总赏花价值目标
Z_2	总旅行成本目标

本文主要创建一个公共假期赏花旅行的多目标路径优化模型^[10]。目的在于,在限定的时间与经费之下,促使游客有条理地安排起跨城市之行的行程,尽可能多地观赏到花开美景,并且也力求减少出行所耗费的成本。不同于传统的旅行商问题 (TSP) 或者最短路径问题,该任务具有时间依赖性、空间异质性以及多目标权衡的特点,需要将花开花期、景观价值、时间成本、货币预算等各方面因素一起考虑进去^[11-13]。

假设总旅行时长为 T , 候选城市数量为 N 。对于每个城市 C_i ,

其花期记为 $[s_i, e_i]$, 景观价值为 v_i , 该景观价值反映了花卉多样性和用户满意度得分。从城市 C_i 到 C_j 的交通成本和时长分别记为 d_{ij} 和 t_{ij} , 城市 C_i 中的其他停留相关成本记为 C_i 。给定一条旅行路径 $P = \{C_{i_1}, C_{i_2}, \dots, C_{i_k}\}$ 及其对应的停留时间 $\{t_1, t_2, \dots, t_k\}$, 我们的目标是在若干约束条件下优化多个目标^[14]。

令每个访问城市的赏花贡献为:

$$F_i = f(t_i, s_i, e_i) \cdot v_i, \quad (1)$$

其中 $f(t_i, s_i, e_i) \in [0, 1]$ 衡量停留时间 t_i 与当地花期窗口 $[s_i, e_i]$ 的重叠程度。那么, 总奖励函数为:

$$\max Z_1 = \sum_{i \in P} F_i. \quad (2)$$

时间约束: 总时间不得超过允许的假期时长:

$$\min Z_2 = \sum_{i=1}^{k-1} d_{i,i+1} + \sum_{i=1}^k c_i. \quad (3)$$

时间约束: 总时间不得超过允许的假期时长:

$$\sum_{i=1}^k t_i + \sum_{i=1}^{k-1} t_{i,i+1} \leq T_{\max}. \quad (4)$$

预算约束: 总旅行成本不得超过可用预算 B :

$$Z_2 \leq B. \quad (5)$$

花期有效性, 若一个城市在花期之外被完全访问, 则该城市的贡献被忽略,

$$f(t_i, s_i, e_i) = 0 \Rightarrow F_i = 0. \quad (6)$$

为了对这个问题结构进行建模，我们将多城市旅行规划表示为一个加权图 $G=(V,E)$ ，其中：顶点集 $V=\{C_1, C_2, \dots, C_N\}$ 表示所有候选城市。边集 $E=\{(C_i, C_j)\}$ 表示城市之间的两两连接，由旅行成本和时间加权。每个节点包含诸如花期窗口 $[s_i, e_i]$ 、景观价值 v_i 、当地成本 c_i 和地理位置 (lat_i, lon_i) 等属性。每条边与诸如 d_{ij} 和 t_{ij} 等属性相关联。此图不仅编码了空间连通性，还嵌入了与赏花体验相关的时间和经济背景^[15]。通过利用图神经网络（GNN），我们提取城市的结构感知嵌入，这些嵌入进一步集成到多目标粒子群优化（MOPSO）算法中，以增强初始化并在搜索过程中指导粒子更新。最终，任务是找到一个城市访问序列，在满足时间和预算约束的同时最大化赏花价值并最小化总成本。下一节将详细阐述集成 GNN 和 MOPSO 的算法设计。

二、方法

为了实现假日赏花路线高效规划和智能优化，本文提出了一种集成 GNN 和 MOPSO 的路径规划算法框架整体方法流程如图1所示。



图1：方法框架图

它包含模块有输入模块（城市数据、花期窗口、预算、时间约束）、GNN 图构建与节点嵌入提取、多目标粒子编码与初始化、GNN 引导的 MOPSO 进化过程、帕累托解集输出和路径可视化模块

（一）城市图构建与特征编码

在这项工作中，我们将所有候选城市表示为一个带权无向图 $G=(V,E)$ ，其中 $V=\{v_1, v_2, \dots, v_n\}$ 表示城市集合， $E \subseteq V \times V$ 表示城市间的连通性，边权对应城市间的旅行时间和成本。每个城市节点 v_i 与一个多维属性向量 x_i 相关联，该向量包括城市的赏花价值 v_i 、花期 $[s_i, e_i]$ 、当地成本 c_i 、地理坐标 (lat_i, lon_i) ，以及可能的其他因素，如用户评分或天气预报 r_i 。这些特征表示为：

$$x_i = [v_i, s_i, e_i, c_i, lat_i, lon_i, r_i]. \quad (7)$$

为了得到本地节点属性和城市之间的结构关系，使用图注意力网络（GAT）来计算上下文感知节点嵌入。GAT 框架中每一个节点都会用到自己学到的注意力系数去聚合自己的邻居信息。节点表示的更新过程如下：

$$h_i = \sigma \left(\sum_{j \in N(i)} \alpha_{ij} W h_j \right), \quad (8)$$

其中 h_j 表示相邻节点 v_j 的特征向量， W 是一个可学习的权重矩阵， α_{ij} 是在节点 i 和节点 j 之间计算得到的注意力权重，并且 σ 是一个非线性激活函数，例如 ReLU。得到的输出 h_j 捕捉了节点级语义和拓扑依赖性。

在 GAT 传播之后，每个城市由一个高维嵌入向量 z_i 表示，该向量作为下游优化任务的基础。这些嵌入不仅编码了城市的内在属性（例如，花卉类型和开花期），还编码了其在旅行图中的相对重要性和连通性。在后续模块中，这些节点嵌入用于 MOPSO 框架内的粒子初始化、路线评估和优化指导。

（二）多目标粒子群优化建模（MOPSO）

为解决多约束和多目标下的赏花旅行规划问题，我们采用多目标粒子群优化（MOPSO）算法作为核心搜索引擎。群体中的每个粒子代表一个候选旅行方案，对访问城市的顺序和相应停留时间进行编码。具体来说，一个粒子 P 被定义为一个元组：

$$P = \{(C_{i_1}, t_1), (C_{i_2}, t_2), \dots, (C_{i_k}, t_k)\}. \quad (9)$$

为了便于计算以及用向量来表示，将粒子转换成固定长度的向量形式

$$X = [i_1, i_2, \dots, i_k, t_1, t_2, \dots, t_k], \quad (10)$$

前半部分为城市访问顺序，后半部分为停留时间。群体由 M 个这样的粒子组成，粒子被迭代更新来同时优化两个目标函数，即最大化总赏花效益和最小化总旅行成本。

第一个目标就是考虑计划访问的时间和每一个城市实际的开花期之间是否重叠，使得所有的选定城市的有效赏花奖励最大化。将该目标定义为：

$$Z_1 = \sum_{j=1}^k f(t_j, s_{ij}, e_{ij}) \cdot v_{ij}, \quad (11)$$

其中 $f(t_j, s_{ij}, e_{ij}) \in [0, 1]$ 是一个时间重叠函数，用于评估观赏时间 t_i 与城市花期 $[s_{ij}, e_{ij}]$ 的匹配程度，并且 v_{ij} 表示城市 C_{ij} 的赏花价值。

第二个目标是使市内、市际费用之和最小化，即最小化总出行成本。

$$Z_2 = \sum_{j=1}^k c_{ij} + \sum_{j=1}^{k-1} d_{ij, i_{j+1}}. \quad (12)$$

为了对这些互相矛盾的目标进行管理，用帕累托存档的方式存储在优化过程中得到的非支配解集。每一代中根据支配性和多样性来评定粒子。拥挤距离度量是沿着帕累托前沿保持多样性的一种方式，保证解集包含两个目标之间所有的权衡。

使用以下方程迭代更新每个粒子的位置和速度：

$$V^{(t+1)} = \omega V^{(t)} + c_1 r_1 (P_{\text{best}} - X^{(t)}) + c_2 r_2 (G_{\text{best}} - X^{(t)}), \quad (13)$$

$$X^{(t+1)} = X^{(t)} + V^{(t+1)}, \quad (14)$$

其中 ω 为惯性权重， c_1 和 c_2 为认知和社会学习因子， $r_1, r_2 \in [0, 1]$ 为随机数。 P_{best} 是粒子找到的个人最佳解， G_{best} 是基于拥挤距离或 GNN 引导从外部存档中选择的精英解。

多目标公式可以使得算法去寻找许多可行的旅行路线，从而达到赏花效果与总成本的平衡。用迭代优化粒子群的方法来逼近

帕累托前沿,得到一组优化的、多样化的旅行规划建议。

(三) GNN 与 MOPSO 的集成策略

为了提高粒子初始化的质量和进化搜索的过程的效率,本文把 GNN 学习得到的结构特征加到 MOPSO 优化模型里,如图2所示。




图2: 基于 GNN 从城市图中提取嵌入

GNN 的集成有两方面目的,第一,用结构感知的城市嵌入来指导高质量初始解的产生;第二,在迭代中给群体提供辅助评分信息,促使它向更有价值的赏花路线前进。

在初始化阶段,GNN 生成的节点嵌入 z_i 用于根据每个城市的连通性和属性特征评估其潜在重要性。在初始粒子生成过程中,基于嵌入得分较高的城市被赋予更高的优先级。这有助于生成一个初始群体,该群体不是纯粹随机产生的,而是偏向于结构上有利且语义上有意义的旅行序列。

迭代优化阶段用 GNN 引导的评分函数来评价每一个候选路线,该函数把已经访问过的城市嵌入得分聚合起来,再根据它的开花效果进行调制。评分函数定义为:

$$Score(P) = \sum_{j=1}^k softmax(z_{i_j}) \cdot f(t_j, s_{i_j}, e_{i_j}). \quad (15)$$

该评分函数被加入到外部存档的选择中。当多个非支配解竞争存储或者指导粒子更新的时候,具有高 GNN 引导得分的解会被优先考虑。用这种方法,MOPSO 的搜索轨迹向更好的结构定位、更高的预测效用解趋近,加快收敛速度,使最后的帕累托前沿更加多样化。

通过把基于 GNN 的表示学习同 MOPSO 的进化过程紧密结合起来,提出的方法用拓扑感知和自适应优化的方式,更高效、智能地解决了赏花路径规划的问题。

三、实验设计与结果分析

为了检验本文提出的 GNN-MOPSO 方法在优化假日赏花路径方面是否有效,本文做了若干实验,城市规模、预算约束、花期分布等都不同。用各种主流的优化算法进行实验,从路径质量、目标值性能、解集多样性、计算效率等几个方面对算法性能进行评价。

(一) 实验设置

本文创建了一个包含20个城市、不同的地理位置、交通联系、花卉种类分布以及观赏评分的城市赏花旅行图。

每个城市被赋予一个开花窗口 $[s_i, e_i]$ 、一个赏花价值 v_i 、城市间旅行成本 d_{ij} 、住宿成本 c_i ,以及诸如天气评级和用户满意度得分等辅助变量。

城市之间网络是由高铁连通性所形成的。旅行时间、成本根据实际区域数据做归一化处理。假日时长:72小时(3天)。预算限制:1500单位。最多访问城市数量:6。

在此设置下对所提方法进行评价,并与下面四种算法进行比较,如表2所示。

表2: 测试集上的模型性能比较

算法	描述
GNN-MOPSO	本文提出的方法,将 GNN 嵌入与 MOPSO 相结合。
标准粒子群优化算法	没有 GNN 和多目标建模的基线粒子群优化算法。
非支配排序遗传算法 II	经典多目标遗传算法。
贪心 + 回溯	基于花朵得分 / 开花时间排序和剪枝的启发式算法。

所有实验均在相同的计算平台(英特尔 i7、16GB 内存、Python 3.10、PyTorch Geometric)上进行,并且每种算法运行10次以获得平均结果。

(二) 评估指标

为了全面评估算法的性能,本文使用以下评估指标:

$$R_f = \frac{1}{k} \sum_{j=1}^k f(t_j, s_{i_j}, e_{i_j}). \quad (16)$$

总赏花价值 Z_1 在3.2节中定义,用于衡量审美和体验效益。

总路径成本 Z_2 包括交通 + 住宿,单位越小越好。

解集拥挤指数 (Spacing) 用来度量帕累托解集的多样性以及分布是否均衡,其定义如下

$$S = \frac{1}{|P|-1} \sum_{i=1}^{|P|} |d_i - \bar{d}|. \quad (17)$$

平均运行时间,用于衡量算法的计算效率(秒)。

(三) 实验结果与比较分析

表3展示了四种算法(包括 GNN-MOPSO、PSO、NSGA-II 和贪心 + 回溯算法)在路径质量方面的比较。评估指标包括平均赏花价值 (Z_1)、平均旅行成本 (Z_2)、平均花期重叠率 (R_f) 以及衡量帕累托解多样性的 Spacing 指标。可以观察到,GNN-MOPSO 实现了最高的赏花价值和花期重叠率,同时保持了具有竞争力的旅行成本和最佳的多样性表现。虽然贪心 + 回溯算法实现了最低的成本,但其赏花效益和帕累托多样性明显较差证明了所提方法的整体优越性。

表3: 路径质量比较

算法	平均 Z_1	平均 Z_2	平均 R_f	间距
GNN-MOPSO	53.42	1260.3	0.84	0.013
PSO	47.31	1294.6	0.76	0.021
NSGA-II	51.28	1272.5	0.81	0.018
贪心 + 回溯	42.19	1247.0	0.69	0.045

图3展示了四种算法在总赏花价值 (Z_1) 和总旅行成本 (Z_2) 之间的帕累托前沿比较。GNN - MOPSO (蓝色圆圈) 在赏花价值和旅行成本之间实现了最佳平衡,展现出高赏花价值和低旅行

成本，且解的分布相对均匀，证明了其优越性。相比之下，虽然标准 PSO（红色方块）对某些解提供了较低的旅行成本，但它的赏花价值较低且解的多样性较差。NSGA - II（绿色三角形）在赏花价值和旅行成本之间实现了平衡，但其整体性能略逊于 GNN - MOPSO。贪心回溯（紫色叉号）实现了最低的旅行成本，但其赏花价值和解的多样性明显不足，无法有效提供高质量的帕累托解集。




图3：帕累托前沿比较（ Z_1 与 Z_2 ）

表4展示了不同算法（包括 GNN - MOPSO、PSO、NSGA - II 和贪心 + 回溯）之间的运行效率比较。表中显示了每种算法的平均运行时间，GNN - MOPSO 需要18.3秒，PSO 需要9.1秒，NSGA - II 需要23.5秒，而贪心 + 回溯最快，为2.8秒。

表4：运行效率比较

算法	平均运行时间（秒）
GNN-MOPSO	18.3
PSO	9.1
NSGA-II	23.5
贪婪 + 回溯	2.8

虽然和传统的算法相比，GNN-MOPSO 的运行时间要长得多，但是它的解质量、多样性都很好，因此更适合于大规模的城市网络优化。

实验结果清楚地表明，本文所提出的 GNN - MOPSO 方法对于多城市赏花路线优化任务是有效的、有优势的。多目标权衡、复杂结构建模、解集分布控制，它比传统的优化方法好。GNN 模块给出的结构感知嵌入可以提高搜索空间引导的能力，减少无效路径的探索，加快收敛速度，增大帕累托前沿的宽度。

当城市数量增多到50个以上的时候，传统的解法质量会明显降低，但是我们提出的方法仍然可以保持稳定的性能，具有较好的可扩展性。另外 GNN 模块加入了部分模型可解释性，节点注意力权重以及路径得分来源可以被用作决策支持以及路线推荐系统的支撑。

四、结论与未来工作

本文提出了一种基于 GNN 和 MOPSO 相结合的路线优化方法，专门用于解决假日赏花旅游城市游览和路线规划问题。将开花期、交通成本、停留时间等各个约束条件加入到目标函数中，可以很快得到最优路线，也可以较好地兼顾各个目标。GNN 模型可以从中提取出城市网络的结构特征，使路线搜索更加智能。MOPSO 用模拟粒子群的进化过程来完成多目标优化，即在控制旅行成本的同时达到最大的赏花效益。该种将图学习与多目标优化相结合的算法，在计算机算法领域有着较大的应用前景。

虽然 GNN-MOPSO 的计算效率比传统的 PSO、NSGA-II 等要高一些，但是它的解质量、多样性都比其它算法好得多。从实验结果可知，GNN-MOPSO 既能保证较低的旅行成本，又能较好地改善赏花效益，对大城市的网络也具有较好的优化能力。另外，由于城市数量的增多，传统的算法已经不能满足需要。但是 GNN-MOPSO 可以有效地解决大规模的问题，并且有很好的可扩展性以及鲁棒性。因此，本文研究结果表明，粒子群优化算法和图神经网络相结合，给解决复杂的城市路径规划问题提供了一种新的方法，有很强的实际应用价值。

未来研究可以在几个方面进一步优化和扩展现有方法。虽然目前的算法表现很好，但是它的计算时间仍然比传统的算法要长。未来的研究可以进一步研究更加高效并且适合 GPU 的并行计算方法，从而提高计算速度。其次，用强化学习（RL）来实现路径规划的自适应优化，可以使得算法对于实时环境条件（天气、交通等）作出更加灵活的改变。最后随着智慧城市、物联网的发展，可以将实时交通流量、用户偏好等更多的多模态数据加入到路径优化算法当中来，从而提高它在实际应用中的准确性以及鲁棒性。经过上述改进之后，GNN-MOPSO 算法在更加复杂的、动态的应用环境中会发挥出更大的作用。

参考文献

[1]McNulty A ,Berman O B ,Engelbrecht A .A comparative study of evolutionary algorithms and particle swarm optimization approaches for constrained multi-objective optimization problems[J].Swarm and Evolutionary Computation,2024,91101742-101742.DOI:10.1016/J.SWEVO.2024.101742.

[2]Dezvarei M ,Tomovic K ,Sun S J , et al.A graph neural network framework for security assessment using topological measures[J].Electric Power Systems Research,2025,249111972-111972.DOI:10.1016/J.EPSR.2025.111972.

[3]Kajla I N ,Missen S M M ,Coustaty M , et al.A histogram-based approach to calculate graph similarity using graph neural networks[J].Pattern Recognition Letters,2024,186286-291.DOI:10.1016/J.PATREC.2024.10.015.

[4]Zhao Y ,Dong J ,Wang W , et al.A multi-typed multi-relational heterogeneous graph neural network model for complex networks[J].Knowledge-Based Systems,2025,329(PA):114291-114291.DOI:10.1016/J.KNOSYS.2025.114291.

- [5]Quintero H P , Triviño G P , Gonz á lez C D , et al.Adaptive multi-objective real-time hierarchical control for isolated microgrid clusters utilizing an enhanced particle swarm optimization strategy to optimize costs and emissions[J].Electric Power Systems Research, 2026, 250112169–112169.DOI: 10.1016/J.EPSR.2025.112169.
- [6]Meng X , Li H .An adaptive co-evolutionary competitive particle swarm optimizer for constrained multi-objective optimization problems[J].Swarm and Evolutionary Computation, 2024, 91101746–101746.DOI: 10.1016/J.SWEVO.2024.101746.
- [7]Cunha B C , Massarotto F D , Fornazza L S , et al.An ALNS metaheuristic for the family multiple traveling salesman problem[J].Computers and Operations Research, 2024, 169106750–106750.DOI: 10.1016/J.COR.2024.106750.
- [8]Luo X , Yi Z .Efficiency management of engineering projects based on particle swarm multi objective optimization algorithm[J].Systems and Soft Computing, 2025, 7200320–200320.DOI: 10.1016/J.SASC.2025.200320.
- [9]Yang X , Wang R , Li K , et al.Exploratory landscape analysis on black-box optimization problems via Graph Neural Network[J].Swarm and Evolutionary Computation, 2025, 99102136–102136.DOI: 10.1016/J.SWEVO.2025.102136.
- [10]Wu J , Xu Z , Qiao S .Fast Heterogeneous Graph Neural Network Generation via Meta Contrastive Learning[J].Neural networks : the official journal of the International Neural Network Society, 2025, 192107727.DOI: 10.1016/J.NEUNET.2025.107727.
- [11]Wang X , Lv Y , Sun H , et al.Multi-modal travel route planning considering environmental preference under uncertainties: A distributionally robust optimization approach[J].Transportation Research Part E, 2025, 198104097–104097.DOI: 10.1016/J.TRE.2025.104097.
- [12]Zhao Y , Wang W , Wang S , et al.Over-smoothing problem of heterogeneous graph neural networks: A heterogeneous graph neural network with enhanced node differentiability[J].Information Processing and Management, 2026, 63(2PA): 104395–104395.DOI: 10.1016/J.IPM.2025.104395.
- [13]Dinçer H , Y ü ksel S , Eti S , et al.Q-learning algorithm and molecular fuzzy multi-objective particle swarm optimization-based decision-making approach to circular economy-oriented investment alternatives for renewable energy technologies[J].Information Sciences, 2025, 718122378–122378.DOI: 10.1016/J.INS.2025.122378.
- [14]Lin C , Xie Y , Wang H C .Significant wave height prediction at multiple sites using sequence decomposition and dynamic spatiotemporal graph neural networks[J].Ocean Engineering, 2025, 341(P2): 122548–122548.DOI: 10.1016/J.OCEANENG.2025.122548.
- [15]Feng B , Zhou P X .The novel physics-enhanced graph neural network for phase-field fracture modelling[J].Computer Methods in Applied Mechanics and Engineering, 2025, 446(PB): 118284–118284.DOI: 10.1016/J.CMA.2025.118284.