

DOI: 10.19650/j.cnki.cjsi.J2614873

基于改进遗传寻优算法的微动边缘成像方法*

田入运,王红雨,许佳慧,陈玉扬,张宇星

(南京信息工程大学自动化学院 南京 210044)

摘要:微动勘探法具有不破坏地理环境、安全环保、信噪比高等特点,在地震学和勘探地球物理学领域具有广泛的应用前景。但传统“分布式采集-集中式回收”的工作模式导致横波速度结构成像严重滞后,难以满足实时勘探需求。边缘计算虽能降低时延、减少网络负载,却面临边缘节点异构、资源受限的问题,制约了微动勘探的实时性与准确性。针对上述瓶颈,提出了一种基于改进遗传寻优算法的微动勘探边缘成像方法。首先,设计微动边缘协同成像系统架构,通过部署地震边缘服务器统一管理传感器节点,实现网络边缘即时成像;其次,适配节点资源异构特性,构建以延迟最小化、能耗可控为目标的多节点协同计算框架,对任务分配问题建模;最后,提出融合交叉、变异策略及启发式规则的改进遗传寻优算法(MGOA),高效求解任务分配全局最优解。EdgeCloudSim 仿真实验表明,与传统遗传算法相比,本算法在保持 100% 任务覆盖率下使即时成像总时间降低 23.36%,在中等规模场景下计算效率较 CPLEX 求解器提升 29.8%;鲁棒性测试显示其稳定性评分为 44.12、鲁棒性评分为 52.12,均优于对比算法。实地测试验证了该方法在不同初始地层模型下的适应性,成像误差处于低水平,且优化后的边缘设备内存利用率仅 53%,适配资源受限场景。该方法实现了延迟与能耗的协同优化,为微动勘探实时成像提供了高效解决方案。

关键词:微动勘探;即时成像;任务分配;多节点协作计算;改进遗传寻优算法

中图分类号: TH762 TP393.027

文献标识码: A

国家标准学科分类代码: 510.40

A microtremor edge imaging method based on modified genetic optimization algorithm

Tian Ruyun, Wang Hongyu, Xu Jiahui, Chen Yuyang, Zhang Yuxing

(College of Automation, Nanjing University of Information Science and Technology, Nanjing 210044, China)

Abstract: The microtremor survey method is characterized by the advantage of non-destructiveness to the geographical environment, safety, environmental friendliness and high signal-to-noise ratio, which possesses the broad application prospects in seismology and exploration geophysics. However, the traditional "distributed acquisition-centralized processing" model results in significant delays of shear wave velocity structure imaging, failing to meet the real-time exploration requirements. While the edge computing reduces the latency and network load, it faces challenges such as heterogeneous edge nodes and resource constraints, limiting the instant performance and accuracy of microtremor survey. To address these bottlenecks, this paper proposes a microtremor edge imaging method based on modified genetic optimization algorithm. First, a microtremor edge collaborative imaging system architecture is designed by deploying seismic edge servers to centrally manage sensor nodes, which enables the instant network edge imaging. Additionally in order to minimize the latency and control energy consumption, a multi-node collaborative computing framework is designed by tailoring the heterogeneous node resources and modeling the task allocation challenges. Finally, introduce the modified genetic optimization algorithm(MGOA) integrating crossover, mutation strategies and heuristic rules is introduced to efficiently solve the global optimal task allocation. The EdgeCloudSim simulations demonstrate that compared to traditional genetic algorithms, the proposed method reduces the total instant imaging time by 23.36% while maintaining 100% task coverage, which increases the higher computational efficiency by 29.8% than the CPLEX solver in medium-scale scenarios. The robustness tests show stability scores of 44.12 and robustness scores of 52.12, both surpassing the comparison algorithms. The field tests validate the method's adaptability across different initial geological models with the low imaging errors and optimized edge device memory utilization at just 53%, making

收稿日期: 2026-01-20 Received Date: 2026-01-20

* 基金项目: 国家自然科学基金(62403248)项目资助

it suitable for the resource-constrained environments. In conclusion, it achieves the coordinated optimization of delay and energy consumption, providing an efficient solution for instant imaging in microtremor survey.

Keywords: microtremor survey; instant imaging method; task assignment; multi-node collaborative computing framework; modified genetic optimization algorithm

0 引言

微动勘探方法利用地震站网记录微动噪声数据,通过台站对之间的数据互相关获得反映地下介质信息的格林函数,被广泛用于地层构造探测和场地稳定性评价等领域,是目前地震学领域理论研究和工程应用方面的前沿和热点^[1-2]。该方法无需人工震源,具备不破坏地理环境,施工效率高等优势^[3]。传统微动勘探方法采用“分布式采集—集中式回收”的模式,即分布式地震传感器节点(seismic sensor nodes, SSN)采集数据后,回传至中央服务器进行处理并进行剪切波速度结构(shear wave velocity structure, SWVS)成像^[4]。然而,由于大规模微动勘探任务所需采集节点众多,需较长施工周期,且勘探过程需要连续不断地采集数据,增加了数据回收的难度。此外,采集节点在长期运行过程中,易受环境复杂性、外部干扰和资源耗尽等因素影响^[5-7]。

为突破传统模式的瓶颈,无线传感网、云计算等方法逐步应用于地震勘探领域,实现了数据质量的实时监测^[8]。Zhou等^[9]研发了能源平衡型分布式无线传感网络,适用于三维地震勘探;Yin等^[10]则提出基于Wi-Fi与LTE双层网络的无线地震传感器网络方案,可实现长距离高速地震数据传输并保持高可靠性。然而,这些方法仍存在节点寿命有限、网络带宽不足、能耗过高和成像延迟等问题^[11-12]。云计算技术通过集中式物联网云平台,可实现大规模SWVS成像,但远程任务卸载导致网络延迟显著增加,影响服务质量^[13]。

边缘计算作为一种新型计算范式,通过将计算和存储能力下沉至靠近数据源的边缘节点,能够有效降低端到端时延、减少网络负载,并提升系统的实时响应能力和可靠性^[14-15]。该技术在地球物理勘探领域的前沿应用已取得突破性进展,Chamarczuk等^[16]将分布式声学传感与实时边缘计算深度融合,成功实现了增强型地热系统运行期间的微震活动实时监测。工程实验证实,边缘计算架构可有效适配地球物理勘探的实时性、低时延需求^[17]。

微动勘探的成像延迟直接决定其实际应用价值,对地质灾害实时预警、数据质量控制及工程现场决策具有关键影响。地质灾害预警中,延迟超过5 min会导致预警窗口失效,误判前兆信号。数据质量控制中,高延迟无法及时筛查异常数据,易造成成像失真。工程现场决策

中,延迟过长会降低勘探效率,无法实时优化方案。对于云端需承担海量数据传输、多任务调度等额外延迟,边缘计算可通过本地处理规避此类损耗。然而,微动勘探系统中边缘服务器通常计算资源有限,且设备异构性导致不同任务处理性能存在差异,难以实现即时成像^[18]。此外,现有研究大多局限于边缘计算任务调度的单一维度(如能耗、延迟或成本)优化,未考虑实际系统运行中延迟与能耗之间的动态平衡关系。

为解决上述问题,本文提出一种基于改进遗传寻优算法的微动勘探边缘成像方法。首先,构建微动边缘协同成像系统架构,通过部署地震边缘服务器(seismic edge servers, SES)对传感器节点进行集中管理。传感器节点采集数据后,支持本地成像或任务卸载两种模式;边缘计算节点通过任务队列实现缓存调度,协同完成数据预处理与核心计算任务,最终实现网络边缘的即时成像。边缘服务器与传感节点之间的物理邻近性促进其快速交互和即时成像任务请求的响应,从架构层面降低成像延迟。为分析成像任务的延迟特性,需选取适配的横波速度结构成像算法^[19]。空间自相关法(spatial auto correlation, SPAC)是一类从微动信号的垂直分量中提取瑞利波相速度频散曲线的数据处理方法,通过对频散曲线的反演可估算介质横波速度结构^[20]。SPAC成像过程中包含多个步骤,各任务对计算资源的需求不同,而SES与SSN在系统架构、计算资源容量、运算能力及网络传输性能方面存在显著差异^[21]。忽视上述资源差异可能导致计算资源浪费或任务积压。为此,本文构建多节点协同计算框架,对边缘成像任务分配问题进行建模,该框架以时间、空间及协作关系为约束条件,以延迟和能耗为优化目标^[22]。针对任务分配的求解问题,采用改进遗传寻优算法(modified genetic optimization algorithm, MGOA)。由于传统遗传算法(genetic algorithm, GA)易过早收敛,算法需通过调整变异和交叉概率来增强种群的迭代能力^[23-24],同时设计不同的变异策略(回复、插入、交换突变)确保解的多样性^[25]。针对GA局部精细搜索能力不足的问题,进一步引入启发式规则,确保算法能够持续优化最优解^[26]。最终在实现所有任务合理分配的基础上,缩短即时成像时间。

综上,本文的创新可总结为3点:1)为降低成像延迟提出微动边缘协同成像架构,通过部署SES管理SSN实现边缘即时成像;2)针对性适配边缘节点与传感节点的资源异构特性,构建多约束多目标任务分配模型;3)为高

效求解任务分配全局最优解设计融合多变异策略与启发式规则的 MGOA 算法。

1 原理和模型

1.1 基于 SPAC 的成像原理

SPAC 法利用快速傅里叶变换将微动垂直振动波形原始记录变换到频率域,随后在相同时间段内,分别对圆心点 O 和各个圆周点组成的台站对,求其互功率谱及各自的自功率谱,计算每段数据的空间自相关函数。首先,计算随机谱 $X(f, \xi)$, 其公式为:

$$X(f, \xi) = \int_0^\infty \int_0^{2\pi} e^{i(\omega f + k\xi)} dz(\omega, k) \quad (1)$$

式中: f 为频率; ξ 为空间参数; ω 为角频率; k 为波数; $z(\omega, k)$ 表示正交随机过程。在横波速度成像时,仅需考虑地震信号的垂直分量^[27], 因此,式(1)可被表示为:

$$X(f, r, \theta) = \iint_0^{2\pi} e^{i\omega f} e^{ikr \cos(\theta - \phi)} dz(\omega, \phi) \quad (2)$$

式中: r 和 θ 分别表示站间距离和角度; ϕ 表示方位角,如图 1 所示。




图 1 SPAC 圆形台阵极坐标台站几何关系

Fig. 1 Schematic diagram of polar coordinate station geometric relationship for spac circular array

从所有台站中选择两个台站 O 和 A , 距离为 r , 夹角为 θ 。设 O 为原点 $(0, 0)$, 建立极坐标系, A 坐标为 (r, θ) 。台站 O 的微动频谱可表示为:

$$X(f, 0, 0) = \iint_0^{2\pi} e^{i\omega f} dz(\omega, \phi) \quad (3)$$

台站 O 和站 A 之间的 SPAC 函数 $\Gamma(r, \theta, \omega)$ 可以表示为:

$$\Gamma(r, \theta, \omega) = \int K(r, \omega) d\omega \quad (4)$$

这里 $K(r, \omega)$ 是空间协方差函数, 它可以计算为:

$$K(r, \omega) = \iint_\phi e^{-ikr \cos(\theta - \phi)} \cdot S(\omega, \phi) d\phi \quad (5)$$

其中, $S(\omega, \phi)$ 是方向谱密度。角频率下的 SPAC 系数可以通过用功率谱函数归一化平均空间协方差函数来获得。角频率下的 SPAC 系数 $\rho(r, \omega)$ 可以计算为:

$$\rho(r, \omega) = \frac{\bar{K}(r, \omega)}{P_0(\omega)} = J_0 \cdot rg \quad (6)$$

其中, $\bar{K}(r, \omega)$ 是平均空间协方差函数, $P_0(\omega)$ 是功率谱函数, g 是相速度函数, J_0 是第 1 类零阶贝塞尔函数。这里, 功率谱函数 $P_0(\omega)$ 可以计算为:

$$P_0(\omega) = \int_0^{2\pi} p(\omega, \phi) d\phi \quad (7)$$

此外, 相速度函数 g 可以表示为:

$$g = \frac{\omega}{c(\omega)} = \frac{2\pi f}{c(f)} \quad (8)$$

其中, $c(\omega)$ 表示相速度。因此, 相速度形式的 SPAC 系数公式也可以表示为:

$$\rho(f, r) = J_0 \cdot \frac{2\pi r f}{c(f)} \quad (9)$$

SPAC 系数与相速度之间的关系由第 1 类零级贝塞尔函数决定。因此, 用非线性最小二乘法进行拟合, 即可计算出各中心频率对应的相速度。非线性最小二乘法的目标函数为:

$$\min_{c(f)} \sum_i \left[\rho_i - J_0 \cdot \frac{2\pi r f_i}{c(f)} \right]^2 \quad (10)$$

在频散曲线的提取步骤中, 由于地震传感节点组成的阵列中有许多组半径, 因此只保留满足 $|f_{\text{data}} - f_{\text{target}}| < 0.1 \text{ Hz}$ 的频点。在给定初始地层模型参数的情况下, 对频散曲线进行反演, 获得横波速度结构成像。

1.2 任务模型

将边缘服务器中的即时成像任务 T 划分为 m 个子任务, 子任务可表示为一个集合 $T = \{T_1, T_2, \dots, T_m\}$ 。将这些具有依赖关系的子任务建模为一个有向无环图 (directed acyclic graph, DAG) $G = (T, R)$, 其中 $R \subseteq T \times T$ 表示一条用于描述子任务之间依赖关系的有向边, 如图 2 所示。当有向边 (T_j, T_i) 存在时, 子任务 T_i 的执行时间取决于子任务其前驱子任务 T_j 的完成时间。




图 2 串并行依赖感知子任务

Fig. 2 Serial and parallel dependency-aware subtasks

依赖感知型任务的调度策略对边缘计算系统的能耗与延迟具有显著影响, 尤其是串并行异构的任务结构, 需

针对性设计调度方案^[28]。用 T^{type} 来标识子任务的类型: $T^{\text{type}} = 0$ 表示串行子任务, $T^{\text{type}} = 1$ 表示并行子任务。串行子任务之间呈现一对一连接, 子任务 1 的输出必须作为子任务 2 的输入。其中, 子任务 1 被称为子任务 2 的前驱任务。并行子任务之间为一对多或多对多连接, 一个子任务的执行时间取决于其所有前驱任务中最晚完成的那个任务的结束时间。

1.3 延迟与能耗模型

当任务 i 需要卸载到 SSN_j 进行处理时, 延迟 $L_{i,j}$ 可分解为传输延迟、计算延迟和排队延迟。延迟 $L_{i,j}$ 的计算公式为:

$$L_{i,j} = L_{i,j}^{\text{trans}} + L_{i,j}^{\text{comp}} + L_{i,j}^{\text{quene}} \quad (11)$$

其中, $L_{i,j}^{\text{trans}}$ 表示任务 i 卸载到 SSN_j 所需的传输延迟, $L_{i,j}^{\text{comp}}$ 表示任务 i 在 SSN_j 中处理所需的计算延迟, $L_{i,j}^{\text{quene}}$ 表示任务 i 在 SSN_j 中受到队列拥塞所需的排队延迟。

传输延迟 $L_{i,j}^{\text{trans}}$ 取决于任务数据量以及 SES 与 SSN 之间的链路带宽。计算延迟 $L_{i,j}^{\text{comp}}$ 由任务的计算负载与 SSN_j 的处理速度共同决定。当任务 i 被调度到 SSN_j 进行处理时, 若该节点仍有未完成的任务, 就会产生排队延迟。任务 i 在 SSN_j 上的总延迟 $L_{i,j}$ 应表示为:

$$L_{i,j} = \frac{D_i}{B_{i,j}} + \frac{W_i}{f_j} + \frac{\rho_j}{\mu_j - u_j} \quad (12)$$

其中, D_i 表示任务 i 的数据量, $B_{i,j}$ 表示链路带宽, W_i 表示任务 i 的计算负载 (CPU 周期数), f_j 表示 SSN_j 的处理速度 (频率)。 u_j 为 SSN_j 的任务到达率, μ_j 为任务处理率, ρ_j 为 SSN_j 的负载率。

对于具有依赖关系的任务, 其延迟还取决于子任务的类型。定义 t_i 为子任务 T_i 的完成时间, 记子任务 T_i 的所有前驱任务集合为 $\text{pred}(T_i)$, 即: $\{T_j | (T_j, T_i) \in R\}$ 。定义 $t^*(T_i)$ 为子任务 T_i 所有前驱任务中最晚完成时间, 即: $t^*(T_i) = \max\{t_j | T_j \in \text{pred}(T_i)\}$ 若子任务 T_i 没有任何前驱任务, 则令 $t^*(T_i) = 0$ 。

因此, 对于串行子任务, 其延迟计算公式为:

$$L_{\text{ser}} = \sum_{i=1}^M \sum_{j=1}^N x_{i,j} \cdot t_i \quad (13)$$

其中, $x_{i,j}$ 为任务卸载决策变量: 若 $x_{i,j} = 1$, 表示任务被卸载至 SSN_j ; 否则 $x_{i,j} = 0$ 。对于并行子任务, 其延迟为:

$$L_{\text{par}} = \max_{i=1, \dots, m} \{ [t^*(T_i) + t_i] \cdot x_{i,j} \} \quad (14)$$

即时成像任务同时包含串行和并行子任务, 因此其总延迟需综合考虑串行与并行子任务的延迟。本研究定义集合 $S = \{s_1, s_2, \dots, s_k\}$ 表示所有串行子任务组, 其中每个 $s \in S$ 包含一组串行子任务; 集合 $P = \{p_1, p_2, \dots, p_l\}$ 表示所有并行子任务组, 每个 $p \in P$ 包含一组并行子任务。因此, 即时成像任务的总延迟为所有串行子任务组

与并行子任务组延迟之和。

$$L_{\text{total}} = \sum_{s \in S} L_{\text{total, ser}} + \sum_{p \in P} L_{\text{total, par}} \quad (15)$$

任务在传输阶段和计算阶段都会消耗能量传输能耗 $E_{i,j}^{\text{trans}}$ 取决于传输功率 P_i^{tx} 与传输延迟 $L_{i,j}^{\text{trans}}$, 传输功率 P_i^{tx} 与传输距离有关, 其计算公式为:

$$E_{i,j}^{\text{trans}} = P_i^{\text{tx}} \cdot L_{i,j}^{\text{trans}} = \frac{P_{\min} \cdot d_{i,j}}{G_i G_j \lambda^2} \cdot \frac{D_i}{B_{i,j}} \quad (16)$$

式中: $P_{\min}$ 是 SSN_j 的最小可检测功率; λ 是与通信频率 f 相关的波长; $G_i G_j$ 为任务传输过程中的增益。

计算能耗 $E_{i,j}^{\text{comp}}$ 与 SSN_j 的计算功率 P_j^{comp} 和计算延迟有关, 计算功率 P_j^{comp} 与频率 f_j 的平方成正比, 其计算公式为:

$$E_{i,j}^{\text{comp}} = P_j^{\text{comp}} \cdot L_{i,j}^{\text{comp}} = k \cdot f_j \cdot W_i \quad (17)$$

其中, k 为硬件系数。因此总能耗为:

$$E_{i,j} = \frac{P_{\min} \cdot d_{i,j}}{G_i G_j \lambda^2} \cdot \frac{D_i}{B_{i,j}} + k \cdot f_j \cdot W_i \quad (18)$$

由于传输能耗仅与传输功率和传输延迟有关, 而计算能耗仅与计算功率和计算延迟有关, 可忽略任务类型对能耗的影响。因此, 整个即时成像任务的总能耗可简化为:

$$E_{\text{total}} = \sum_{i=1}^M \sum_{j=1}^N x_{i,j} \cdot E_{i,j} \quad (19)$$

1.4 约束条件

由于 SSNs 的计算资源有限, 且 SESs 除成像外还需管理 SSNs , 因此必须满足以下约束条件。

任务卸载唯一性: 每个任务在同一时刻只能被调度到一个 SSN 上, 约束表达式为:

$$\sum_{j=1}^N x_{i,j} = 1, \quad \forall i \quad (20)$$

其中, $x_{i,j} = 1$ 表示任务 i 被卸载到节点 j 。

计算资源约束: SSN 的计算资源受限, 其可用计算量不能超过自身容量, 约束表达式为:

$$\sum_{i=1}^M x_{i,j} \cdot W_i \leq C_j \quad (21)$$

其中, 容量 $C_j = f_j \cdot T_{\max}$, $T_{\max}$ 为最大允许计算时间。

链路带宽约束: 无线传输带宽本身受限, 若超出限制会显著增加延迟与能耗, 因此总链路传输速率不得超过带宽, 约束表达式为:

$$\sum_{i=1}^M x_{i,j} \cdot \frac{D_i}{L_{i,j}^{\text{trans}}} \leq B_{i,j} \quad (22)$$

能量约束: SSN 的能量有限, 任务总耗能不能超过其剩余能量, 约束表达式为:

$$\sum_{i=1}^M x_{i,j} \cdot E_{i,j} \leq E_j^{\text{init}} - \sum_{k=1}^{t-1} E_{k,j} \quad (23)$$

其中, E_j^{init} 为节点 j 的初始能量, $\sum_{k=1}^{t-1} E_{k,j}$ 为该节点已

处理任务的总能耗。

截止期限约束:对于计算任务,其完成时间仅取决于对应 SSN 节点所需的任务处理时长。而通信任务的完成时间则受任务处理时长与传输延迟双重影响。部分对延迟敏感的紧急任务需在截止期限前完成,约束表达式为:

$$L_{i,j} \leq D_i^{\text{ddl}} = \begin{cases} t_i^{\text{cmp}} + t_{i,j}^{\text{tr}} + t_{i,j}^{\text{rx}}, & x_{i,j} = 1 \\ t_i^{\text{cmp}}, & x_{i,j} = 0 \end{cases} \quad (24)$$

其中, t_i^{cmp} 表示任务 i 的处理时长, $t_{i,j}^{\text{rx}}$ 为接收延迟, $t_{i,j}^{\text{tr}}$ 为传输延迟。

在优化边缘成像任务的过程中,时间效率是最为关键的优化目标,与此同时,还需将系统整体能耗严格控制在预先设定的范围之内并满足约束条件。该优化目标可被定义为:在确保所有计算与传输环节的总能耗 E_{total} 不超过给定上限的前提下,通过合理的资源分配与任务调度,实现系统总延迟 L_{total} 的最小化。因此,该问题的目标函数可以形式化表述为:

$$\begin{aligned} \min L_{\text{total}} &= \sum_{s \in S} L_{\text{total, ser}} + \sum_{p \in P} L_{\text{total, par}} \\ \text{subject to } E_{\text{total}} &\leq E_j^{\text{init}} - \sum_{k=1}^{i-1} E_{k,j} \end{aligned} \quad (25)$$

具体而言,在构建优化模型时,需明确时间效率与能耗控制之间的权衡关系,并通过约束条件确保系统运行符合硬件限制与实际条件。传感节点计算资源约束确保设备在安全范围内稳定运行,避免因超负荷工作导致性能下降或硬件损坏;系统能耗约束贴合边缘计算低功耗应用场景的实际需求,通过限制整体功耗水平保障系统能够长效稳定运行;截止期限约束确保延迟敏感型任务在规定时间内完成,满足微动勘探即时成像的实时性需求。

2 MGOA 算法

2.1 算法设计

GA 是一种有效的任务分配优化算法,但该算法易陷入局部最优、收敛慢,无法直接用于微动勘探边缘即时成像。通过改进遗传算法的交叉和变异策略,来增加遗传算法解的多样性,保证其收敛。另一方面,遗传算法的局部精确搜索能力不够,引入启发策略,可在解的最优值附近局部精确搜索。改进后的算法称为 MGOA,如算法 1 所示。MGOA 并非对现有方法的简单改进,而是面向微动勘探边缘成像场景的组合策略适应性设计,并针对微动数据特性构建了专用适应度函数。

$$f(X) = \sum_{i=1}^m \sum_{j=1}^n x_{i,j} L_{i,j} \quad (26)$$

其中, $f(X)$ 为个体适应度值,越小表示任务分配方案越优, $x_{i,j}$ 为任务卸载决策变量, $L_{i,j}$ 为任务 i 在节点 j 上的总延迟。

算法 1: 基于 MGOA 的任务分配算法

输入: 任务号 t , 节点号 f , 交叉概率 $p_{\text{cross}}(t)$, 变异概率 $p_{\text{mut}}(t)$

输出: 最佳任务分配解决方案 X^*

- 1: 初始化种群 p_{best_0}
- 2: 设置适应度函数以最小化总时间 T_{total}
- 3: **for** $p_{\text{cross}} \in (0, 1)$, $p_{\text{mut}} \in (0, 1)$ 执行以下操作
- 4: 设置初始交叉概率 $p_{\text{cross-max}}$ 和初始变异概率 $p_{\text{mut-max}}$,
- 5: 降低变异概率 p_{mut} 和交叉概率 p_{cross}
- 6: 使用分段交叉策略
- 7: **if** 变异概率 $p_{\text{mut}}(t) \geq 0.5$, 则使用回复突变
- 8: **if** $\text{fitness}_1 < \text{fitness}_0$, 则保留 x_{best_1} 和 p_{best_1} , 并更新当前最优个体基因 x_{best_1} 和最优种群 p_{best_1}
- 9: **else if** 变异概率 $0.5 > p_{\text{mut}}(t) \geq 0.2$, 则使用插入突变
- 10: 更新当前最优个体基因 x_{best_2} 和最优种群 p_{best_2}
- 11: **if** $\text{fitness}_2 < \text{fitness}_1$, 则保留 x_{best_2} 和 p_{best_2}
- 12: **else if** $\text{fitness}_2 > \text{fitness}_1$, 则设置交叉规则和增强规则, 并更新当前最优个体基因 $x_{\text{best}_2'}$ 和最优种群 $p_{\text{best}_2'}$
- 13: **else if** 变异概率 $p_{\text{mut}}(t) < 0.2$, 则使用交换突变
- 14: 更新当前最优个体基因 x_{best_3} 和最优种群 p_{best_3}
- 15: **if** $\text{fitness}_3 < \text{fitness}_2$, 则保留 x_{best_3} 和 p_{best_3}
- 16: **else if** $\text{fitness}_3 > \text{fitness}_2$, 则设置交叉规则和增强规则, 并更新当前最优个体基因 $x_{\text{best}_3'}$ 和最优种群 $p_{\text{best}_3'}$
- 17: **end if**
- 18: **end for**
- 19: 记录最优个体基因和种群
- 20: **return** 最优任务分配方案 X^*

2.2 编码方法

采用实数编码作为遗传算法的编码方法。

$$X = (x_1, x_2, \dots, x_n) \quad (27)$$

其中, X 的长度表示 SSN 的数量, 而 x 表示任务编号。对于实数编码下的遗传算法种群, 采用均匀随机方法对种群进行初始化。

$$x_{i,j} = a_j + (b_j - a_j) \cdot U(0, 1) \quad (28)$$

其中, U 表示在 $(0, 1)$ 中均匀分布的随机数。适应度函数采用多节点协同计算框架下的目标函数, 其目标是最小化总时间。此类参数设置的优势在于, 能直观地体现多节点协同计算框架下节点与任务之间的对应关系, 且效率较高。

2.3 交叉与变异操作

遗传算法的核心操作是交叉和变异, 其共同决定解的搜索幅度、收敛快慢及最终质量。变异概率偏高可扩大全局搜索范围, 偏低则提升局部搜索精度。交叉概率偏高利于维持种群多样性, 偏低则加快收敛、便于锁定最优解。

遗传算法在时空约束任务调度中已得到针对性改进, Mahjoubi 等^[29]提出增强型修复遗传算法(enhanced healed genetic algorithm, EHGA)算法,用于分布式边缘-云基础设施中的任务调度,通过遗传算法优化任务分配以提升系统执行效率。尽管 EHGA 已将遗传算法应用于边缘-云任务调度,但其未充分考虑微动勘探场景下的时空约束与节点异构特性,在动态资源环境下易出现早熟收敛与调度不合理问题。本文针对微动勘探的节点资源受限、任务异构特性,进一步设计组合调整策略,并绑定多变异策略与工程场景,使算法更适配微动成像的实时性与稳定性需求。针对框架内的任务分配问题,变异概率需随迭代线性递减,交叉概率则需按指数规律下降,即:

$$\begin{cases} p_{\text{cross}}(t) = p_{\text{cross-max}} - \frac{p_{\text{cross-max}} - p_{\text{cross-min}}}{T_{\text{max}}} \cdot t \\ p_{\text{mut}}(t) = p_{\text{mut-max}} \cdot e^{-\beta \frac{t}{T_{\text{max}}}} \end{cases} \quad (29)$$

基于上述参数调整策略,算法初期可最大化全局搜索范围,避免解陷入局部最优;算法中期则逐步降低变异概率,缩小搜索范围,并在局部空间开展精细搜索。由于指数递减,交叉概率迅速降低,使得算法快速收敛,快速找到最优解;在后期,算法产生最优解,并保持较低的变异概率和交叉概率,以减少破坏最优解的概率。

在修改交叉和变异概率的基础上,设计了新的交叉策略和变异策略。为了避免传统交叉操作带来的重复或不可行解,采用分段交叉策略来保持解的可行性,如图3所示 $P_1 = [x_1, x_2, \dots, x_N]$ 和 $P_2 = [y_1, y_2, \dots, y_N]$,从其中随机选择段 $[k, k+L]$,则后代为 C_1 和 C_2 。

$$\begin{cases} C_1 = [x_1, \dots, x_{k-1}, y_k, \dots, y_{k+L}, x_{k+L+1}, \dots, x_N] \\ C_2 = [y_1, \dots, y_{k-1}, x_k, \dots, x_{k+L}, y_{k+L+1}, \dots, y_N] \end{cases} \quad (30)$$




图3 交叉操作

Fig.3 Cross operation

增强种群多样性,避免过早收敛。为了通过组合实现多样化搜索,提出了3种变异策略,如图4所示。变异策略为:

1) 回复突变:该策略的实施是在 $p_{\text{mut}}(t) \geq 0.5$ 时开始的,随机选择连续的片段 $[k, k+L]$,并颠倒它们的顺序,即

$$M_r = [x_1, \dots, x_{k+L}, \dots, x_k, x_{k+L+1}, \dots, x_N] \quad (31)$$

2) 插入突变:该策略在 $0.5 > p_{\text{mut}}(t) \geq 0.2$ 时启动,随机选择一个基因插入到另一个随机位置,即

$$M_i = [x_1, \dots, x_{j-1}, x_k, x_j, \dots, x_{k-1}, x_{k+1}, \dots, x_N] \quad (32)$$

3) 交换突变:当 $p_{\text{mut}}(t) < 0.2$ 随机选择两个基因位置 a 和 b 并交换它们的值时,该策略被触发。

$$M_s = [x_1, \dots, x_b, \dots, x_a, \dots, x_N] \quad (33)$$




图4 变异操作

Fig.4 Variation operation

变异策略(回复、插入、交换突变)是用来解决任务调度中微动勘探采集节点在长期运行中可能因环境复杂性、外部干扰或资源耗尽而故障的问题。回复突变可修正基因序列中的局部偏差,适配任务与节点资源的小幅错配场景,快速微调优化;插入突变能重构基因序列结构,适配任务优先级调整、节点负载重分配等大幅优化需求;交换突变可微调相邻基因位置,适配边缘节点间的协作关系优化,平衡节点负载。可维持种群多样性,避免传统 GA 早熟收敛,为延迟与能耗优化提供最优搜索范围。

2.4 启发性规则

MGOA 在每次迭代后更新当前的最优适应度。如果下一次迭代的最优适应度小于前一次迭代的最优适应度,则 MGOA 更接近最优解。当变异概率 $p_{\text{mut}}(t)$ 在

0.5~1 的范围时, MGOA 表现出稳健的搜索能力, 使其能够快速收敛到最优解(算法 1 的第 7~8 行)。当变异概率 $p_{\text{mut}}(t)$ 落在 0~0.5 的范围时, MGOA 采用局部空间的精细搜索来提高最优解的精度(算法 1 的第 9~20 行)。

为了提高 MGOA 在变异后期的局部搜索能力, 进一步提高最优解的质量, 在变异概率为 $p_{\text{mut}}(t) < 0.5$ 的阶段加入了启发式规则。在这个阶段, 变异概率呈线性下降, 因此仍能保持一定的搜索能力, 并能继续在局部找到满足启发式规则的最优解。而交叉概率呈指数下降, 因此可以保证解的稳定性。具体启发式规则如下:

1) 交叉规则: 高适应度个体对应低延迟、低能耗、满足节点资源约束的任务分配方案, 其基因序列承载了适配边缘节点异构特性的信息。定义局部交叉最大长度为:

$$L_c = [\alpha \cdot N], \quad 0 < \alpha < 0.2 \quad (34)$$

对于适应度较高的个体, 只用小范围交叉, 进行相邻维度之间的基因互换, 基因更新方式为:

$$x'_{k_i} = \begin{cases} x_{k_{i-1}}, & \text{rand}(0,1) < 0.5 \text{ 且 } x_{k_i} > 1 \\ x_{k_{i+1}}, & \text{rand}(0,1) \geq 0.5 \text{ 且 } x_{k_i} < N \\ x_{k_i}, & \text{边界基因 } (k_i = 1 \text{ 或 } k_i = N) \end{cases} \quad (35)$$

创建局部交叉规则, 避免破坏现有的遗传结构, 并产生不同的后代, 提升种群向最优解进化的效率, 适配边缘任务调度对实时性的高需求。

2) 增强规则: 微动边缘成像任务调度需同时满足延迟最小化与能耗约束。从当前种群中选取适应度最优的两个个体, 定义为:

$$X_{\text{best}_1}, X_{\text{best}_2} = \underset{X \in P}{\operatorname{argmin}} \{f(X)\} \quad (36)$$

对最优个体执行邻域局部搜索:

$$X'_{\text{best}} = X_{\text{best}} + \delta \cdot U(-1, 1) \quad (37)$$

保留两个最优个体单独开展局部搜索, 可避开交叉变异带来的随机扰动, 聚焦最优解周边的局部最优区域, 优化任务分配细节(如数据传输时序、节点计算资源占用比例), 进一步降低延迟并严格控制能耗在阈值范围内。同时, 将更新后的最优个体放回种群, 可引导整体种群向更优方向进化, 既保证解的精度与稳定性, 又避免算法后期收敛停滞, 适配边缘计算资源有限、多目标协同优化的需求。

2.5 收敛性证明

为从理论上验证所提改 MGOA 的有效性 & 可靠性, 基于有限齐次马尔可夫链理论对算法进行完整的收敛性分析。首先给出收敛性证明所需的基本定义, 可行任务分配空间 Λ 表示满足微动勘探边缘网络约束的所有 0~1 分配矩阵 D 的集合, 由于分配矩阵的行列数均为有限值, 因此 Λ 为有限集合。适应度函数 $f(X): \Lambda \rightarrow R^+$ 为可行解空间到正实数域的映射, 其取值对应任务分配方案

的总耗时, 直接决定解的优劣。种群状态空间 S 定义为 Λ 的 N 次笛卡尔乘积, 即 $S = \Lambda^N$, 用于表示所有可能的种群状态, 其中 N 为种群规模。

在此基础上给出收敛性所需的关键假设, 适应度函数 $f(X)$ 在可行解空间 Λ 上具有有界性, 即存在常数 $M > 0$ 使任意 $x \in \Lambda$ 均满足 $0 < f(X) \leq M$, 且全局最优解集合 Λ^* 非空。MGOA 的分段交叉策略与回复、插入、交换变异策略能够保证子代解的可行性, 即若双亲个体 $x_i(t), x_j(t) \in \Lambda$, 则交叉产生的后代 c_1, c_2 与变异产生的后代 m_1, m_2 均属于 Λ ; 算法采用精英保留的启发式规则, 若第 t 代种群 $X(t)$ 中包含全局最优个体 $x^* \in \Lambda^*$, 则第 $t+1$ 代种群 $X(t+1)$ 中必定保留该全局最优个体 x^* 。

基于上述定义与假设可证明 3 个核心引理, MGOA 的种群状态过程 $\{X(t) | t \geq 0\}$ 满足有限状态性与无后效性, 因此为有限齐次马尔可夫链。由最优个体保留机制可知, 包含全局最优个体的状态集合 S^* 满足吸收态的定义, 即一旦进入 S^* 便不会再离开, 因此 S^* 为吸收态集合。对于任意不属于最优状态的种群, 均可通过有限次交叉与变异操作以大于零的概率生成全局最优个体, 从而进入吸收态集合。

根据有限齐次马尔可夫链的基本性质, 非吸收态均为瞬态, 当迭代次数趋于无穷时, 处于任意瞬态的概率趋近于零。结合上述引理可推出 $\lim_{t \rightarrow \infty} P\{X(t) \in S^*\} = 1$ 即 MGOA 以概率 1 收敛至全局最优任务分配方案, 具备严格的全局收敛性, 能够保证在微动勘探边缘成像的任务分配问题中稳定获取最优解。

3 仿真测试及优化效果

为验证算法改进效果, 在 EdgeCloudSim 仿真平台完成测试。该平台专为边缘计算研究设计, 可评估资源管理策略并模拟多种边缘架构。鉴于边缘节点与采集设备算力有限, 实验按此约束配置参数, 具体数值见表 1。

3.1 收敛性测试


收敛性测试可反映出 MGOA 在限定时间内是否可以得到最优或者近似于最优的解。舒伯特函数作为经典的多峰测试函数, 具有多个局部极小值且整个函数的定义域上只有一个全局极小值, 被广泛用于测试优化算法的性能。

初始种群分布于二维空间和三维空间上, 均匀无序, 经过多轮迭代之后, 所有的种群几乎可以全部收敛到全局最优解, 如图 5 所示。还有少数种群围绕着最优解徘徊, 即有极少部分还在不停地进行搜索。MGOA 算法具有较好的全局搜索能力, 可高效寻找到全局最优解。


表 1 配置信息参数

Table 1 Configuration information parameters

配置类型	参数	数值
实验设备	CPU	Intel(R) Core(TM) i7
	内存	32 G
边缘节点	每秒百万条指令	300~600
	内存	2 G
网络参数	带宽	20 MHz
	传输功率	0.6 W
	路径损耗指数	1
	高斯噪声功率	-175 dBm
任务属性	任务数量	0~500
	边缘节点数量	5~35
	迭代次数	900
	粒子数量	500
	任务长度	10 000~20 000



(a) 二维收敛后种群
(a) Two-dimensional converged population



(b) 三维收敛后种群
(b) Three-dimensional converged population

图 5 MGOA 在舒伯特函数中的应用

Fig. 5 Application of MGOA in schubert functions

通过分析适应度曲线的变化情况可以判断 MGOA 的收敛性。如图 6 所示,传统 GA 在迭代初期找出了最

优解,此后仅更新一次最优解,最佳解位 735,说明遗传算法的搜索能力较差,容易出现过早收敛的现象。而 MGOA 初始最优解为 700 左右,优于 GA;且在后期多次进行迭代后得到了适应度为 675 的最优解。在接近最优解过程中,MGOA 采用了启发式规则,能够不断调整更新解中目前最优解。MGOA 可以对变异概率、交叉概率等参数进行多次调优操作,这样使得其在初始阶段就拥有更好的全局搜索能力。




图 6 最佳适应曲线的比较

Fig. 6 Comparison of optimal adaptation curves

3.2 最大任务完成时间测试

为评估 MGOA 的优化能力,将其与以下方法进行对比:混合整数线性规划 (mixed integer linear programming, MILP)、基于分层博弈的联合任务卸载与资源分配方法 (hierarchical game-based joint task offloading and resource allocation algorithm, HG-JTROA)、深度 Q 网络 (deep Q-network, DQN)、双重延迟目标双深度 Q 网络 (double delayed target double deep Q-network, DDT-DDQN) 以及自适应遗传算法 (adaptive genetic algorithm, AGA)。DQN、DDT-DDQN 和 HG-JTROA 是近年提出的任务分配方法,其中 DQN 和 DDT-DDQN 基于深度强化学习,HG-JTROA 则基于博弈论,AGA 则是针对 GA 固定参数导致的早熟收敛、收敛速度慢问题设计的经典改进遗传算法。如图 7 所示,分别比较了各算法在完成 6 个和 7 个节点的 500 项任务时所需总时间,可以有效证明 MGOA 的优越性。

图 7(a)展示节点数量为 6 时,各算法完成 0~500 个任务的总时间。完成单个任务总时间随任务数增加而增长,但 MGOA 算法稳定性最佳、耗时最短。MILP 初始阶段对 MGOA 有微弱优势,但随任务数增加,完成时间远超 MGOA,这表现其能精准求解最优解,但计算复杂度 高,仅适用于小规模任务。DQN 采用深度强化学习,一定程度上解决动态环境决策难题,但频繁迭代致耗时和能耗增加。DDT-DDQN 可以优先处理具有延迟约束的任




图 7 不同算法的总时间比较

Fig. 7 The total time comparison of different algorithms

务,高效分配资源。因此,在资源有限的情况下,可以有效减少完成任务所需的总时间。然而,在大约 400 次迭代后发生收敛,导致额外的资源消耗。HG-JTORA 基于博弈论框架,在多任务场景表现优异,但忽略节点协作机制,模型复杂度高,难用于资源有限场景。AGA 作为传统遗传算法的经典改进版本,通过动态调整交叉与变异概率平衡全局搜索与局部优化,耗时低于 MILP、DQN 及 HG-JTORA,但其未引入多变异策略与启发式规则,面对任务数增长时,易出现局部最优收敛,稳定性与耗时优化效果均不及 MGOA。因此,节点数量为 6 时,MGOA 性能最佳。

如图 7(b) 所示,7 节点场景多算法性能对比显示,节点数量增加,各算法总耗时下降,说明计算资源越充足,任务完成效率越高。7 节点网络中,MGOA 总耗时最短,初始阶段少于 MILP。DQN、DDT-DDQN、HG-JTORA 和 AGA 虽为先进方法,但总耗时仍高于 MGOA,因为 MGOA 更适应多节点协作场景。对比图 7(a) 和 (b),MGOA 总耗时明显低于其他算法,MGOA 相对于 GA 平均降低了 23.36%。在 500 个任务数量,接近 6 个节点最大处理量的临界情况下,MGOA 仍能完成任务分配,这表明 MGOA 可以应用于不同规模的任务,反映了其广泛的适用性和高可靠性。

3.3 MGOA 与 CPLEX 对比实验

本文所求解的任务分配问题本质为带约束多目标混合整数线性规划 (MILP) 问题。CPLEX 优化求解器 (CPLEX optimization solver, CPLEX) 是工业级高精度 MILP 专用求解器,可用于任务分配问题的精确求解。为进一步验证 MGOA 在不同规模下的求解精度、计算开销与收敛性能,本节设置多组任务与节点规模,将 MGOA 与 CPLEX 进行对比实验,结果如表 2 所示。

表 2 CPLEX 与 MGOA 对比
Table 2 Comparison of CPLEX and MGOA

实验场景	M	N	CPLEX		MGOA		
			Obj	CPU/s	Avg	Gap /%	CPU/s
1	50	5	7.20	2.91	7.20	0.00	53.41
2	50	6	5.41	1.58	5.41	0.00	49.27
3	200	6	9.38	94.02	9.38	0.00	82.73
4	200	7	7.71	70.44	7.71	0.00	79.55
5	400	7	12.55	583.21	12.89	2.71	364.12
6	400	8	10.73	552.67	10.94	1.96	330.84
7	600	8	19.68	1 197.45	20.21	2.69	942.38
8	600	9	19.74	1 183.29	20.16	2.13	901.67
9	800	9	46.12	—	43.94	—	1 092.55
10	800	10	45.57	—	42.31	—	1 075.82
平均值	—	—	18.41	460.70	18.02	1.19	497.23

在以边缘服务器为中心的 50 m 半径内随机生成 N 个传感器节点和 M 个任务。每个传感器节点有 1.5 M 内存和 40 Mb/s 带宽。CPU 代表平均计算时间,Obj 代表 CPLEX 求解器计算的最优结果,Avg 代表 MGOA 在每个实验场景下运行 10 次的平均计算结果。为了模拟微动勘探边缘网络对即时性的需求,本实验将运行时间上限设置为 1 200 s,超过此上限将停止计算。此外,Gap = (Avg - Obj) / Obj × 100% 代表了 MGOA 和 CPLEX 在求解结果中的性能差异。

实验场景 1 和 2 在任务数量相同的情况下,传感器节点数量越多,完成任务的总完成时间越短。在实验场景 1~4 中,MGOA 得到的平均最优解与 CPLEX 求解器计算出的最优解相同,并且都在短时间内获得了最优解,这表明 MGOA 在小规模场景中是有效的。比较实验场景 5~8 可以发现,任务数量越多,所需计算时间就越多,这反映了任务在非确定多项式上的难度。特别是在计算效率方面,MGOA 在场景 5~8 中平均计算时间较 CPLEX 降低 29.8%,且与最优解的精度差异极小。实验结果表明,在中等规模的场景中,MGOA 的性能要好于 CPLEX 求解器。在实验场景 9 和 10 中,CPLEX 求解器无法在指

定的计算时间内获得最优解,其 Obj 是 CPLEX 在求解器 1 200 s 内计算的最佳上限。MGOA 在规定时限内收敛,获取高质量近似最优解,证明了它在解决大规模问题时具有更高的效率和稳定性。

基于上述实验结果研究,在大规模场景中,MGOA 仍能在指定时间内找到最优解,且解的质量满足 CPLEX 求解器找到的最优上限,这表明 MGOA 具有良好的泛化能力。

3.4 任务覆盖度测试

对于即时成像来说,由于任务呈现具有不确定性,因此在系统中存在着任务密集区与任务稀疏区。在处理比较复杂任务时需通过多个节点合作来保障整个系统正常运转。因此须检查 MGOA 的任务分配覆盖率是否可以实现在所有的任务都分派到相应的节点上进行处理,如图 8 所示。这些节点将会按照不同半径来进行分层划分,每一个层次里面又会有 3 个节点,然后会在空间中随机生成任务点,圆点表示被节点覆盖的任务。




图 8 不同任务数下的任务分配覆盖率

Fig. 8 Coverage of task allocation under different task numbers

任务覆盖率计算公式即:

$$Coverage = P_{TP} \cdot P_{tar} + (1 - P_{FP}) \cdot (1 - P_{tar}) \quad (38)$$

其中, P_{TP} 表示正确覆盖, P_{FP} 表示错误覆盖, P_{tar} 为

先验概率。正确覆盖 P_{TP} 和错误覆盖 P_{FP} 的公式为:

$$P_{TP} = \sum_m \binom{N}{m} (P_t)^m (1 - P_t)^{N-m} \quad (39)$$

$$P_{FP} = \sum_m \binom{N}{m} (P_f)^m (1 - P_f)^{N-m} \quad (40)$$

其中, N 表示节点数量, m 为覆盖任务的节点数, P_t 代表单个节点的正确覆盖率, P_f 表示单个节点的错误覆盖率。当任务数量为 50 和 100 时,任务都能完全覆盖,表明 MGOA 能将任务分配给资源充足的节点,体现任务分配合理性。任务数量为 50 时,有 11 个协作任务;增至 100 时,有 19 个协作任务,证明 MGOA 具备与多节点协同处理复杂任务的能力。因此,即使任务数量变化,MGOA 仍能有效分配任务并满足复杂任务的协作约束条件。

3.5 鲁棒性测试

稳定性和鲁棒性是评价算法性能的重要指标,反映了算法在小干扰、噪声干扰和不合理情况下的性能。在微动勘探边缘网络中,系统的性能可能会受到自然环境的影响。因此,对 MGOA 的稳定性和鲁棒性进行评估尤为重要。本节对 MGOA、GA、MILP、DDT-DDQN 和 AGA 算法各进行了 100 次独立重复实验,分别计算总时间和覆盖率的平均值和标准差。为模拟微动勘探现场环境干扰,在 100 次重复实验中随机加入信道噪声与节点算力波动,以测试算法在非理想条件下的稳定性与鲁棒性。根据均值和标准差计算结果,采用加权评分法对算法的稳定性和鲁棒性进行评估,计算结果如图 9 所示。




图 9 不同算法的稳定性与鲁棒性评分

Fig. 9 The stability and robustness scores for different algorithms

稳定性和稳健性的加权评分公式为:

$$S_{st} = 20 \frac{\sigma_{T,max} - \sigma_{T,i}}{\sigma_{T,max} - \sigma_{T,min}} + 20 \frac{\sigma_{P,max} - \sigma_{P,i}}{\sigma_{P,max} - \sigma_{P,min}} \quad (41)$$

$$S_{no} = 30 \frac{|\Delta P_{min}| - |\Delta P_j|}{|\Delta P_{min}| - |\Delta P_{max}|} + 30 \frac{|\Delta T_{min}| - |\Delta T_j|}{|\Delta T_{min}| - |\Delta T_{max}|} \quad (42)$$

其中, $\sigma_{T,max}$ 表示最大延迟标准差, $\sigma_{T,i}$ 表示当前算

法的延迟标准差, $\sigma_{T, \min}$ 表示最小延迟标准差, σ_p 则表示每个覆盖项的标准差。此外, ΔP 和 ΔT 分别代表覆盖度与延迟的相对差异。MGOA 算法展现出 44. 12 的稳定值, 在 5 种算法中保持最优水平。这得益于对变异概率、交叉概率、变异策略和交叉策略的调整, 使得 MGOA 能在干扰环境下始终识别出最优任务分配策略。MGOA 的鲁棒性达到 52. 12, 表明其在偏离规范条件时仍能保持高可靠性。

4 实地测试

本研究在边缘设备中部署了成像系统, 所采用的硬件配置如图 10 所示。传感节点采用自主研发的无线低功耗节点式地震仪 GEIWSR-III, 如图 10(a) 所示。针对具有较高性能要求的边缘计算节点, 综合考虑勘探成本和成像性能, 采用自研的微动勘探横波速度结构即时成像仪。仪器可通过图形用户界面控制软件实现数据库管理、任务分配方法及即时成像等功能, 如图 10(b) 所示。




图 10 硬件设备
Fig. 10 Hardware devices

本次成像数据源自在中国江苏省南通市如东县小洋口地区开展的微动勘探实验, 该区近海区, 海洋潮汐等环境噪声来源丰富。实验设置多个观测点, 每个观测点的数据采集节点均按等边三角形布局, 采样频率为 500 Hz。三角形各边长分别为 50、100、200 和 400 m, 边缘设备放置中心到各传感节点距离分别为 28. 87、57. 74、115. 47、230. 94, 具体空间布局形式如图 11 所示。

测试所用数据来自现场测试期间收集的 5 组地震数据, 其中 3 组被选中用于 SWVS 成像对比。通过选择测量数据集作为输入进行 SWVS 反演。将反演生成的模型设为 3 层结构, 并根据经验选取初始模型参数。将剪切波速度的取值范围设定为 0. 5~3. 5 km/s, 同时允许地层厚度存在一定波动, 从而适应不同的地质条件。图 12 展示了该数据集的反演结果。

图 12 中灰度表示各深度候选模型的速度分布密度。随灰度增加, 剪切波速度处于指定深度区间内的比例也随之上升。虚线表示成像根据最小残差准则选择的最佳




图 11 江苏省南通市如东县小洋口地区
Fig. 11 Spatial layout of microtremor survey in Xiaoyangkou Area of Rudong County, Nantong City, Jiangsu Province




图 12 地下 SWVS 示意图
Fig. 12 Schematic diagram of underground SWVS

模型, 代表与输入数据最匹配的地下 SWVS 剖面。反演结果表明, SWVS 具有明显分层特征。表层存在松散沉积物或覆盖物, 其剪切波速度约为 0. 7~1. 0 km/s。风化带或半成岩层对应中等速度区间, 约为 1. 8~2. 0 km/s。深层速度保持在 2. 5~3. 2 km/s, 反映了基岩或强地层的特征。候选模型在各深度范围呈集中分布, 整体反演过程表现稳定且无异常偏移。

在两种不同的初始地层模型中进行实验, 进一步验证即时成像在不同初始地层模型中的稳定性和适应性。初始地层模型 A 具有多层结构特征, 展现出显著的速度差异。该模型显示剪切波速度从浅层到深层存在明显过渡现象, 这体现了由上覆岩层、风化层和基岩构成的典型分层结构特征。表 3 中列出了地层参数的具体数据。初始地层模型 B 则呈现均匀结构特征, 其速度梯度连续分布。本模型中速度逐渐加快, 以模拟地层速度逐渐变化的常见情况, 对应的地层参数包括厚度和剪切波速如表 4 所示。

图 13 展示了这两种初始成像模型中 SWVS 的反演结果。如图 13(a) 所示, 大量候选模型集中在 3 个速度带: 1. 0~1. 2 km/s、2. 0~2. 2 km/s 和 2. 8~3. 2 km/s,

表 3 初始地层模型 A
Table 3 Initial formation model A

层号	厚度范围/km	剪切波速范围/($\text{km}\cdot\text{s}^{-1}$)
第 1 层	0.01~0.10	0.20~1.00
第 2 层	0.05~0.15	1.20~2.00
第 3 层	0.20~0.40	2.00~3.50

表 4 初始地层模型 B
Table 4 Initial formation model B

层号	厚度范围/km	剪切波速范围/($\text{km}\cdot\text{s}^{-1}$)
第 1 层	0.01~0.10	0.80~1.20
第 2 层	0.10~0.20	1.20~1.80
第 3 层	0.10~0.30	1.80~2.80




图 13 不同初始形成模型中的 SWVS

Fig. 13 SWVS in different initial formation models

反映出明显的 3 层分布趋势。最佳模型在 0.05 km 和 0.18 km 深度处表现出速度跃变,初始速度约为 0.9 km/s,随后增加至 1.8 km/s,最终达到 3.0 km/s。

如图 13(b) 所示,各模型均集中于 1.0~1.4 km/s 和 2.0~2.4 km/s 范围。最佳模型分别于 0.10 km 和 0.22 km 深度出现速度拐点。并保持速度由 1.1 km/s 平滑升至 2.6 km/s,其体现边缘成像在速度跨度受限条件下,仍能判定有效速度梯度。

与图 13(a) 相比,图 13(b) 中的候选模型更集中于中低速范围。因此推测其优化空间更为紧凑且收敛方向更明确。在两种初始成像模型下,边缘成像方法都成功反演了合理的 SWVS 剖面,且最佳模型的路径吻合度较高,说明其能正确捕捉地震数据所反映的主要 SWVS。

在边缘微动勘探即时成像的实现过程中,成像精度至关重要。因此,平均绝对误差 (mean absolute error, MAE) 和均方根误差 (root mean sqmave error, RMSE) 被引

入作为评估精度的指标。如图 14 所示,前 5 个成像任务的 MAE 和 RMSE 计算结果表明,成像任务 A 的 MAE 和 RMSE 最高,这可能源于成像时采用了更宽泛的初始地层模型。成像任务 D 的 MAE 和 RMSE 极低,表明所选初始地层模型与实际地下结构高度吻合,因此成像精度最优。通过对比 5 项任务的 MAE 和 RMSE 可观察到初始地层模型对成像精度的影响——初始地层模型与真实地下结构越接近,成像精度越高。整体上,5 组任务的 MAE 与 RMSE 均处于较低水平,验证了本文方法在边缘计算场景下具备优异的成像精度与稳定性。




图 14 不同任务中 RMSE 与 MAE 的比较

Fig. 14 Comparison of RMSE and MAE across different tasks

性能测试实验从功耗、运行时长以及内存利用率 3 个层面对微动勘探边缘即时成像系统的运行性能进行测试。在实验中,将 RK3566 中即时成像模型优化,从而和未经优化的 RK3566 以及本地电脑进行对比,如图 15 所示。




图 15 系统运行性能测试

Fig. 15 System performance testing

未优化的 RK3566 的各项指标最高,而采用优化后的即时成像模型的 RK3566 的指标最低。这是由于优化后模型仅在触发对应功能时实例化相关模块,减少设备的内存占用,提升系统的运行效率,从而提高 RK3566 的性能。优化后的 RK3566 在运行时只消耗 53% 的内存,略低于本地电脑,而本地电脑的内存资源远超 RK3566,说明优化的即时成像模型在资源受限的设备上也能取得优异的效果。

5 结 论

为了应对传统微动勘探横波速度结构成像存在的滞后问题,本文提出一种基于改进遗传寻优算法的微动边缘成像方法。通过在边缘服务器上部署基于 SPAC 的成像算法,实现了即时地下 SWVS 成像。针对性适配边缘节点与传感节点的资源异构特性,构建多约束多目标任务分配模型,有效解决传统分配策略因忽视节点差异导致的资源浪费或任务积压问题。MGOA 算法通过改进的交叉与变异策略及启发式规则,最小化成像总时间同时确保资源高效利用。实验结果表明,所提出的 MGOA 方法能有效降低系统延迟并使能耗表现稳定,实现了延迟与能耗的协同优化。随着系统规模扩大,计算开销将增加,在实际地震勘探环境中,传感器节点易因环境干扰或能量耗尽而失效。未来需要增加自适应调整机制来应对此类突发故障,以进一步提升算法的应用潜力。

参考文献

- [1] 牟新刚,周奇,周晓,等. 一种高频拓展的改进地震干涉算法研究[J]. 仪器仪表学报, 2021, 42(4): 59-66.
MOU X G, ZHOU Q, ZHOU X, et al. Study on an improved seismic interference algorithm with high frequency extension [J]. Chinese Journal of Scientific Instrument, 2021, 42(4): 59-66.
- [2] CHO I, NAKAZAWA T. Shallow microtremor array survey using miniature and small arrays: Strategy for efficient and feasible dense survey[J]. Earth and Space Science, 2024, 11(7): 2023EA003472.
- [3] 李广才,李培,姜春香,等. 我国城市地球物理勘探方法应用进展[J]. 地球物理学进展, 2023, 38(4): 1799-1814.
LI G C, LI P, JIANG CH X, et al. Advances of the application of urban geophysical exploration methods in China[J]. Progress in Geophysics, 2023, 38(4): 1799-1814.
- [4] WANG L X, DUAN R ZH, YANG H Y, et al. A greedy flee in the direction routing algorithm for data quality control system of 3D seismic sensors array[J]. IEEE Communications Letters, 2021, 25(7): 2415-2419.
- [5] TIAN R Y, ZHANG Y X, CAO Y H. A mutation particle swarm optimization method for task scheduling in seismic edge networks[J]. IEEE Internet of Things Journal, 2025, 12(11): 15667-15680.
- [6] CHOUDHARY P, GOEL N, SAINI M. A survey on

seismic sensor based target detection, localization, identification, and activity recognition [J]. ACM Computing Surveys, 2023, 55(11): 1-36.

- [7] LIN J, WANG L X, YANG H Y, et al. A link and energy aware gradient routing method for seismic node networks[J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 9503710.
- [8] TIAN R Y, XING H Y, CAO Y H, et al. Lyapunov-optimized and energy-constrained stable online computation offloading in wireless microtremor sensor networks [J]. IEEE Transactions on Signal and Information Processing over Networks, 2024, 10: 83-93.
- [9] ZHOU X H, ZHENG J B, MENG X K, et al. Design of the energy-balanced wireless sensor networks for 3D seismic exploration[J]. ICT Express, 2023, 9(3): 459-465.
- [10] YIN ZH Y, ZHOU Y, LI Y X. Seismic exploration wireless sensor system based on Wi-Fi and LTE [J]. Sensors, 2020, 20(4): 1018.
- [11] WANG S, LI X Y, GONG Y. Energy-efficient task offloading and resource allocation for delay-constrained edge-cloud computing networks [J]. IEEE Transactions on Green Communications and Networking, 2024, 8(1): 514-524.
- [12] BIN K CH, LUO SH H, ZHANG X P, et al. Compressive data gathering with generative adversarial networks for wireless geophone networks [J]. IEEE Geoscience and Remote Sensing Letters, 2021, 18(3): 558-562.
- [13] GOUDARZI M, WU H M, PALANISWAMI M, et al. An application placement technique for concurrent Iot applications in edge and fog computing environments[J]. IEEE Transactions on Mobile Computing, 2021, 20(4): 1298-1311.
- [14] WU Y R, GUO H F, CHAKRABORTY C, et al. Edge computing driven low-light image dynamic enhancement for object detection[J]. IEEE Transactions on Network Science and Engineering, 2023, 10(5): 3086-3098.
- [15] 李亚,王卫岗,张原,等. 基于改进型 TD3 算法的车载边缘计算任务卸载决策[J]. 电子测量技术, 2024, 47(6): 64-70.
LI Y, WANG W G, ZHANG Y, et al. Vehicle edge computing task offloading decision based on improved TD3 algorithm[J]. Electronic Measurement Technology, 2024, 47(6): 64-70.

- [16] CHAMARCZUK M, AJO-FRANKLIN J, NAYAK A, et al. Insights into seismicity associated with flexibly operating enhanced geothermal system from real-time distributed acoustic sensing[J]. *Journal of Geophysical Research: Solid Earth*, 2025, 130(7): 2025JB031634.
- [17] 占慧芳, 李正权, 武贵路, 等. D2D 辅助移动边缘计算下的任务卸载和资源分配研究[J]. *电子测量与仪器学报*, 2025, 39(1): 90-100.
- ZHAN H F, LI ZH Q, WU G L, et al. Joint optimization of task offloading and resource allocation in D2D-assisted mobile edge computing [J]. *Journal of Electronic Measurement and Instrumentation*, 2025, 39(1): 90-100.
- [18] YIN L X, LUO J, LI K Q. An optimal image storage strategy for container-based edge computing in smart factory[J], *IEEE Internet of Things Journal*, 2023, 10(8): 7204-7214.
- [19] HANEY M M, MIKESELL T D, VAN WIJK K, et al. Extension of the spatial autocorrelation (SPAC) method to mixed-component correlations of surface waves[J]. *Geophysical Journal International*, 2012, 191(1): 189-206.
- [20] 汪利民, 夏江海, 罗银河, 等. 浅地表面波成像技术研究进展与展望[J]. *地球与行星物理论评*, 2022, 53(6): 613-655.
- WANG L M, XIA J H, LUO Y H, et al. Progress and prospect of surface-wave imaging techniques in near-surface applications [J]. *Reviews of Geophysics and Planetary Physics*, 2022, 53(6): 613-655.
- [21] 徐微, 丁志峰, 吴萍萍, 等. 利用密集阵列背景噪声研究通州—三河地区高分辨率三维 S 波速度结构[J]. *地球物理学报*, 2022, 65(12): 4685-4703.
- XU W, DING ZH F, WU P P, et al. Study of 3D high-resolution S-wave velocity structure in the Tongzhou-Sanhe area from ambient noise with dense array [J]. *Chinese Journal of Geophysics*, 2022, 65(12): 4685-4703.
- [22] YIN L, SUN J, ZHOU J L, et al. ECFA: An efficient convergent firefly algorithm for solving task scheduling problems in cloud-edge computing [J]. *IEEE Transactions on Services Computing*, 2023, 16(5): 3280-3293.
- [23] 刘俊毅, 汪洋. 多样性种群增强遗传算法机器人全局路径规划研究[J]. *电子测量与仪器学报*, 2025, 39(9): 39-54.
- LIU J Y, WANG Y. Research on genetic algorithm for robot global path planning with diversity population enhancement[J]. *Journal of Electronic Measurement and Instrumentation*, 2025, 39(9): 39-54.
- [24] 武晓雯, 郭孟营, 胡阿建, 等. 基于改进遗传粒子群算法的无人机路径规划[J]. *仪器仪表学报*, 2025, 46(4): 315-325.
- WU X W, GUO M Y, HU A J, et al. Path planning for UAV based on improved hybrid genetic particle swarm algorithm[J]. *Chinese Journal of Scientific Instrument*, 2025, 46(4): 315-325.
- [25] DOCKHORN A, LUCAS S. Choosing representation, mutation, crossover in genetic algorithms [J]. *IEEE Computational Intelligence Magazine*, 2022, 17(4): 52-53.
- [26] BI J, YUAN H T, DUANMU S, et al. Energy-optimized partial computation offloading in mobile-edge computing with genetic simulated annealing based particle swarm optimization[J]. *IEEE Internet of Things Journal*, 2021, 8(5): 3774-3785.
- [27] 徐佩芬, 李世豪, 凌甦群, 等. 利用 SPAC 法估算地壳 S 波速度结构[J]. *地球物理学报*, 2013, 56(11): 3846-3854.
- XU P F, LI SH H, LING S Q, et al. Application of SPAC method to estimate the crustal S-wave velocity structure [J]. *Chinese Journal of Geophysics*, 2013, 56(11): 3846-3854.
- [28] CHEN X, LYV M ZH, ZHANG K, et al. Energy consumption and time-delay optimization of dependency-aware tasks offloading for industry 5.0 applications [J]. *IEEE Transactions on Consumer Electronics*, 2024, 70(1): 1590-1600.
- [29] MAHJOUBI A, GRINNEMO K J, TAHERI J. EHGA: A genetic algorithm based approach for scheduling tasks on distributed edge-cloud infrastructures [C]. 13th International Conference on Network of the Future, 2022: 1-5.

作者简介



田入运, 2016 年于吉林大学获得学士学位, 2021 年于吉林大学获得博士学位, 现为南京信息工程大学讲师。主要研究方向为无线传感网及嵌入式边缘计算技术。

E-mail: tianry@nuist.edu.cn

Tian Ruyun received his B. Sc. degree from Jilin University in 2016, and his Ph. D. degree from Jilin

University in 2021. He is currently a lecturer at Nanjing University of Information Science & Technology. His main research interests include wireless sensor networks and embedded edge computing technologies.



王红雨,2025 年于南京信息工程大学获得学士学位,现为南京信息工程大学硕士研究生,主要研究方向为分布式计算和无线传感网。

E-mail:202512230851@ nuist. edu. cn

Wang Hongyu received her B. Sc. degree from Nanjing University of Information Science & Technology in 2025. Now she is a master's student at Nanjing University of

Information Science & Technology. Her main research interests include distributed computing and wireless sensor networks.



张宇星(通信作者),2023 年于南京工业大学获得学士学位,现为南京信息工程大学硕士研究生,主要研究方向为信号处理、分布式计算和边缘计算。

E-mail:202312490015@ nuist. edu. cn

Zhang Yuxing (Corresponding author) received his B. Sc. degree from Nanjing Tech University in 2023. Now he is a master's student in Nanjing University of Information Science and Technology. His main research interests include signal processing, wireless sensor networks and edge computing.